



UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO
PROGRAMA DE MAESTRÍA Y DOCTORADO EN INGENIERÍA
INGENIERÍA QUÍMICA – SISTEMAS DE CALIDAD

**PROPUESTA DE INTEGRACIÓN DE UN SISTEMA DE INTELIGENCIA ARTIFICIAL PARA
SISTEMAS DE CALIDAD EN LA INDUSTRIA DE INYECCIÓN DE PLÁSTICOS**

TESIS
QUE PARA OPTAR POR EL GRADO DE:
MAESTRO EN INGENIERÍA

PRESENTA:
I. Q. URIEL AMADOR MÁRQUEZ LÓPEZ

TUTOR:
DR. MARIANO ANTONIO GARCÍA MARTÍNEZ,
FACULTAD DE INGENIERÍA

CIUDAD UNIVERSITARIA, CD. MX., ABRIL 2023



Universidad Nacional
Autónoma de México



UNAM – Dirección General de Bibliotecas
Tesis Digitales
Restricciones de uso

DERECHOS RESERVADOS ©
PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

JURADO ASIGNADO:

Presidente: M. C. Ortiz Gallardo María Georgina

Secretario: Dr. Bernal Pérez Rolando Javier

1^{er} Vocal: Dr. García Martínez Mariano Antonio

2^{do} Vocal: M. C. Alpizar Ramos María del Socorro

3^{er} Vocal: I. Q. Baraja Y Ponce De León Carlos O

Lugar donde se realizó la tesis: Facultad de Química, UNAM.

TUTOR DE TESIS:

NOMBRE

Dr. Mariano Antonio García Martínez

FIRMA

Agradecimientos

Al Dr. Mariano Antonio García Martínez por su asesoría, tiempo y apoyo durante la realización de esta tesis. Por su confianza y compromiso para ayudarme en cada etapa del proceso.

A los miembros del jurado, el I. Q. Carlos O Baraja Y Ponce De León, la M. en C. María del Socorro Alpizar Ramos, la M. en C. María Georgina Ortiz Gallardo, el Dr. Mariano Antonio García Martínez y el Dr. Rolando Javier Bernal Pérez, por sus lecturas del texto, sus observaciones y recomendaciones que enriquecieron mi investigación.

A la M. en C. María Georgina Ortiz Gallardo agradezco enormemente por su guía en mi recorrido académico y por sus consejos para darle mayor relevancia a esta investigación.

Al Consejo Nacional de Humanidades, Ciencias y Tecnologías (CONAHCYT) por la beca otorgada para realizar mis estudios de maestría (CVU: 1146121).

Índice

Índice de Tablas	III
Índice de Figuras	IV
Introducción	1
Panorama actual de la industria de inyección de plásticos	1
Industria de inyección y sus principales retos	1
La presencia humana en la industria de inyección	2
Tecnología inteligente en la industria	3
Objetivo y alcance	3
Descripción metodológica y algunas consideraciones	4
Capítulo 1. Marco Teórico.....	8
1.1 Gestión de la calidad en la industria de manufactura	8
1.1.1 Concepto de calidad y gestión de calidad.....	8
1.1.2 Competitividad	9
1.1.3 Control, aseguramiento y sistemas de gestión de calidad	11
1.1.4 Calidad en la manufactura y sus responsables	14
1.1.5 Influencia de los medios electrónicos en el control de calidad	19
1.2 Mapeo de procesos	21
1.2.1 Análisis del mapeo de procesos.....	22
1.2.2 Problemáticas y control de procesos en la manufactura	23
1.3 La Industria 4.0 y la Inteligencia artificial.....	25
1.3.1 La Inteligencia artificial y la manufactura.....	28
1.3.2 Integración de IA en la industria.....	32
1.3.3 Calidad en la Industria 4.0.....	33
Capítulo 2. La inyección de plásticos y sus principales retos	37
2.1 Resinas termoplásticas y su manufactura	37
2.2 Inyección de plástico	37
2.3 Proceso estándar de inyección de plásticos	38
2.4 Unidades de moldeo por inyección de plásticos.....	43
2.4.1 Componentes clave de una máquina de inyección.....	43
2.4.2 Parámetros en las unidades de inyección	51
2.5 Principales retos del proceso de inyección	61

2.5.1 Materia prima	61
2.5.2 Importancia de las personas en los procesos de manufactura (operación e inspección) .	62
2.5.3 Diseño de productos	64
2.5.4 Gestión de costos	66
2.5.5 Gestión de tiempos	67
2.5.6 Parámetros y máquina de inyección (inyección de piezas plásticas)	69
Capítulo 3. Metodología.....	72
3.1 Búsqueda de información en la literatura: Discriminación de fuentes bibliográficas y primera exploración del tema	72
3.2 Delimitación de retos característicos en la industria de inyección	72
3.3 Reconocimiento de los usos principales de IA en la inyección de plásticos	73
3.4 Elección de problemáticas para abordar con IA y consolidación de metodología de implementación tecnológica	74
Capítulo 4. Propuesta de metodología de implementación tecnológica	76
4.1 Selección de función para la IA.....	76
4.1.1 La labor humana y el procesamiento de máquinas	77
4.1.2 Parámetros de procesos y condiciones de proceso.....	79
4.1.3 Principales funciones de la IA: monitoreo, control y optimización de parámetros; predicción e inspección de calidad.....	80
4.2 Procedimiento y recursos necesarios para la implementación	86
4.2.1 Técnicas de inteligencia artificial	86
4.2.2 Requisitos para el sistema.....	96
4.2.3 Estrategia de instalación o programación.....	104
4.3 Resultados de un modelo inteligente óptimo	116
Capítulo 5. Conclusiones y recomendaciones.....	118
Bibliografía	123
Anexo.....	133
1. Análisis de los artículos relacionados con los retos de la industria de inyección en donde se implementó Inteligencia artificial.....	133

Índice de Tablas

TABLA 1. FACTORES QUE INFLUYEN EN EL PROCESO DE INYECCIÓN.	2
TABLA 2 PRINCIPALES COMPONENTES Y SUS FUNCIONES DE UN MOLDE PARA INYECCIÓN DE PLÁSTICOS	48
TABLA 3. RESUMEN DE LOS RETOS DE MAYOR RIESGO EN LA INDUSTRIA DE INYECCIÓN.....	70
TABLA 4. RESULTADOS OBTENIDOS EN LA PRIMERA EXPLORACIÓN BIBLIOGRÁFICA.....	73
TABLA 5. SEGUNDA EXPLORACIÓN BIBLIOGRÁFICA, RELACIONADA CON EL DESARROLLO DE TECNOLOGÍA CON IA EN LA INDUSTRIA DE INYECCIÓN.	74
TABLA 6. TIPO DE RNA Y ESTRUCTURA DE RED, UTILIZADAS EN LA INDUSTRIA DE INYECCIÓN DE PLÁSTICOS.....	89
TABLA 7. PRINCIPALES HIPERPARÁMETROS EMPLEADOS EN LAS TECNOLOGÍAS CON IA PARA LA INDUSTRIA DE INYECCIÓN DE PLÁSTICOS.	90
TABLA 8. HERRAMIENTAS COMPUTACIONALES UTILIZADAS EN LA IMPLEMENTACIÓN DE TECNOLOGÍA INTELIGENTE (CLASIFICADAS POR SU FUNCIÓN).	96
TABLA 9. DISPOSITIVOS UTILIZADOS EN LA IMPLEMENTACIÓN DE TECNOLOGÍA CON IA, EN LA INDUSTRIA DE INYECCIÓN DE PLÁSTICOS.	100
TABLA 10. DATOS UTILIZADOS EN LA IMPLEMENTACIÓN DE MODELOS BASADOS EN IA.	110

Índice de Figuras

FIGURA 1. SÍNTESIS DE LAS ACTIVIDADES REALIZADAS EN LA INVESTIGACIÓN.	4
FIGURA 2. DIAGRAMA QUE MUESTRA LOS ELEMENTOS QUE COMPONEN LA INDUSTRIA 4.0 Y SU INTERACCIÓN.	27
FIGURA 3. ESTRUCTURA PROPUESTA POR LEE, J. [18] PARA DESARROLLAR SISTEMAS DE IA EN LA INDUSTRIA.	32
FIGURA 4. DIAGRAMA DE LAS ETAPAS QUE SE CONSIDERAN EN LA INYECCIÓN DE PLÁSTICOS.	38
FIGURA 5. REPRESENTACIÓN SIMPLIFICADA DEL PROCESO DE INYECCIÓN.	39
FIGURA 6. ESQUEMA SIMPLIFICADO DE UNA MÁQUINA DE INYECCIÓN POR MOLDE.	43
FIGURA 7. UNIDAD DE INYECCIÓN	44
FIGURA 8. TOLVA DE ALIMENTACIÓN BÁSICA.	45
FIGURA 9. CILINDRO DE CALENTAMIENTO.	45
FIGURA 10. ESTRUCTURA Y COMPOSICIÓN DE LOS MOLDES.	48
FIGURA 11. APERTURA, CIERRE Y EXPULSIÓN DE PIEZAS EN EL MOLDE.	49
FIGURA 12. PIEZA PLÁSTICA CON DEFECTO DE RECHUPE.	55
FIGURA 13. EJEMPLO DE LÍNEAS DE FLUJO EN UN PRODUCTO PLÁSTICO.	56
FIGURA 14. EJEMPLOS DE REBABA EN PIEZAS PLÁSTICAS.	58
FIGURA 15. ETAPAS DEL CICLO DE INYECCIÓN DE PLÁSTICOS DONDE ESTÁ PRESENTE EL PROCESO DE ENFRIAMIENTO.	60
FIGURA 16. DISTRIBUCIÓN DE CAUSAS DE DEFECTOS EN EL PROCESO DE INYECCIÓN.	69
FIGURA 17. METODOLOGÍA EMPLEADA EN LA PRESENTE INVESTIGACIÓN.	72
FIGURA 18. PROCESO DE IMPLEMENTACIÓN TECNOLÓGICA PROPUESTO.	76
FIGURA 19. GRÁFICA QUE EXPONE LAS ÁREAS DEL PROCESO DE INYECCIÓN CON MAYOR FRECUENCIA DE INVESTIGACIÓN.	81
FIGURA 20. TÉCNICAS IA MÁS UTILIZADAS EN LA INYECCIÓN DE PLÁSTICOS.	87
FIGURA 21. PROCESO DE IMPLEMENTACIÓN DE MODELO INTELIGENTE, BASADO EN CASOS REPORTADOS EN LA LITERATURA.	104

Introducción

Panorama actual de la industria de inyección de plásticos

La industria del plástico tiene gran popularidad debido a la alta demanda de sus productos, ya que estos materiales presentan mejores características, en comparación con otros, como su facilidad de procesamiento, transparencia y resistencia mecánica, a la corrosión y hacia ácidos, bases y solventes. El uso de estos productos es variado ya que se pueden observar en la vida cotidiana y en diversos sectores industriales [1].

Recientemente, algunos países han establecido legislaciones que regulan el consumo y la producción de plásticos con el fin de reducir el impacto ambiental derivado de esta industria. Por ejemplo, la Unión Europea en el Pacto Verde [2]; Canadá [3], y Chile [4], han restringido la fabricación de productos plásticos de un solo uso, como las bolsas, envolturas de alimentos, cubiertos, popotes, etc. No obstante, la producción de esta industria ha continuado creciendo durante los últimos años, alcanzando casi 370 millones de toneladas en 2019 [5]. Durante ese mismo año, México ocupó el duodécimo lugar en el consumo de plásticos y el undécimo en la producción, (7 millones de toneladas anuales, con una tasa de crecimiento sostenido desde 2009 del 4.8%) (tan solo de 2019 a 2020 tuvo un aumento del 3% en su producción total) [6]. El consumo de estos materiales se concentra en distintos segmentos del mercado, dentro de los que destacan: los envases, embalajes y productos de consumo cotidiano; materiales de construcción, componentes del sector automotriz y materiales eléctricos-electrónicos [6], [7].

El mercado del material plástico es del 5% del PIB manufacturero, y el 3% del PIB del país [8], es generado a partir de esta industria. Específicamente, la fabricación de bolsas y películas de plástico flexible; de autopartes de plástico y de botellas son las tres actividades de mayor importancia económica por su aportación al valor de producción de la industria mexicana [6]. Las regulaciones ambientales, el incremento global de producción, la diversificación de productos y procesos de la industria de materiales plásticos, y el desarrollo de las industrias inteligentes; han inclinado a los productores de plásticos a buscar nuevas y mejores herramientas tecnológicas que les permitan conseguir mayores rendimientos productivos e incrementar sus niveles de calidad [9].

Industria de inyección y sus principales retos

El moldeo por inyección es uno de los procesos más versátiles en la manufactura de productos termoplásticos. Su popularidad recae en su versatilidad y el alto nivel de complejidad que pueden tener los productos resultantes [10]. El proceso de inyección consiste en un ciclo, el cual inicia con la inyección del material polimérico fundido en un molde cerrado, en donde se enfría y solidifica, y finalmente se expulsa en una forma específica. Este ciclo se repite las veces necesarias hasta que cumple con los objetivos de producción [11].

De acuerdo con Barrios [12], los principales procesos que integran la industria de inyección son: a) la generación de órdenes de producción por parte del área de planeación, b) revisión

de almacén de materia prima, c) gestión de los recursos necesarios para realizar las actividades del proceso, d) adecuación de la máquina de inyección (pruebas de acondicionamiento); e) inyección de productos plásticos; f) inspección de productos, g) acondicionamiento de la zona de producción; h) resguardo de producto terminado; y finalmente, i) la remisión de piezas finales al cliente. Aunque se pueden contemplar diversos procesos en la cadena de valor de esta industria, para esta investigación se consideraron aquellas que involucran actividades que representan mayor riesgo para alcanzar las metas productivas y de calidad, y en las que se compromete en mayor medida la integridad de las personas.

El proceso de inyección es una de las etapas más críticas de esta industria, ya que sus resultados afectan su eficiencia operativa, su imagen ante los clientes y, de este modo, su nivel de competitividad. Existen diversos factores que influyen en este proceso, como los que se muestran en la tabla 1 [13].

Tabla 1. Factores que influyen en el proceso de inyección [13].

Factores que influyen en la inyección	Descripción
Materia prima	Influye directamente en las características del producto final y en el comportamiento que tendrá en la inyectora, por sus propiedades de flujo.
Diseño de la pieza	La complejidad de la estructura del producto determina la facilidad con la que se forma la pieza.
Parámetros de inyección	Las variables que se utilizan en la máquina afectan el modo en que se maneja el polímero y el rendimiento que se tiene en la producción.
Balance de cavidades del molde	La composición del molde debe permitir el llenado uniforme con el polímero y evitar concentraciones inadecuadas del material, que puedan afectar el producto final.
Tiempo de sellado del punto de inyección y enfriamiento	Permite controlar el tiempo con el que se mantiene el material en el molde, hasta generar la estructura con las propiedades deseadas.

Aunque todos estos factores son importantes, se ha reportado que las operaciones relacionadas con la máquina de inyección y moldes son los factores que más comprometen el buen desarrollo de la producción y, además, son la fuente principal de los defectos más comunes en los productos [10].

La presencia humana en la industria de inyección

La importancia que tienen las personas en las industrias manufactureras es tal, que gran parte de las actividades requieren de su intervención. En la etapa de inyección, sus actividades están relacionadas principalmente con la operación de las máquinas de inyección y en el proceso de inspección. La operación de máquinas incluye todas las acciones realizadas para conservar el buen estado del equipo, al mismo tiempo que se mantiene una producción adecuada. En este rubro se contempla el monitoreo y ajuste de parámetros, revisión de componentes de máquina y de los materiales que se utilizan para su funcionamiento, mantenimiento de los equipos, tratamientos que se hacen a los productos antes de pasar a los siguientes procesos; etc. Respecto a la inspección de productos, se comprueba que las especificaciones de las piezas producidas estén acordes con su diseño. Estas revisiones

generalmente son visuales, sin embargo, en algunos casos se realizan pruebas que pueden ser destructivas, lo que representa desperdicio de producto en buen estado [14],[15]. En ambos casos existe un nivel de riesgo alto de no cumplir con los objetivos que se tienen establecidos, ya que cada una de sus actividades dependen de la de la regularidad que el personal tiene durante las jornadas laborales. Dicha consistencia depende de factores, como la motivación de las personas, que si no se tratan correctamente pueden afectar el rendimiento del proceso, la calidad de los productos y, lo más importante, su propia integridad.

Aunque en México la industria de inyección tiene un papel importante, se considera que el 50% de las industrias nacionales no tiene la capacidad de competir en mercados globales debido al estado de obsolescencia tecnológica que mantienen. Dicha obsolescencia ha repercutido también en el nivel de productividad de las industrias de inyección, ya que se estima que actualmente los rendimientos de las inyectoras se encuentran por debajo del 80% de su capacidad ideal [11]. Con el fin de abordar esta situación, en la presente investigación se contemplaron las opciones tecnológicas que han surgido en la cuarta revolución industrial y que han podido integrarse en las organizaciones dedicadas a la inyección de plásticos.

Tecnología inteligente en la industria

El surgimiento de la industria 4.0 ha traído consigo un nuevo tipo de tecnología, la cual ha demostrado ser capaz de modificar la forma tradicional en que se conciben los procesos. Lo anterior ha favorecido no solo a la automatización de los procesos, como en la tercera revolución industrial, sino también su autonomía, al reforzar la comunicación existente entre los procesos industriales y sus componentes (desde los productos, máquinas, hasta las personas) y establecer una interacción dinámica entre ellos (interconectividad) [16], [17].

La inteligencia artificial es una de las herramientas más representativos de la industria 4.0 y su funcionamiento consiste en la emulación de algunas facultades intelectuales humanas en sistemas artificiales. Mediante su uso se busca que las tecnologías tengan la capacidad de aprender automáticamente sobre su entorno y su propio desarrollo, y como consecuencia se pueda aprovechar este conocimiento para optimizar los procesos o para notificar si hay alguna situación que deba atenderse [18], [19]. Para lograrlo, se desarrollan, validan e implementan algoritmos que proporcionan a las innovaciones con IA cierta capacidad de análisis. De esta forma, la aplicación que se le quiera dar a la tecnología inteligente dependerá significativamente de la estructura algorítmica que se le programe [19].

Algunas de las técnicas de IA más utilizadas en la industria son: redes neuronales artificiales, lógica difusa, árboles de decisión, bosque aleatorio, algoritmo genético y las máquinas de soporte vectorial (SVM por sus siglas en inglés).

Objetivo y alcance

Describir una propuesta metodológica que facilite la integración de tecnología inteligente en la industria de inyección, con el fin de optimizar sus procesos.

Alcance: trabajo documental, enfocado en las industrias de inyección de plásticos.

Descripción metodológica y algunas consideraciones

Con el propósito de cumplir el objetivo establecido se realizaron las actividades presentadas en la figura 1.

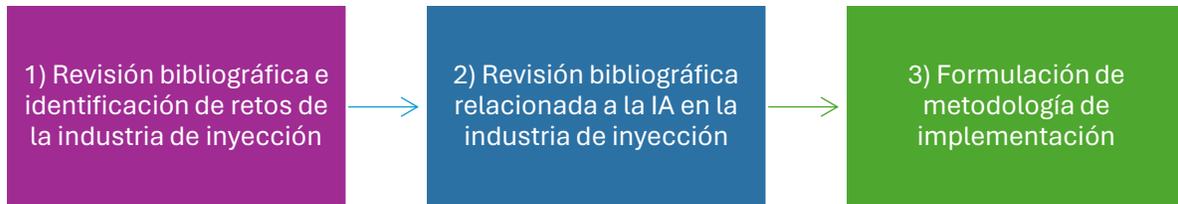


Figura 1. Síntesis de las actividades realizadas en la investigación.

1) Inicialmente, se realizó una revisión bibliográfica en dos bases de datos y en bibliografía especializada para conocer la estructura y los procesos más relevantes que componen la industria de inyección. De esta etapa se definieron algunos de los retos que representan un mayor riesgo en el buen funcionamiento de este tipo de industrias. Dichos retos son: 1) calidad de resinas plásticas, 2) gestión de personal, 3) diseño de productos, 4) estimación de costos, 5) gestión de tiempo y 6) control de parámetros y componentes de la máquina de inyección

2) Después de explorar el funcionamiento de la industria de inyección, se realizó una nueva búsqueda, en las bases de datos Scopus y Compendex, relacionada a las innovaciones de inteligencia artificial en esta industria. Dicha búsqueda sirvió para conocer el nivel de desarrollo tecnológico que se tiene, acerca de la IA, en este sector industrial e identificar los principales enfoques que se le está dando y los elementos que han sido clave para tener una implementación tecnológica exitosa.

De la revisión de la IA en la industria de inyección se pudo apreciar que el uso de tecnología con IA, en la industria de inyección, es un tema que está todavía en desarrollo, ya que aún son pocos los artículos relacionados con estas innovaciones. Se puede afirmar que el interés en esta tecnología es cada vez mayor, ya que se pudo observar un incremento del número de estudios en los últimos años. Lo anterior nos ayudó a confirmar la relevancia de establecer una metodología de implementación que facilite a las industrias nacionales su acercamiento a esta nueva era tecnológica. Del mismo modo, con los resultados de esta etapa se redujo el número de retos industriales que serían considerados en la metodología, con el fin de definir una estructura de implementación más enfocada. De esta manera se seleccionaron “control de parámetros y componentes de la máquina de inyección” y “gestión de personal” para concentrar la información que se utilizaría para consolidar la metodología.

Se realizó una segunda revisión bibliográfica para estudiar los temas que han sido más abordados con IA, de acuerdo con los retos industriales definidos anteriormente. Los resultados en esta búsqueda apuntan que el monitoreo de procesos, control de calidad, simulación, optimización y parámetros de procesos son las áreas más exploradas dentro de la inyección de plásticos. Posteriormente, se recopilaron los artículos pertenecientes a las áreas de investigación y se consolidó el Anexo 1, el cual contiene un análisis de las

innovaciones reportadas en las bases de datos, relacionadas a la IA en los dos retos planteados.

3) La información contenida en los artículos, recopilados en el Anexo 1, se utilizó para establecer la metodología de implementación tecnológica. Del análisis de esta información se delimitaron las principales funciones que se le ha dado a la IA en esta industria y se identificaron las técnicas de IA y los elementos físicos y digitales (como softwares y programas) que más se han utilizado en el desarrollo de estas innovaciones. Del mismo modo, se definieron las etapas de programación o instalación de los sistemas inteligentes. Algunos de los puntos más importantes de esta etapa son:

- La predicción de calidad sería la aplicación en la que se centraría la metodología, debido al número de casos exitosos reportados, los cuales podrían utilizarse como referencia. El objetivo principal de esta función tecnológica, en los documentos revisados, es anticiparse a los diversos inconvenientes que puedan ocurrir durante la producción. De este modo se busca modificar el enfoque tradicional reactivo, en el que se actúa hasta que se detecta un defecto en los productos o alguna anomalía en las máquinas, a uno preventivo, en el que se detectan los problemas (o incluso intervienen) antes de que ocurran. La tecnología predictiva, de esta forma, permiten detectar rápidamente los parámetros que se estén alejando de su rango de operabilidad, facilitando su ajuste y la ubicación con mayor precisión de los productos defectuosos (en caso de fabricarse).
- La red neuronal artificial fue la técnica más empleada en la predicción de calidad y en general en la mayoría de las aplicaciones industriales de inyección. La preferencia de esta técnica se debe, en gran parte, a su capacidad de asociar funciones no lineales y capturar las relaciones entre los datos de entrada y los objetivos de producción [19]. Esta función es muy importante en la industria de inyección, ya que se han reportado más de 100 parámetros involucrados en sus procesos, sin embargo, solo algunos de ellos influyen de mayor manera en los resultados de la producción [10], [21]. Específicamente el tipo de red perceptrón multicapa ha sido más utilizado para estos fines, debido a su buen modelado de funciones complejas y su capacidad de adaptación por su flexibilidad en su arquitectura [22].
- El punto culminante de esta metodología fue la delimitación de los pasos que son necesarios para desarrollar tecnología inteligente. Se distinguieron dos etapas de implementación relacionadas con las actividades realizadas antes de la programación y las que hacen durante el establecimiento de los modelos inteligentes.

La primera fase está compuesta por tres actividades: recopilación de información, preprocesamiento y análisis de datos del proceso. La obtención de datos se hace especialmente por medio de sensores que se instalan en distintas secciones de la máquina de inyección, sin embargo, también se puede utilizar otras herramientas para generarlos, como los simuladores. En el preprocesamiento se normalizan y limpian los datos para mejorar la calidad de la información con la que se alimentan los modelos inteligentes, de tal manera que incremente el rendimiento de sus algoritmos de aprendizaje. Con el análisis de datos se busca ayudar a los modelos inteligentes a solo procesar la

información que se identifica de mayor relevancia para el proceso. Esta etapa es de vital importancia para los modelos inteligentes, ya que su funcionamiento depende en gran medida de los datos con los que se alimenta, por lo tanto, es importante conseguir información de calidad para que los modelos tengan un buen aprendizaje.

La etapa de desarrollo que definí a partir de mi estudio, sobre los modelos inteligentes, está conformada por la programación, entrenamiento, evaluación y optimización de los modelos. La primera fase se refiere al establecimiento de la estructura y los hiperparámetros ¹de la técnica de IA seleccionada. La etapa de entrenamiento fue una de las más discutidas en todo el proceso de implementación. En ella se ajustan algunos parámetros del modelo con el fin de que pueda mejorar su precisión y eficiencia. Se observó que el éxito de esta etapa depende en general de la calidad y cantidad de los datos de entrenamiento y los algoritmos que se utilizan. Durante la evaluación, en los artículos, se revisó el grado de funcionamiento del modelo. En esta etapa el sistema fue alimentado con un conjunto independiente de datos y sus resultados se compararon con valores reales. Con sus resultados se puede conocer el nivel de error que tiene el modelo y, por lo tanto, se puede decidir si cumple o no con los objetivos planteados. Finalmente, la optimización fue realizada para ajustar los hiperparámetros del modelo. Mediante este enfoque se buscó mejorar el funcionamiento del sistema al conseguir la mejor configuración posible de los modelos. La integración de estos pasos demostró ser eficiente para formar sistemas inteligentes óptimos, capaces de predecir eventos del proceso de inyección y con errores pequeños en sus resultados.

A partir de este trabajo se presenta una guía que facilite la planeación e integración de tecnología con IA en las industrias nacionales, dedicadas a la inyección de plásticos. La importancia de esta metodología recae no solo en exponer algunos de los pasos que más han servido para el desarrollo tecnológico, sino en incluir algunas de las especificaciones que más se han utilizado en el proceso de implementación tecnológica. De esta forma, se busca que las industrias aprovechen todas las funciones que la tecnología inteligente ofrece y, con ello, que puedan mejorar su nivel de competitividad, en el mercado interno y global.

Como propuesta de investigación a futuro se podría ajustar esta metodología para ser utilizada específicamente por las micro, pequeñas y medianas empresas. Esto a razón de que las MIPYME representan más del 90% de las industrias dedicadas a la inyección de plásticos y que, de acuerdo con el INEGI, están más restringidas tecnológicamente [7], [23]. Del mismo modo, se podría desarrollar y aplicar esta información para desarrollar un sistema inteligente, en un proceso real y estudiar de qué forma impacta su implementación en su productividad.

En los capítulos de esta tesis se muestra de una forma detallada los elementos que permitieron desarrollar la metodología de implementación tecnológica. En el capítulo 1 se presenta el marco teórico, en el que se exponen algunos conceptos y antecedentes que sirvieron para

¹ Los hiperparámetros son parte de los algoritmos de *machine learning* y se utilizan para ajustar y controlar el proceso de entrenamiento de un modelo. Se hablará más sobre este término en el capítulo 5.

sustentar la investigación. El capítulo 2 se dedica al estudio de la industria de inyección de plásticos y sus principales retos. En el capítulo 3 y 4 se exponen los objetivos y los pasos que se siguieron para formar la metodología. El capítulo 5 contiene la propuesta de metodología, en él se indican las funciones más importantes de la tecnología inteligente, las técnicas más utilizadas en esta industria y los requisitos del sistema (como softwares y dispositivos); también se muestra la metodología de instalación; y por último se señalan los principales resultados que se pueden conseguir con esta implementación. El capítulo 6 incluye las conclusiones de la tesis y las recomendaciones finales.

Capítulo 1. Marco Teórico

1.1 Gestión de la calidad en la industria de manufactura

1.1.1 Concepto de calidad y gestión de calidad

De acuerdo con Camisón [14], actualmente, la gestión de calidad se considera imprescindible para desarrollar cualquier estrategia dirigida hacia el éxito competitivo de una empresa. El objetivo de este enfoque es mejorar la calidad de la organización, por medio de diversos principios, prácticas y técnicas. Sin embargo, para ejercer una correcta gestión de calidad, lo primero que se debe hacer es comprender el término de calidad y observar cómo se relaciona con los procesos industriales. En este sentido, aunque la *American Society for Quality* considera subjetivo el término de calidad, ya que su definición depende de la persona o la organización que utiliza este concepto; la aplicación del término está asociada, la mayoría del tiempo, a las características de los productos o servicios, cuyo objetivo primordial es satisfacer las necesidades de los clientes [24]. Específicamente, en la industria la calidad se contempla como un concepto multidimensional que comprende: a) internamente, la productividad de la organización; b) externamente, el mercado donde se desenvuelve; y c) las expectativas de los grupos de interés (localizados en las dos zonas anteriores) [15].

Dentro de la norma ISO 9000 de 2015² se define a la calidad como el grado en el que un conjunto de características inherentes de un objeto cumple con ciertos requisitos. En este documento agregan que la calidad está determinada por la capacidad para satisfacer a los clientes, y por el impacto previsto (y el no previsto) sobre las partes interesadas pertinentes³. En la norma también señalan el papel que tiene en las organizaciones orientadas a la calidad (gestión de calidad), y mencionan que éstas deben ser capaces de promover una cultura que promueva los comportamientos, actitudes, actividades y procesos que desemboquen en el cumplimiento de las definiciones de calidad para productos y servicios. [24], [25] Con esta perspectiva de gestión de calidad se puede afinar el concepto de calidad y agregar que contempla una conjunción de eficacia y eficiencia productiva, al mismo tiempo que busca un equilibrio organizativo, en donde se adicionan a sus objetivos el cumplimiento de expectativas de todos los posibles grupos de interés [15].

Por otra parte, la gestión de la calidad está compuesta por la combinación de ideologías y métodos aplicables que permiten dirigir las organizaciones hacia una administración orientada al concepto que tienen de calidad. Finalmente, para que este enfoque sea

² Las normas ISO son elaboradas por la federación mundial de organismos nacionales de normalización, pertenecientes a la organización internacional de estandarización (ISO). El objetivo principal de la familia de normas ISO-9000 es unificar y estandarizar los enfoques de sistemas de calidad. Concretamente, la ISO 9000:2015 ofrece los principios y vocabulario necesarios para la implementación de sistemas de gestión de calidad, el cual está representado en la norma ISO 9001:2015 [15], [25].

³ La ISO 9000:2015 define como “partes interesadas” a aquellos grupos que generan riesgo significativo para la sostenibilidad de la organización, si sus necesidades y expectativas no se cumplen. Algunas partes interesadas pueden ser: clientes, proveedores, accionistas, empleados, sindicatos, administraciones públicas, sociedad, entre otros [25].

comprendido y adoptado por todos los miembros de la organización, en la literatura se recomienda que la iniciativa y las actividades de mantenimiento sean respaldadas por el equipo directivo, ya que es en la dirección de las organizaciones donde se conciben las funciones ligadas a la calidad [15].

1.1.2 Competitividad

En general, se puede asegurar que cualquier tipo de industria funciona bajo el principio de satisfacer los requerimientos del cliente. Philip Crosby afirma que, en realidad, la calidad se consigue de manera gratuita ya que, si desde el inicio de las actividades se fabrican adecuadamente los artículos, es posible conseguir rentabilidad en el negocio sin ningún problema que afecte a una organización [26]. Sin embargo, dicho autor menciona que las acciones realizadas para asegurar la calidad en los productos y los procesos definitivamente genera mayor competitividad en las empresas, la cual puede distinguirse desde el interior y el exterior de las organizaciones. Internamente se observa a través de personal más involucrado a las labores y los objetivos de la empresa; procesos y productos realizados con mejor calidad; y con el incremento de la productividad de toda la cadena de producción. Externamente se puede apreciar mayor participación en el mercado y aumento de la satisfacción de todas las partes interesadas [15], [26]. La competitividad empresarial, de este modo, precisa administraciones que estén dirigidas hacia la mejora de calidad, la cual está basada en la relación dinámica existente entre la gestión de calidad, el desempeño organizativo y productivo, y el comportamiento del entorno.

En este sentido, las industrias que trabajan con limitada o nula calidad, por lo general, se caracterizan por tener procesos más caros, ineficientes, inestables e impredecibles, debido a los paros, reprocesos y retrasos que surgen en la producción. Las consecuencias de una mala calidad son, principalmente: mayor generación de desperdicios (materiales, tiempo, espacios y mano de obra); re-inspecciones o inspecciones excesivas que tienen por objetivo evitar que productos no conformes lleguen a los clientes; gastos extra por servicios de garantía, para reparación o cambio de productos defectuosos; incremento de costos (debido a fallas internas y externas de la organización); y, especialmente, aumento de clientes insatisfechos. Las fallas y deficiencias por trabajar sin calidad pueden detonarse en cualquier punto de la cadena productiva, sin embargo, los efectos negativos se acumulan y reflejan en forma de mayores gastos, reducción de ingresos y, finalmente, menor competitividad en el mercado [15].

El nivel de competitividad que manifiesta una organización se puede conocer al comparar diversos indicadores con los de otras empresas del mismo ramo. En dicho análisis se explora principalmente la calidad del producto, la productividad de sus procesos y, adicionalmente, la opinión que los clientes tienen de su productos y servicios. La calidad de los productos se conoce al revisar los atributos del producto y las actividades que se desarrollan para conseguirlos; la imagen o prestigio que goza la organización en el mercado, las relaciones que se tienen con diferentes actores externos para las actividades de su cadena de producción, y el precio que el cliente está pagando por este tipo de producto. El nivel de producción se consigue al contrastar los resultados conseguidos por la organización (como los artículos producidos y vendidos, y las utilidades obtenidas), con los recursos utilizados para su

funcionamiento (materia prima, mano de obra, tiempo invertido, horas máquina, etc.) Para ello, se toma en cuenta la eficiencia o qué tanto se optimizaron los recursos y se evitaron desperdicios, y la eficacia, que contempla el grado de cumplimiento de las metas establecidas.

El tercer componente del análisis está conformado por la voz del cliente, de los clientes potenciales (relacionados con los clientes nuevos o que actualmente consumen productos de la competencia); y de los clientes del pasado, que ahora prefieren productos de otras empresas [15], [27].

La ventaja competitiva en una empresa se refiere a las estrategias que crean valor ante los clientes y que no son sencillas de copiar, o que resultan costosas de implementar a la competencia [139]. Tales estrategias se pueden relacionar con factores internos y externos a la empresa. Por ejemplo, el valor que tiene el conocimiento como recurso intangible lo vuelve una fuente importante de ventaja competitiva, ya que de él surgen las innovaciones tecnológicas, y sus aplicaciones, nuevas formas de organización, etc. Es importante remarcar que estas ventajas competitivas no son estáticas, ya que deben adaptarse y mejorarse, con el fin de que puedan afrontar los cambios que surjan en el mercado y las estrategias que tomen otras empresas. De esta forma, para poder desenvolverse en un entorno industrial globalizado, las compañías deben contemplar diferentes formas de trabajo, organizaciones, tecnologías, entre otras, que las permita destacarse del resto de las organizaciones. [139].

Spulber menciona que, para lograr una ventaja competitiva en una industria mundial, las empresas deben tener una economía de escala mundial y una calidad de producto sobresaliente. Asimismo, debe ser capaz de adaptarse al contexto local en su servicio al cliente, en la adquisición de proveedores, acuerdos de asociación y otras estrategias competitivas. Además, menciona que estas empresas son capaces de aprovechar los recursos que puede contar de su país, de los países proveedores y de los países socios, es decir debe crear una conexión de valor global [140].

Dentro de las ventajas competitivas ⁴que ofrece una producción basada en la calidad, resulta importante destacar el efecto que se tiene en los costos de la organización, los cuales son favorecidos a través un uso más estratégico de los recursos económicos y de los esfuerzos que se realizan en cada proceso [28], [29]. Regularmente este indicador puede abordarse

⁴ Spulber también señala que una forma de aumentar la productividad es que las industrias racionalicen sus organizaciones y que cambien los modelos de trabajo que generan desperdicios. Para ello, estas empresas pueden inclinarse a trabajar en la innovación y la eficiencia productiva para mantenerse en el mercado. [140]

La fabricación de productos plásticos es una de las industrias más relevantes en México (tan solo en 2022, se registró un PIB de \$6.33B MX con este giro industrial [141]). Actualmente, la industria de plástico presenta un crecimiento constante, a pesar de las afectaciones que hubo debido a la pandemia por Covid-19. No obstante, esta industria aún refleja un déficit del 54% [142], [143]. En esta investigación se considera al aprovechamiento/desarrollo de la tecnología proveniente de la industria 4.0 como una estrategia para que las industrias de plásticos que puedan incrementar el volumen de producción de los plásticos con buena calidad y, con ello, mejoren su posición en el mercado internacional.

desde dos enfoques: los costos de prevención y los de evaluación. El primero de ellos incluye los costos de las acciones que se toman para prevenir problemas de calidad, como las actividades de planificación y diseño de calidad, diseño de producción, y otras actividades que incrementen la calidad de los productos y procesos de producción. Los costos de evaluación, por otro lado, se componen por las acciones relacionadas a la detección de problemas durante la producción. Por ejemplo, las actividades de monitoreo mediante gráficos, pruebas e inspección de artículos producidos ayudan a tener un mayor control de los procesos en tiempo real. Su ejecución busca, a diferencia de las actividades de la primera categoría, que se cumpla el diseño del proceso que en ese momento se está llevando a cabo. Con el fin de conseguir beneficios en los costos generales, los enfoques mencionados no deben abordarse de forma aislada, más bien deben tratarse como partes de un sistema que se relacionan dinámicamente [27], [28].

De forma contraria, los costos pueden verse afectados cuando la organización se desenvuelve carente de calidad, lo cual se ve reflejado con la producción de artículos que no cumplen con las especificaciones de calidad de su diseño. Este tipo de pérdidas económicas pueden clasificarse según el momento en el que ocurren, antes o después de que los productos lleguen al cliente:

El primero de ellos engloba los eventos que suceden durante la producción y antes que llegue al cliente, observados como desperdicios de recursos, retrabajos o procesos de selección de materiales no conformes (en donde se separan los productos que podrían aprobarse y distribuirse con menor precio, reacondicionarse o desecharse).

Cuando el producto es entregado al cliente, el costo por la falta de calidad se manifiesta por medio de las garantías que se deben de cumplir por un mal funcionamiento, reposición de componentes o de artículos completos, e incluso puede, en el peor de los casos, contemplarse como gastos por los daños que sufren los consumidores del producto. Cualquiera de los casos afecta, no solo de manera puntual en el costo del evento, también implica una mala imagen de la industria en el mercado y se refleja con un menor número de ventas [27].

Con el fin de tener procesos con mayor control, resulta necesario abordar algunos enfoques que componen la gestión de calidad y que sirven para conseguir, mantener y mejorar la calidad de la organización. Tales enfoques son: el control, aseguramiento y mejora de la calidad y la administración de la calidad total [28].

1.1.3 Control, aseguramiento y sistemas de gestión de calidad

El control de calidad está basado en el uso de técnicas de operación y procedimientos que tienen como objetivo mantener y mejorar la calidad de un producto o servicio, con un costo mínimo [29],[30]. Mediante este enfoque se busca regular el desempeño de los procesos, anticipando y previniendo los cambios negativos que puedan afectar la calidad en la organización [28]. Para lograrlo, se implementan diversas técnicas y actividades como: a) especificación de las necesidades, b) diseño del producto, acorde con las especificaciones anteriores, c) producción conforme a las características esperadas – incluye la revisión de las instalaciones que favorezcan la fabricación – d) inspección de los productos y determinación

del cumplimiento de las metas establecidas; y finalmente, e) examinación del uso del cliente, con el fin de analizar posibles modificaciones de las características del producto [24].

Normalmente, el plan y el diseño de las herramientas necesarias para el control de calidad dependen del tipo de evento que se desea prevenir. Cuando se desea detectar eventos no deseados de forma inmediata, se suele recurrir al uso de controles automáticos y sensores. No obstante, si estas herramientas no se pueden utilizar por practicidad o por la capacidad tecnológica de la empresa, se puede optar por una inspección manual [24]. Asimismo, es posible controlar los procesos a partir de la observación de tendencias en los datos, en largos periodos de tiempo. Esta práctica se basa en el control desde la información. Una de las herramientas más utilizadas en este propósito es el control estadístico de la calidad, en donde, a partir de información recabada del proceso, se analizan e interpretan los datos para determinar el nivel de calidad en la producción [28]. Esta herramienta, a su vez, se complementa adecuadamente con el control estadístico del proceso y con el muestreo de aceptación. Aunque existe una cantidad considerable de métodos y herramientas para controlar la calidad de los procesos, se debe buscar un equilibrio en su implementación, pues si se tiene un exceso de puntos de control se corre el riesgo de caer en la ley de rendimiento decreciente⁵ [24], [31].

El aseguramiento de calidad está basado en diversas acciones, planeadas y sistemáticas, que son necesarias para proporcionar suficiente confianza de que el producto o servicio va a satisfacer los requisitos de la calidad [27], [30]. Es decir, es un esfuerzo total realizado para garantizar que los productos están acoplados totalmente a un conjunto de especificaciones y normas, en los cuales se contemplan distintos parámetros, como sus propiedades físicas y químicas, funciones mecánicas, y los ensambles necesarios para tener un funcionamiento adecuado. El objetivo general de este enfoque es tener completa confianza en que se realizan las operaciones del proceso, según han sido definidas [25], [29].

Las actividades que se implementan en el aseguramiento de calidad no necesariamente están diseñadas para controlar la calidad. Por ejemplo, la prueba de productos contra los estándares de su diseño, aunque es útil en el control de calidad, no cumple los objetivos del aseguramiento de calidad, ya que puede dar confianza para un producto específico, sin embargo, no garantiza la consistencia o continuidad durante suministros posteriores. Para lograr el aseguramiento de calidad se puede recurrir a la certificación de los procesos productivos contra algún estándar. Con estas estandarizaciones, impartidas por agentes externos, se da fe de la capacidad de la industria de contar con procesos que aseguran la continuidad y consistencia en sus actividades, por lo que cualquier artículo que provenga de él cumplirá con la calidad de su diseño [28].

Las funciones que se destacan en el aseguramiento de calidad tienen como objetivo evitar la elaboración de artículos que no cumplan con su diseño. Con ellas se pretende garantizar el cumplimiento de los requisitos operativos, para los directivos, los clientes y autoridades

⁵ De forma sencilla, esta ley explica que aumentar un factor productivo en un proceso, no aumentan necesariamente la producción y los beneficios económicos; también puede disminuir la cantidad producida de artículos y, con ello, disminuir la venta y el ingreso económico [31].

externas [28]. Mediante este enfoque, también se plantea prevenir los problemas que pueden ocurrir en la organización⁶, para ello se procura desarrollar la capacidad de actuar proactivamente ante el surgimiento de algún defecto en la línea de producción, analizar la situación y eliminar sus fuentes, o por lo menos reducirlos a niveles aceptables. De este modo, se busca producir solo artículos en buen estado, mientras se reducen los desperdicios y posibles reprocesos [29].

Dentro de las actividades más comunes para el aseguramiento de calidad destacan:

- 1) Elaboración de documentos que declaran las intenciones de la organización para lograr la calidad.
- 2) Desarrollo de planes que definan la forma en que se conseguirá el aseguramiento de calidad.
- 3) Organización de los recursos que se necesitarán para tal propósito.
- 4) Evaluación de los distintos elementos del proceso, productos y servicios de la organización en donde se localizan los principales riesgos de calidad.
- 5) Análisis de los planes definidos para el aseguramiento de la calidad, en donde se verifica si se contempló la forma de controlar, eliminar o reducir los riesgos identificados.
- 6) Revisión de los riesgos que son contenidos actualmente y la forma en que se amortiguan, de acuerdo con sus planes de la organización.
- 7) Reconocimiento de las características en los productos y estándares de los procesos que se encuentran señalados en normas o regulaciones externas, y que deben cumplirse estrictamente para su permanencia en el mercado [28].

Con estas actividades se pretende mejorar la eficiencia y eficacia de los procesos, así como garantizar los beneficios que se obtienen al mejorar el desempeño de la calidad de las organizaciones.

Por último, el enfoque con base en un sistema de gestión de calidad pretende beneficiar a las organizaciones que lo implementen (como sucedía con los enfoques pasados), y también al resto de las partes interesadas, como clientes, proveedores, entes reguladores y el resto de los grupos relacionados con la organización, lo que lo hace un enfoque más integral. Su objetivo consiste en analizar la organización como un sistema, y definir y administrar los procesos que contribuyen a la elaboración de productos que satisfagan las necesidades de los clientes. Esta gestión de calidad también proporciona las bases para la mejora continua, ya que se considera que debe estar siempre abierto para nuevas formas de trabajo, al aprendizaje adaptativo y generativo, así como a la innovación, para elevar la satisfacción del cliente, reducir los desperdicios, mejorar la calidad de los productos, entre otros [14], [25].

En la norma ISO 9001:2015 se menciona que un enfoque basado en procesos es útil para que las organizaciones funcionen eficazmente, ya que con él se pueden identificar y gestionar los procesos que componen la cadena de valor, los cuales están interrelacionados e interactúan

⁶ En el libro *Managerial Breakthrough*, del gurú de la calidad Joseph M. Juran, se plantea el análisis para el control de procesos antes, durante y después de la ocurrencia de diversos eventos [28].

entre sí. Este enfoque considera la influencia que tienen todas las partes interesadas en las entradas y salidas de los procesos [25].

Una de las ventajas de trabajar con los sistemas de gestión de calidad es que los objetivos de calidad que se logren cumplir complementan otros objetivos de la organización, relacionados con el crecimiento, recursos financieros, medio ambiente, rentabilidad, etc. Resulta importante mencionar que los diferentes sistemas de gestión que maneja la organización pueden integrarse con el sistema de gestión de calidad y, con ello, es posible buscar acciones y estrategias de mejora que se enfoquen en la calidad y en las demás áreas de las organizaciones.

1.1.4 Calidad en la manufactura y sus responsables

El concepto de calidad en la manufactura se comprende teniendo en cuenta a la industria como un sistema y, a partir de ello, las relaciones que existen entre sus componentes. Con esta concepción se pretende estudiar y asignar las funciones y responsabilidades de cada una de sus unidades o áreas funcionales [14], [26]. La responsabilidad hacia la calidad se entiende como la facultad para tomar decisiones sobre la calidad del sistema y también como un método de rendición de cuentas, en forma de costos, reportes de eficiencias, errores o unidades no conformes producidas [24]. En general, el sistema de manufactura se compone de las siguientes áreas:

1. Ventas. Este departamento ayuda a comprender el comportamiento del mercado en la actualidad y realiza proyecciones hacia el futuro, también investiga cuáles son los productos y las características que desean los consumidores y las capacidades adquisitivas del mercado al que está dirigido el producto. Es decir, evalúan el nivel de calidad del producto que el cliente desea o está dispuesto a pagar y determinan los requisitos de calidad que se deben cumplir. Lo anterior se hace con el propósito de definir productos que sean adecuados para diferentes tipos de mercado y que la organización tenga la capacidad para producirlos, de acuerdo con sus restricciones tecnológicas y presupuestales [14], [26].

La entrada del área de ventas está compuesta por los resultados de encuestas de satisfacción del cliente, quejas, informes de ventas, servicio al producto y juicios por responsabilidad al producto. Por medio de esta información es posible saber el nivel de aceptación de los clientes, la demanda actual de los productos y el nivel de calidad real de las unidades (desde la opinión de los consumidores). Además, de los informes de ventas sobre las partes de repuesto, los servicios de reparo por garantía o reportes seguridad de productos al consumidor se pueden conocer problemas potenciales de la calidad y, de este modo, distintas oportunidades de mejora [14]. Por lo tanto, la información que recibe el departamento de ventas sirve para conocer el estado actual de la calidad de sus productos y, con ello, la capacidad de sus procesos.

En los resultados de este departamento se incluyen: las especificaciones físicas, de configuración y ajuste para los procesos; las normas y reglamentos que son aplicables al producto, el tipo de empaque que mejor se ajusta a las características de los artículos y la verificación de calidad que debe implementarse para cumplir con los requerimientos [14],

[30]. Mediante este estudio se desea que el área tenga un sistema continuo de vigilancia y retroalimentación de información para recolectar datos de forma efectiva, ya con estos se pueden conocer los requisitos del cliente y determinar las especificaciones de los productos, junto con sus posibles cambios que le ayudarán a sobrepasar sus expectativas [26].

2. Diseño e ingeniería de producto. El objetivo principal de esta área es diseñar procesos de manufactura adecuados para la producción de un artículo. Para lograrlo, los participantes del área traducen los requisitos del cliente, obtenidos por el departamento anterior, en especificaciones de los productos, y determinan las características técnicas de la operación y sus tolerancias. Una ingeniería pobre o excesiva (para los casos en que los productos sobrepasan los requerimientos del cliente) dan como resultado costos más elevados y menos rentabilidad en el mercado. Por el contrario, un diseño eficiente ayuda a prevenir errores en el proceso de manufactura, lo cual reduce las inspecciones que se le puedan dar y mejora la percepción que el cliente tiene sobre el desempeño y calidad de los productos. En esta área también se determinan los tipos de materiales, y su nivel de calidad, que serán necesarios para producir artículos con la calidad diseñada. Las características de estos materiales dependerán, en gran medida, de las especificaciones determinadas y de los proveedores que se seleccionen para su abastecimiento [14].

Durante el proceso de diseño es conveniente que exista comunicación con otras áreas, como ventas, calidad, producción y adquisiciones, con el fin de prevenir cualquier tipo de problemas que puedan ocurrir, desde etapas iniciales. Las tolerancias definidas dependerán de la variación permisible del proceso y el impacto que tiene las especificaciones en la calidad del producto. De esta forma, se procurará que exista un equilibrio entre la selección de la tolerancia, el costo de producción, la capacidad del proceso, y el nivel de calidad que se quiera alcanzar. Debido a esto, una práctica común para obtener estos rubros es por medio de sistemas normalizados de dimensionamiento, y mediante la aplicación de diseño de experimentos, para determinar los puntos críticos del producto. Para verificar los valores propuestos, antes de concretar la producción en masa, se realizan pruebas del diseño para anticiparse a los posibles problemas que pueden ocurrir durante y después de la producción, con el fin de fabricar productos que cumplan con las especificaciones y que no comprometan la integridad de las personas que lo elaboran, ni de las máquinas que lo producen [14], [30].

3. Compras y recepción. Las funciones principales de esta área es obtener materia prima de calidad y mantener relaciones a largo plazo con los proveedores adecuados. A pesar de que no existe una regla sobre el número de proveedores que una empresa necesita, se recomienda tener solamente un proveedor, debido a que con este número es posible controlar, con mayor facilidad, la calidad de los materiales, del mismo modo como si se tratase de un área interna de la industria. El inconveniente de este caso es el posible desabasto de material, por causas que son ajenas al proveedor y a la organización. Por lo que, para tomar esta decisión es imperativo conocer adecuadamente a los proveedores, su capacidad productiva y los procedimientos que tiene de control de calidad [14], [26]. Una vez seleccionado el o los proveedores, es imprescindible conservar una comunicación efectiva con ellos, de tal forma que sea posible transmitir claramente los requerimientos de calidad de los materiales que se

desean obtener; informar o recibir apoyo ante cualquier problema que surja; y dar retroalimentación (de cualquier tipo) sobre los productos recibidos.

La unidad de recepción debe asegurar que los materiales cumplen con la calidad especificada en el contrato, mediante una serie de inspecciones y pruebas [14]. Los proveedores pueden demostrar su calidad con estadísticas sobre el control y capacidad de su proceso. Sin embargo, las pruebas de conformidad se pueden conseguir mediante ensayos aplicados a los artículos recibidos. Además, resulta conveniente mantener una supervisión y evaluación constante de los proveedores, mediante auditorías de sus procesos, registros de inspección o, de forma interna, con información sobre lotes rechazados, costos por reprocesamiento, entre otros.

4. Diseño de procesos. En este departamento se consideran los costos, el tiempo de implementación, la calidad y eficiencia necesario para realizar los procesos, desde la planificación, hasta las actividades que respaldan la producción. Básicamente, se desea conocer si el proceso tiene la capacidad para satisfacer la demanda actual y futura, y si los productos elaborados cumplirán con la calidad de su diseño, de tal manera que se conserve o mejore la percepción que se tiene de los artículos y la organización en sí ante los clientes y el mercado general. Los resultados de este ejercicio sirven para verificar el nivel con que se cumplen las especificaciones del proceso, y para considerar si es necesario realizar algún mantenimiento previo de los equipos o si se debe comprar, fabricar, arreglar o sustituir algún dispositivo. Dentro del programa de producción se considera todo lo necesario para tener un flujo continuo de fabricación y se verifica la disponibilidad de la materia prima y herramientas de trabajo; la localización de operaciones de precisión en la secuencia y equipo imprescindible para efectuar el proceso [14].

4. Manufactura y ensamblaje. Su objetivo es asegurar que el producto se fabrica con las especificaciones de calidad establecidas y que la cantidad de producción va acorde con lo programado. Los supervisores de primera línea se consideran responsables de hacer cumplir con este propósito, debido a que se encargan de administrar los suministros con los que cuenta la línea de producción y de comunicarse proactivamente con las demás áreas, procurar un ambiente laboral adecuado. Además, tienen la función de proveer oportunamente los recursos e indicaciones necesarias para que el equipo de producción alcance los objetivos delimitados, o para actuar adecuadamente ante el surgimiento de eventos no deseados que puedan comprometer el cumplimiento de estas metas.

Por otra parte, las actividades que realizan los operadores de la línea de producción son de tal importancia para la industria, que es fundamental que todo el personal involucrado en la cadena de suministro del producto esté contemplado en los programas de calificación cuenten con programas de calificación sobre el desarrollo de sus labores: actualizaciones en los procesos, manejo de equipos, cumplimiento de buenas prácticas en la manufactura; y sobre otros asuntos pertinentes a los sistemas de calidad (como las fuentes de variación y generadores de defectos, métodos para mejorar la calidad, etc.) Con el fin de fomentar un entorno orientado a la calidad y hacia la mejora de las prácticas de manufactura. El área de manufactura y ensamblaje debe tener una comunicación robusta entre el departamento de

manufactura e ingeniería de diseño, ya que, de presentarse algún inconveniente en la operación, se debe contar con la capacidad para mitigar y solucionar cualquier problema [14], [15].

5. Inspección y pruebas de productos. Esta área puede considerarse innecesaria en procesos que trabajan con niveles altos de calidad, a causa de que se piensa como una actividad que no agrega ningún valor al producto. Sin embargo, el área de inspección de calidad no solo se encarga de depurar productos buenos de malos, sino también de conocer a profundidad la forma en que se desenvuelven los procesos. Esto último se realiza a partir de datos que le facilitan conocer, corregir y mejorar las fases productivas y la calidad del producto [14].

Se debe enfatizar que, aunque se cuente con departamentos de aseguramiento de calidad o incluso que se tenga personal del área de producción dedicada exclusivamente a inspeccionar y hacer pruebas a los productos, todo el personal relacionado a la línea de producción debe estar comprometido y ser responsable de verificar constantemente la calidad de los artículos elaborados. De esta manera, es importante resaltar que la calidad lleva a cabo por todas las personas relacionadas con el producto, no solo por los inspectores [14], [26].

Existen diversos factores que afectan el desempeño de los inspectores y que se refleja en los resultados derivados de sus labores. Las fuentes más comunes están relacionadas con las distintas capacidades de percepción y criterios que tienen las personas, así como la dificultad de encontrar defectos específicos y al cambio del nivel de calidad entre un producto y otro (lo que puede dar como resultado una cantidad elevada de no conformidades halladas al pasar de una producción a otra). Para mitigar estas posibles variaciones entre inspectores, es conveniente usar muestras de composición conocidas, las cuales permiten evaluar y mejorar el desempeño del personal, otorgándoles pautas más claras para analizar efectivamente la calidad de los productos [14]. Aunado a esto, las personas de esta área deben tener la capacidad de operar equipos de medición y conocer la importancia de su conservación, mantenimiento y calibración. La razón de esto es que, al trabajar con dispositivos de medición que ofrezcan valores confiables y que puedan ser comprobables por terceros, se pueda garantizar que los datos obtenidos en cualquier actividad son correctos. Del mismo modo, se desea que estas inspecciones den lugar a un control estadístico de calidad, para conocer oportunamente el desempeño del proceso y, con ello, dar paso a propuestas relacionadas con mejoras de la calidad [26].

6. Mantenimiento e ingeniería de herramientas. Su función radica en diseñar y mantener en el mejor estado posible todas las herramientas y máquinas que se utilizan en la manufactura, y en otras actividades relacionadas con la producción. Para ello, se utilizan técnicas estadísticas que permiten evaluar el estado actual de las herramientas de trabajo, además, se sirven de programas de evaluaciones periódicas que aseguran el cumplimiento de las funciones establecidas [14].

7. Empaque, almacenamiento y distribución. Esta unidad se encarga de proteger y preservar la integridad del producto, desde que sale de las instalaciones donde se fabrica, su tránsito en el transporte, hasta el momento en que está en manos del cliente. Si bien el control de calidad

está comúnmente relacionado con esta actividad, el departamento de empaque abarca otras actividades, como la distribución, instalación y manejo de los productos [26].

Cada área que integra el sistema de gestión de la calidad cumple sus funciones de forma dinámica, con el objetivo de cumplir sus propias metas, al mismo tiempo que apoya a los demás departamentos a alcanzar las suyas y las de la organización en general. No obstante, es importante reconocer que existe variabilidad en cada uno de los procesos y, en ese sentido, los resultados obtenidos dependerán del control que se tenga en ellos. Al tratarse de un sistema dinámico, cuando los procesos carecen de estabilidad se favorece la presencia de errores que, aunque luzcan minúsculos para un departamento, pueden aumentar su magnitud y sus consecuencias conforme se avanza en la cadena productiva, hasta que derivan en situaciones críticas para la calidad de los productos y la competitividad de la organización [14], [30].

Particularmente dentro del departamento de manufactura pueden surgir dos tipos de variaciones: aleatorias y asignables. El primer tipo de variación considera las situaciones que forman la distribución estadística normal del proceso. Es decir, su origen parte de la variabilidad inherente de cada componente del proceso: de las actividades humanas en cada ciclo de operación, del nivel de calidad de las materias primas, del desempeño de las máquinas y del equipo de manufactura, etc. Con esto se espera que los resultados se agrupen alrededor de la media estadística, sin embargo, también debe considerarse que una parte de los productos tendrá características que podrían alejarse de este valor. Por lo que, mientras el proceso opere de forma normal, la posibilidad que ocurra esta variabilidad continuará presente. A diferencia de la variación aleatoria, la de tipo asignable se relaciona con las situaciones que ocurren en condiciones de operación que no se contemplaron “normales”. Este tipo de eventos se observa como un punto fuera de la curva de distribución normal y, en ese caso, se puede decir que el proceso no está en control estadístico [29].

Taguchi, uno de los gurús de la calidad, abordó el tema de variaciones en la línea de producción y desarrolló el término “factores de ruido”, los cuales define como variaciones difíciles de controlar y que afectan las características del producto. Dicho concepto lo clasifica en tres clases [28], [29]:

1. Factores de unidad a unidad. Están integrados por las variaciones aleatorias inherentes al proceso o producto y están asociadas al proceso que está bajo control estadístico.
2. Factores internos. Las variaciones de este tipo ocurren por la influencia del tiempo en los equipos que intervienen en la producción. Por ejemplo, componentes mecánicos desgastados por el uso, desperdicios de materias primas o fatiga de piezas metálicas.
3. Factores externos. Involucran fuentes ajenas al producto o al proceso, como las provenientes del medio ambiente, de situaciones adversas que pueden sufrir los proveedores, etc.

A partir de esta clasificación, Taguchi propone un “diseño robusto⁷”, en donde se busca desarrollar procesos que no sean sensibles a los diferentes ruidos que existen. Es decir que las actividades involucradas en la producción, así como el propio producto, no sea afectado fácilmente por situaciones adversas que se puedan presentar [32]. Para lograrlo, se recomienda recurrir a nuevas herramientas tecnológicas, establecer relaciones de mercado más fuertes, desarrollar análisis de riesgos más precisos, etc., con tal de prever la mayor cantidad de ruidos posibles o actuar efectivamente ante la ocurrencia de alguno.

1.1.5 Influencia de los medios electrónicos en el control de calidad

Cada vez resulta más común el uso de aparatos electrónicos en las actividades esenciales de las industrias. Específicamente, las computadoras han sido involucradas en un mayor número de tareas y giros industriales. La preferencia hacia estos dispositivos proviene de su capacidad de adaptarse a una gran variedad de componentes industriales, ejecutar rápidamente distintas operaciones y manejar un volumen elevado de datos. A través de la programación de estos equipos es posible realizar análisis de los datos del proceso y controlar actividades específicas de la cadena de valor [14]. Dichos dispositivos pueden favorecer a la calidad por medio de las siguientes actividades:

Recolección de datos: Debido a que los procesos industriales generan grandes cantidades de datos, se desea aprovechar la mayor cantidad de información, en el menor tiempo posible. Las computadoras pueden cumplir este objetivo con menores costos y un número mínimo de errores de captura. Además, esta actividad se puede efectuar automáticamente, por las vías de comunicación entre los equipos de medición y las máquinas de producción, o por interfaz directa con los sistemas operativos. Una vez conseguidos los datos, es indispensable seleccionar la información útil para los análisis posteriores, identificar el ruido que existe en los valores y conocer la dependencia que existe entre una variable y otra. Otra ventaja que se tiene al trabajar con una computadora en el manejo de datos es la capacidad de consultar y actualizar la información en intervalos cortos de tiempo y transmitirlos eficientemente a cualquier terminal de la organización.

Análisis de datos. Por medio de las computadoras se gestionan los datos del proceso, reduce los ruidos presentes entre los valores, analiza la información y, finalmente, elabora informes con los resultados (en forma de reporte, tablas, gráficas, entre otros). Estas operaciones se pueden efectuar en tiempo real, utilizando los datos históricos o solo los actuales. De igual manera, es posible definir reglas de decisión en los programas, que indiquen cuando se reconozca la presencia de algún problema de calidad y también, que sugiera diferentes acciones correctivas que se puedan llevar a cabo.

Control de procesos e inspecciones automáticas. Recientemente, a las funciones básicas de las computadoras, como las mencionadas anteriormente, se les ha añadido la capacidad de controlar procesos, a través de las máquinas involucradas con las líneas productivas. Otros elementos que complementan el control de los procesos son los robots, sensores y

⁷ El diseño robusto involucra tanto el diseño del producto, como el diseño del proceso [32].

dispositivos actuadores. Cuando estas unidades trabajan en conjunto, son capaces de medir y controlar variables críticas del proceso, a fin de mantenerlas dentro de los límites aceptables y evitar así operar en condiciones inadecuadas.

Una razón para buscar la implementación de sistemas computarizados que automaticen procesos es que vuelve las operaciones más seguras para el personal y los equipos industriales, al mismo tiempo que ayuda a reducir los costos y tener mayor productividad, debido a la disminución de paros y desperdicios originados por condiciones del proceso fuera de especificación. La velocidad de reacción del sistema operativo de la computadora da lugar a que se tomen acciones correctivas de forma inmediata, por lo que el ajuste de las condiciones se realizará de tal forma que no se originen materiales defectuosos o, en caso contrario, se pueda localizar precisamente el producto no conforme.

Debido a que las tareas de inspección y pruebas del proceso se pueden contemplar como actividades incluidas en la producción, incluso para manufactura de alto volumen, la automatización de los procesos también ha desarrollado actividades de inspección por medio de equipos computarizados capaces de revisar en tiempo real los artículos elaborados y, con base en su programación, decidir si algo es aceptable, o si debe separarse y clasificarse (en el caso de que se trabaje con componentes para ensamble). La alta velocidad de inspección y la capacidad para tomar decisiones sobre la calidad de producción ha provocado un mayor interés en el desarrollo de tecnología que pueda adaptarse mejor a industrias ya establecidas y que implican altos niveles de especialización [31], [33].

Si bien, la integración de tecnología en los sistemas de calidad implica un amplio margen de beneficios (no solamente para el sistema de calidad, sino también para los niveles productivos de la industria), su implementación debe considerar temas relacionados con la organización (como su capacidad adquisitiva, el nivel de especialización de sus procesos); el mercado en el que se desenvuelven; y de la oferta de tecnologías disponibles para su adquisición o para su desarrollo. Con el fin de elaborar una metodología de implementación tecnológica para la industria de inyección que cubra etapas de proceso críticas, en el siguiente apartado se hará una revisión sobre el mapeo de procesos, para ayudar a definir en dónde se podría incorporar la tecnología con inteligencia artificial.

1.2 Mapeo de procesos

Una de las herramientas más útiles y básicas para la administración y control de la calidad es el mapeo de los procesos. Mediante ella se puede tener una perspectiva más completa de las actividades que se realizan en una organización, los personajes y recursos que se involucran y los factores de riesgo que pueden afectar al cumplimiento de los objetivos [33]. Su objetivo consiste en gestionar los procesos medulares en una organización, para garantizar su funcionamiento adecuado e identificar los puntos de mejora [34].

En la administración de la calidad se comprenden las siguientes prácticas en la gestión de procesos:

- Identificar las actividades vitales que generan valor al cliente y las partes interesadas; y rentabilidad y competitividad a la organización.
- Determinar las necesidades de cada fase del proceso.
- Reconocer el personal que interviene en cada una de las etapas (de forma interna o externa).
- Optimizar los procesos de trabajo delimitados, para cumplir los requerimientos de la organización.
- Prevenir problemas que puedan afectar el desarrollo de las tareas de los procesos, el equipo y la integridad del personal de la organización [33].

Con el fin de realizar una gestión adecuada de los procesos es necesario planear y administrar las actividades que están involucradas a lo largo de la cadena de valor. Para lograrlo, se deben identificar los procesos y requerimientos de la organización, lo más apegado a la realidad, desde la adquisición de conocimiento del mercado, para planificar y establecer las pautas y el alcance de la producción, hasta la entrega de los productos terminados o servicios a los clientes [15], [33]. En general, los diagramas que resultan de los mapeos pueden ser de alto o micro nivel. En los primeros se tiene una visión general, sin mucho detalle, de los procesos principales del sistema. Los diagramas micro tienen más especificaciones de los componentes de cada proceso, por ejemplo: las variables de salida y entrada de cada etapa, las actividades que agregan valor y las que no aportan nada; detalles de las operaciones y los objetivos de los procesos que tiene cada etapa del proceso [15].

Una forma de definir y comprender las actividades de una organización es de acuerdo con el valor que ofrecen al cliente. En ese sentido, los procesos se pueden clasificar en los que generan valor y los que son de apoyo:

Procesos de creación de valor. Se refieren a las actividades que permiten el desarrollo de la empresa y que están alineados con las competencias centrales y los objetivos de la compañía. Su realización da lugar a la elaboración de productos. Además, su cumplimiento repercute directamente en la satisfacción de los clientes, al mismo tiempo que impacta la obtención de las metas estratégicas de la organización y facilita el alcance de una ventaja competitiva sostenible. En este tipo de procesos (también llamados procesos centrales) se incluye el diseño del producto y los procesos de producción y entrega. El diseño del producto abarca

todas las actividades que se realizan para reunir los objetivos de la empresa, requisitos del cliente, conocimiento de mercado y las especificaciones funcionales dictaminados por fuentes externas (como normas gubernamentales). Los procesos de producción y entrega, por otro lado, están relacionados con las actividades de creación de productos y su disposición a los clientes. Finalmente, existen otros procesos que también crean valor, pero no se localizan específicamente en las categorías anteriores, como la investigación y desarrollo, adquisición de tecnología, gestión de proyectos, entre otros [15], [33].

Por su parte, los procesos apoyo dan estructura a los procesos centrales, pero no se consideran como generadores de valor para los productos. En este sector se contemplan algunas áreas como contabilidad, servicios legales, departamento de recursos humanos, etc. Si bien estas actividades no agregan valor a los productos, su participación en la industria facilita el cumplimiento y funcionamiento de toda la compañía [33].

Es importante conocer las unidades que componen la cadena de valor, ya que con ello se pueden identificar los procesos que se llevan a cabo en cada uno de ellos, las interacciones con otras unidades del sistema, y sus requisitos para cumplir los objetivos de la organización. Estos requerimientos dependen totalmente del tipo de actividad que realiza la organización, los productos que elaboran, la voz del cliente y el tipo de procesos internos que posee (si son de creación de valor o de apoyo). Para los procesos centrales estos requisitos están basados en las necesidades del consumidor o clientes externos. De esta forma, las materias primas, el nivel de especialización de los empleados o el grado de especialización tecnológica que se implemente en la organización se determinarán de acuerdo con el nivel de calidad que desean los consumidores o por la dictaminación de alguna norma. En el caso de los procesos de apoyo, estas condiciones se relacionan con las necesidades de los clientes internos y se alinean con los procesos centrales [33], [34].

1.2.1 Análisis del mapeo de procesos

Como se mencionó anteriormente, el análisis de los procesos por medio de un mapeo posibilita el incremento del nivel de cumplimiento de los requerimientos, al identificar los puntos que necesitan corregirse. De esta manera es posible disminuir, por ejemplo, el tiempo ciclo de los procesos, los defectos producidos o el número de pasos que no proporcionan valor. Por medio de esta herramienta también se puede delimitar la forma en que se desea que se realicen los procesos, al permitir la definición de rutas nuevas que generan valor o que facilitan la realización de actividades. Asimismo, el mapeo sirve para orientar a los colaboradores sobre el desarrollo y la importancia de sus actividades; establecer mejores métodos de organización, identificar oportunidades de mejora, y para evaluar, u optimizar las medidas de desempeño [35].

El mapeo de procesos se lleva a cabo mediante diagramas que, dependiendo el grado de detalle, se pueden clasificar en diagrama de relaciones, de procesos interdisciplinarios y flujogramas, de los cuales el primero es el menos detallado, y el último el que posee el máximo nivel de especificación. El diagrama de relación indica, a grandes rasgos, las interrelaciones o vínculos que existe entre los clientes y proveedores de la organización, así

como las funciones de cada uno. En los diagramas de proceso interdisciplinario muestran las cadenas de adición de valor de los principales procesos de la organización, y las funciones encargadas del desarrollo de cada etapa. Finalmente, los flujogramas exponen específicamente la forma en que se realizan las tareas, las secuencias de actividades, sus responsables, y las entradas y salidas de los procesos [35]. El tipo de datos utilizada para esta actividad depende directamente del proyecto sobre el que se trabaja. Generalmente se puede utilizar información relacionada con el desempeño del proceso, como el costo, tiempo, efectividad, o número de defectos [34].

Para construir los diagramas de flujo que ilustren los procesos industriales, es indispensable definir si los procesos que se revisan son centrales o de apoyo. En general, se recomienda partir de los resultados o expectativas del cliente y, con ello, retroceder en el proceso para identificar los puntos clave para producir cada resultado. En cada subproceso es importante comprender los insumos que se necesitan para llegar a ese punto y saber cuál es la fuente de cada uno de ellos (si proviene de otro subproceso o si es de algún proveedor externo). Este ejercicio se realizará hasta que el insumo provenga solamente de proveedores externos [33], [34].

En el análisis del mapeo, inicialmente, se debe interpretar el diagrama completo y ver si está ordenado en secuencia lógica o se deben reordenar sus componentes; si se pueden combinar pasos, si es posible prescindir de alguno de ellos que no agregan valor al producto o, por el contrario, si es necesario agregar uno para mejorar la calidad o el desempeño operativo. Para lograrlo se revisan las etapas que presentan cuellos de botella y en donde podrían ocurrir errores que afectarían el cumplimiento de los objetivos de producción. Finalmente, como resultado del análisis se definen los puntos donde se debe medir la calidad y se identifican las habilidades, equipos y herramientas que son necesarios en cada etapa para que el proceso fluya adecuadamente (se considera si es posible automatizar alguna actividad) [32], [33].

1.2.2 Problemáticas y control de procesos en la manufactura

Existen errores que se originan típicamente en los procesos productivos y se relacionan con la omisión de pasos en las actividades del proceso, errores de configuración, piezas faltantes o equivocadas o ajustes incorrectos. De estos errores se deben estudiar rigurosamente los que son cometidos por las personas, ya que su ocurrencia es el reflejo directo de que el sistema de producción es ineficiente y aunque su origen está ligado a descuidos por falta de reforzamiento, mala interpretación de las instrucciones de trabajo, distracciones o falta de atención; es importante reconocer que la fuente original está en el mismo sistema.

Los métodos para abordar los errores y defectos en los procesos varían de acuerdo con el momento en el que se tratan: 1) Al corregir el proceso rápidamente, poco después que ocurren los errores (aunque con este enfoque sí se generan desechos y reelaboraciones); 2) deteniendo el proceso antes que ocurran los errores potenciales (no se considera que el tiempo que se invierte en esta actividad ofrezca valor agregado a los procesos); y, 3) al eliminar defectos y errores desde el diseño de los procesos, donde se reducen las posibilidades de que ocurran eventos no deseados [33].

De forma general, todos los indicadores de desempeño industrial fluctúan alrededor de un nivel promedio. No obstante, estos estándares pueden desviarse debido a anomalías o eventos atípicos. Con el fin de mantener la estabilidad de los procesos y asegurar la conformidad con los requerimientos, se realizan actividades para controlar los procesos, al eliminar las causas de las situaciones fortuitas y mantener constante los indicadores de desempeño [33], [34].

Para las industrias manufactureras, el control puede aplicarse desde las entradas del sistema (por ejemplo, en la materia prima), los procesos, productos, hasta los servicios finales. Existen diferentes mecanismos y prácticas que facilitan el control de la calidad en la manufactura. Por ejemplo, se pueden implementar sistemas de alerta que advierten cuando ocurren situaciones indeseables que afectan el desarrollo de los procesos. Su objetivo es que, cuando ocurra alguna anomalía, se tenga la capacidad de identificar fácilmente los eventos indeseables y, como consecuencia, de ajustar el proceso para estabilizar el desempeño. Para ello, las señales que producen comúnmente son visuales y, en algunos casos, también audibles, y se ubican en las herramientas de trabajo, puntos de producción, mantenimiento y flujo de material [33].

En el control también se contemplan los equipos de trabajo, su exactitud y variabilidad; el desempeño de los operadores, sus habilidades y conocimiento; factores ambientales y la exactitud de los resultados de medición y los datos utilizados. La inspección de los productos finales es una práctica recurrente para el control de procesos, en ella se realizan pruebas funcionales para garantizar el cumplimiento de las características de los productos. Del mismo modo se puede implementar tecnología a lo largo de la cadena de valor para supervisar, anticipar y actuar en favor del proceso. Aunque existen diferentes métodos orientados en el control de procesos, en la presente investigación se opta por utilizar las funciones de la tecnología proveniente de la Industria 4.0, debido a su amplio rango de aplicación y a los beneficios que ha demostrado cumplir [16], [33].

1.3 La Industria 4.0 y la Inteligencia artificial

La tecnología proveniente de la cuarta revolución industrial ha traído consigo nuevas formas de concebir los procesos para cualquier tipo industria. El origen de esta tecnología, denominada inteligente, es resultado del avance de las tecnologías de la información, operación y comunicación (principalmente con el uso y aprovechamiento de las herramientas del internet) y su integración en los medios industriales tradicionales, en sus procesos físicos y digitales [16], [17], [36]. Lo anterior ha dado lugar a la creación de sistemas que promueven la comunicación e interacción entre los productos, máquinas y las personas que componen una industria, otorgándole al sistema cierto grado de autonomía [17], [37].

Los productos de la industria 4.0 han potenciado diversos factores industriales, de los que destacan: el mejoramiento de los sistemas de producción y la calidad de los productos (debido a sistemas de control de calidad más robustos e instantáneos); la formación de cadenas de suministro con mayor capacidad de respuesta; y el uso eficiente de datos “inactivos” o que anteriormente no eran contemplados [16], [17] Por lo que, para las organizaciones y sus directivas que deseen integrar a sus sistemas este tipo de tecnología se les presenta un reto importante, ya que deben comprender, valorar y evaluar el abanico de opciones tecnológicas que funcionan con estos principios; definir los puntos donde se puede implementar estas herramientas y, finalmente, reunir los requerimientos necesario para su implementación, desde su infraestructura, hasta la capacitación del personal para el manejo de los equipos inteligentes.

A diferencia de los productos tecnológicos de la tercera revolución industrial, caracterizados por automatizar los procesos productivos; en la cuarta revolución industrial se pretende alcanzar autonomía en la cadena de producción, a través de una interconectividad, basada principalmente en internet, entre los medios de producción físicos y digitales [16], [17]. El objetivo principal del diseño de los dispositivos “inteligentes”, es que puedan: realizar cálculos de forma inmediata, almacenar una gran cantidad de datos y comunicarse e interactuar con los diferentes elementos de su entorno [17]. Es decir, se desea que estas herramientas, según su programación, sean capaces de obtener, codificar y analizar información de algún punto del proceso y que, con los resultados obtenidos, puedan tomar decisiones, ejecutar acciones y comunicar el estado del proceso a los demás elementos de la cadena de valor (máquinas o personas) [37].

Con la cuarta revolución industrial se ha beneficiado la industria en todas las etapas de la cadena productiva, lo cual se puede ver reflejado en un mayor cumplimiento de las necesidades de los clientes, aprovechamiento de capacidades de la producción, disminución de desperdicios de recursos y potencialización de la imagen de las organizaciones en el mercado. Asimismo, ha provocado cambios en otros campos socioeconómicos, ya que ha favorecido a la implementación de nuevos modelos de negocios y servicios; a la elaboración de productos más complejos e inteligentes; y la generación de entornos de trabajo más interactivos y colaborativos [17], [38]. De esta forma, la competitividad de las industrias se

ha beneficiado directamente por el nivel de inteligencia que son capaces de integrar en sus procesos.

El objetivo de desarrollar interconectividad dentro del sistema industrial radica en fomentar una interacción dinámica y permanente entre los productos y los distintos elementos que componen una organización, sin importar su ubicación o las actividades que realice [16]. Se busca que todos los componentes de la industria puedan comunicarse entre sí y que la información compartida contemple la mayoría de las operaciones de la producción, con el fin de tener la capacidad de evaluar y pronosticar escenarios en las distintas etapas productivas y, con ello, decidir las actividades que se deben llevar a cabo para alcanzar los objetivos de la organización [17]. De esta forma, se tendría la seguridad de que cualquier evento que ocurra podrá ser anticipado o detectado oportunamente por la tecnología inteligente y que la información del evento será comunicada a las demás máquinas, personas o elementos que integran a la industria, con el fin de que tomen las medidas necesarias para mantener un nivel de producción adecuado [16], [17].

La interconectividad en la industria, además de establecer vínculos entre los elementos que integran la organización, también da lugar a relaciones más estrechas entre los clientes y la industria. A través de los servicios de soportes inteligentes ha sido posible conectar los productos con las opiniones e información de uso de los clientes, durante todo su ciclo de vida. Esto ha permitido distinguir el nivel de aceptación del producto en el mercado e identificar su desempeño real y los principales factores de falla. Lo anterior ayuda no solo a conocer la posición de la organización en el mercado, también a delimitar mejoras de los procesos y productos; y promover la cooperación entre los integrantes de la cadena productiva; establecer nuevas líneas de negocio [16], [17].

Todos los procesos que integran las industrias generan una gran cantidad de información, sin embargo, no siempre es utilizada adecuadamente. La tecnología inteligente, en este sentido, pretende aprovechar el mayor número de datos posibles, provenientes del tiempo de vida de los componentes del proceso, los parámetros de fabricación, las condiciones climáticas, la calidad de las piezas producidas, el nivel de funcionamiento de las máquinas, etc. Tales datos pueden ayudar a generar, en tiempo real, diagnósticos de la situación actual del proceso y, adicionalmente, a planear los siguientes pasos que se deben tomar para mantener o incrementar su eficiencia [16], [37]. Por ejemplo, si se presenta una variación de los parámetros de operación, la tecnología inteligente debe ser capaz de detectar y comprender que este cambio puede afectar la calidad de los productos y, por lo tanto, debe corregir o mandar instrucciones para ajustar los parámetros, antes que se vea afectada la producción o que se elaboren demasiadas piezas defectuosas [36]. La interconectividad en el sistema, de esta forma, busca agilizar las respuestas ante cualquier evento no deseado, para tener un mayor control de los procesos.

Los principales componentes referentes a la industria 4.0, expuestos en la literatura, *son*: los sistemas ciber-físicos, internet de las cosas, computación en la nube, análisis de *big data* y la inteligencia artificial [37]. La figura 2 muestra algunos de estos componentes y los procesos en los que se integran a lo largo de la cadena de valor.

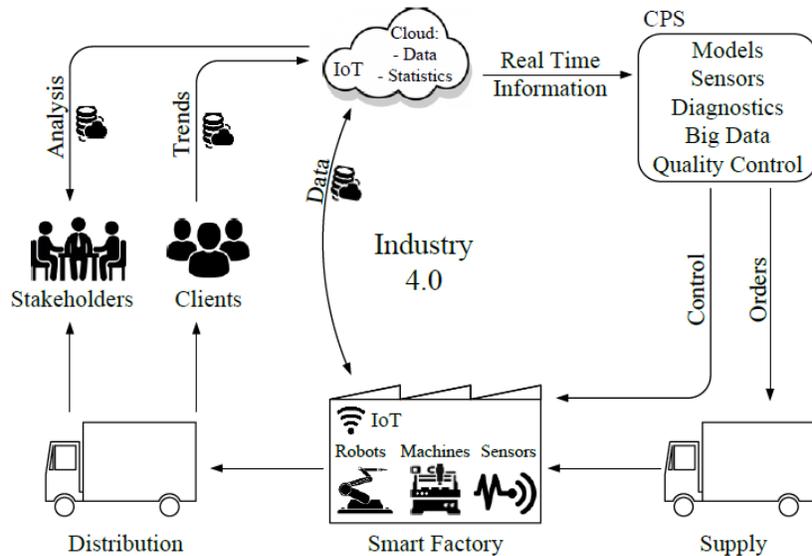


Figura 2. Diagrama que muestra los elementos que componen la industria 4.0 y su interacción [39].

Sistemas ciber-físicos. Su concepto está basado en la relación que se forma entre los procesos físicos y la computación, con el fin de aumentar la eficiencia de operaciones en la industria [36]. El vínculo formado es la base para la integración adecuada de las demás tecnologías inteligentes en los procesos, ya que facilita que estas herramientas monitoreen y controlen los procesos físicos [38], [39].

Internet de las cosas (IoT, por las siglas en inglés de *Internet of things*). Se trata de una herramienta que promueve la conexión entre dispositivos, personales o industriales, a través de internet, para ubicar y conocer el estado de cualquier objeto [36], [39]. Su objetivo radica en facilitar la interacción y comunicación entre elementos industriales, por medio de dispositivos móviles inalámbricos y sistemas de identificación electrónica, a través de los cuales se pueda intercambiar conocimientos, datos y procesos, sin importar su ubicación.

Big-data se refiere a una tecnología que permite el almacenamiento y análisis de un volumen enorme de datos, proveniente de diversas fuentes de la organización [17], [36]. Como se mencionó anteriormente, con la industria tradicional no era sencillo aprovechar todos los datos provenientes de la industria. En ella solo se manejaban ciertos datos de la cadena de producción, los cuales eran capturados de forma selectiva, de acuerdo con el nivel de importancia que le atribuían (por ejemplo, solo utilizaban algunos parámetros de operación, como la presión y temperatura). Gracias al uso del *big data* se ha posibilitado la gestión de una mayor cantidad y variedad de información, lo que ha provocado la recopilación, análisis y almacenaje de datos a velocidades superiores en comparación con las herramientas anteriores [16].

Cabe señalar que la información capturada actualmente puede ser complementada por datos de diferentes formatos (como las imágenes o videos) formados a lo largo del proceso, y el registro de estos valores también puede realizarse de forma continua, sin que el volumen de ellos afecte el sistema operativo. De este modo, es plausible transformar los datos disponibles

en la industria, en información útil (sin importar su tamaño, formato, origen o velocidad de formación), lo que facilita su uso y deriva en análisis del sistema productivo con mayor calidad [17].

Computación en la nube. Con esta tecnología se facilita la entrega de servicios informáticos (almacenamiento de datos, servidores, software, redes, etc.) mediante plataformas desarrolladas y localizadas en internet. Su uso busca agilizar los procesos de gestión de información, conocimiento y tecnologías no tangibles, volviéndolos más rápidos, accesibles y económicamente rentables [36].

Inteligencia artificial (IA). A pesar de que este término es manejado desde el siglo pasado, sus beneficios en la industria no han sido tan notorios como en las últimas décadas, debido al incremento de su poder de procesamiento y su integración en un número mayor de procesos industriales y de servicios [36], [37].

1.3.1 La Inteligencia artificial y la manufactura

Una de las tecnologías que más representa el paso de la industria 4.0 es la inteligencia artificial, la cual es definida como una ciencia cognitiva, perteneciente a la familia de las ciencias computacionales, cuyo objetivo es emular algunas facultades intelectuales humanas⁸ en sistemas artificiales [18], [19]. En la industria, la IA es considerada como una disciplina que busca que las tecnologías integradas en los procesos tengan la capacidad de aprender automáticamente sobre su entorno y su propio desarrollo y que, como consecuencia, aprovechen este conocimiento para decidir la mejor forma de alcanzar algún objetivo o para informar a otros componentes de la industria sobre alguna situación que necesite ser atendida. Con este fin se desarrollan, validan e implementan algoritmos que proporcionan aplicaciones sostenibles en las unidades que componen la organización [19], [40].

Aunque su aplicación en la industria es aún reciente, se estima que su uso facilitará a las industrias manufactureras a satisfacer la demanda creciente de los productos; a aumentar su competitividad, especializar sus procesos y productos ante el mercado, y, como consecuencia, disminuir el impacto negativo que tiene hacia el ambiente [38], [39]. Concretamente, se asegura que su integración permitirá la autonomía de los procesos, al permitir la toma de decisiones, en tiempo real, basadas en datos históricos, con una mínima participación humana [38].

Lee, J. et al. [18] exponen que la inteligencia artificial, para que pueda resolver o anticiparse a determinados problemas, debe contar con una gran capacidad analítica que le permita manejar toda la información disponible y que sus operaciones estén relacionadas con otras tecnologías como *big data*, computación en la nube o cibernética (las cuales funcionan como fuentes de información o plataformas que le ayudan a desarrollar sus actividades).

⁸ Estas facultades están relacionadas a diversos procesos de percepción sensorial y de reconocimiento de patrones [40].

Específicamente, la facultad de análisis de las IA está definida por su estructura algorítmica, la cual contiene una secuencia finita de instrucciones que especifican las actividades que debe cumplir. Esta estructura es complementada por: conocimiento específico de áreas, *domain knowledge*⁹, y trabajo a partir de evidencias¹⁰, los cuales le brindan a esta tecnología la capacidad de resolver problemas, por ejemplo, de forma heurística, mediante pruebas de ensayo y error [18], [19].

Aunque el término de inteligencia artificial es usado con mucha frecuencia, resulta oportuno mencionar que se reconocen diversos modelos de Inteligencia artificial, de los que se destacan el *Machine learning* (ML) y *Deep learning* (DL).

Aprendizaje automático

La IA basada en ML (por sus siglas en inglés de *Machine Learning*) trabaja con dispositivos que aprenden sin estar programados concretamente para este fin. Su funcionamiento lo determinan los algoritmos con los que está programado, los cuales le llevan a detectar patrones, aprender de los resultados obtenidos y, finalmente, hacer predicciones o clasificaciones [41]. Según el tipo de aprendizaje, ML se clasifica en tres clases:

- Aprendizaje de refuerzo. Su funcionamiento surge de la experiencia, es decir, de encontrar la mejor manera de resolver una tarea mediante prueba y error [19], [41].
- Aprendizaje supervisado. En esta estructura algorítmica se utilizan datos clasificados y organizados que le permiten a la IA aprender cómo hacer tareas futuras, mediante la asociación de patrones. Su funcionamiento requiere la intervención humana, quien le proporciona los elementos iniciales y de retroalimentación [41].
- Aprendizaje no supervisado. A diferencia del caso anterior, los algoritmos no contienen datos previamente etiquetados o clasificados, ya que su funcionamiento se enfoca en las similitudes que encuentra entre los datos y los patrones que forma con ellos [41].

Aprendizaje profundo

El aprendizaje profundo o *Deep Learning* (DL), de forma general, es un tipo de aprendizaje guiado y, además, un subconjunto del campo de Machine learning. La diferencia con este último recae en su nivel de procesamiento y su capacidad de aprendizaje, ya que el ML requiere una mayor intervención humana para entrenar y desarrollar sus funciones, mientras que el DL utiliza un modelo para evaluar datos y observar ejemplos e instrucciones para modificar dicho modelo cuando considere necesaria alguna mejora. Particularmente, DL es un término relacionado con el procesamiento automático de datos, por medio de estructuras

⁹ *Domain knowledge* o *domain knowhow* se refiere a la especialización y comprensión de eventos, con el fin de que la IA tenga la capacidad de percibir la magnitud de sus actividades, la relación entre su funcionamiento y de los demás componentes de la industria; y la importancia de los datos que maneja (como los parámetros de las máquinas). Con esta especialización se busca que la IA enfoque sus esfuerzos y conocimiento en la resolución de problemas, recopilación de datos pertinentes a sus tareas y en el análisis del comportamiento de las unidades que están relacionadas con ella [19], [40].

¹⁰ Las evidencias están relacionadas con el aprendizaje acumulativo, en donde la IA recopila patrones de datos históricos y los asocia con nuevos eventos [18].

lógicas organizadas en capas, las cuales evalúan y analizan escenarios con diferente grado de procesamiento y a través de tareas repetitivas, que facilitan el aprendizaje progresivo. En este tipo de aprendizaje se utiliza una gran cantidad de datos no clasificados, de las cuales se generan los patrones de comportamiento y ocurrencia [40], [41]

Sin importar el tipo de aprendizaje que se busque utilizar, el buen funcionamiento de la IA depende en gran medida de la estructura logarítmica con la que está compuesta. Dicha estructura puede estar elaborada por una de las siguientes técnicas¹¹:

Lógica difusa (LD). El objetivo de esta rama de IA es emular la lógica humana, a partir de la creación de sistemas, compuestos por estructuras de algoritmos capaces de modelar diferentes escenarios. Tales modelos están constituidos por reglas lingüísticas¹² que ajustan funciones y forman rangos de membresía, con una escala entre 0 y 1 (a diferencia la lógica booleana, en donde se trabaja específicamente con esos valores para decir si es verdadero o falso). El sistema formado utiliza un banco de conocimiento, establecido por expertos, para establecer una propuesta que describa mejor el entorno y facilite la toma de decisiones. El funcionamiento de la LD está basado en el uso de reglas de sentido común, referidas a cantidades indefinidas, para controlar o describir eventos. Estas reglas, por lo regular, surgen de expertos en distintas áreas, sin embargo, cuando no existen elementos que brinden las pautas de comportamiento, los sistemas adaptativos pueden desarrollar modelos de funcionamiento (crean sus propias reglas) por medio del aprendizaje proveniente de la observación de casos similares reales, resueltos por otras entidades [19].

Su operación está basada en tres etapas: Primero, se establece el nivel de incertidumbre metalingüístico de cada variable, se define el rango de pertenencia (entre 0 y 1) y se determina si los valores de las variables pertenecen a un conjunto difuso. En la segunda etapa se establecen reglas lingüísticas, o de inferencia, que delimitan el comportamiento del sistema, de acuerdo con los objetivos del usuario; con estas reglas se evalúan las variables para conocer su grado de pertenencia y, como consecuencia, la salida que está asociada al conjunto difuso resultante. En la última etapa se determina los valores óptimos de salida, al traducir el grado de pertenencia encontrado a un valor real; esta fase ocurre debido a que las reglas lingüísticas estructuradas le permiten al sistema interpretar las órdenes, tomar decisiones y realizar acciones [19], [40].

Redes neurales artificiales (RNA). Se trata de sistemas de mapeos no lineales que generan sistemas de decisiones y clasificaciones, a partir de conocimientos obtenidos de problemas ya resueltos. Es decir, que sus operaciones están basadas en la generalización de información que ha sido extraída de datos derivados de diferentes fuentes. Las RNA están relacionadas con los principios que integran el sistema nervioso humano, ya que su funcionamiento ocurre por el intercambio de información entre las unidades de procesamiento (denominadas neuronas), conectadas entre sí. Los procesadores o neuronas reciben una entrada y generan

¹¹ Existen más componentes de la ciencia de la IA, sin embargo, la lógica difusa, redes neurales artificiales y algoritmos genéticos son los más reconocidos y utilizados [40].

¹² Las variables lingüísticas adoptan valores con palabras que permiten describir el estado de un evento, mediante conjuntos difusos [40].

una salida, de acuerdo con la información que tienen disponible internamente o que reciben de otras neuronas [19].

El funcionamiento de cada neurona se basa en recibir datos de las demás unidades o de fuentes externas, procesar la información conseguida y generar una salida que transmite a las demás neuronas o al exterior del sistema. Aunque la estructura de las redes neuronales no tiene un modelo específico, se caracterizan por estar compuestas por capas ¹³que contienen diferentes neuronas. Una ventaja del uso de RNA es que sus elementos pueden trabajar de forma independiente, lo que permite aprender diferentes eventos simultáneamente, sin depender de los demás elementos. No obstante, la calidad de su funcionamiento resulta de procesos de entrenamiento que pueden ser largos y que necesitan una gran cantidad de datos [19], [41].

Algoritmos genéticos (AG). Esta técnica, de búsqueda iterativa, trabaja a través de la derivación de estrategias de optimización. Su operación está basada en los principios de la selección natural, en la cual las funciones que no aportan decisiones óptimas son reemplazadas por funciones capaces de hallar los mínimos o máximos deseados. Este tipo de método, aunque busca encontrar la función que optimiza mejor un problema, sus resultados pueden ser satisfactorios solo con encontrar el valor más cercano al deseado [19], [41].

Las operaciones que realizan los algoritmos genéticos se generan por la combinación de cadenas que forman la “prescripción genética total”, similar a la unión entre cromosomas en los organismos naturales. Estas cadenas están compuestas por características de diferentes variables y su unión da lugar a una estructura o paquete de cadenas que, al interactuar con otras similares, genera las funciones objetivo. Una vez que se ha llegado a una función satisfactoria, se reproduce y se mantiene como función base, hasta que es necesario conseguir una siguiente optimización [19].

La implementación de una u otra técnica de IA se debe realizar de acuerdo con las características de los eventos que se quieren analizar, su facilidad de uso y por el tiempo de implementación. Por ejemplo, los métodos de RNA y AG son más robustos y pueden generar las mismas soluciones que una lógica difusa, sin embargo, se necesita una gran cantidad de tiempo para entrenar y adaptar nuevas funciones. Además, estos métodos se aplican a problemas con muchas variables y gran flujo de información, lo que les permite adaptar las soluciones a los problemas y no a medir las variables, como se hace en la lógica difusa. Por otra parte, las RNA comúnmente se implementan cuando no existen modelos de aproximación o procesos iterativos, pues su entrenamiento se basa en la observación continua y la concentración de su atención en lo que se desea encontrar. También, se prefiere su uso

¹³ Las capas que se encuentran ubicadas en las entradas externas se consideran la primera capa (aunque generalmente no se les considera capas, porque en ella no se realizan procesamientos, solo transmiten la información a las siguientes capas de neuronas). La capa que contiene las neuronas relacionadas con las salidas se considera la última y, por último, las capas que se encuentran entre la primera y la última son denominadas capas ocultas [19].

cuando se trabaja con datos subjetivos, ya que otros métodos, como LD, requieren elementos cuantificables o datos que tengan una relación directa con alguna clasificación [19].

Lo anterior no pretende mostrar los métodos de IA como estructuras rígidas o que sus características no pueden ser mejoradas, ya que sus funciones, aunque no varían, pueden complementarse al integrar en su estructura otras técnicas [40].

1.3.2 Integración de IA en la industria

Una vez revisados los tipos de aprendizaje y las técnicas fundamentales de la inteligencia artificial, resulta oportuno presentar una de las guías sistemáticas que han sido reportadas para integrar esta tecnología en los procesos industriales. Lee, Davari, Singh y Pandhare presentaron una estructura de implementación llamada “*eco-system de IA industrial*”, figura 3, en donde exponen una secuencia de estrategias de análisis para desarrollar IA en una industria [18].

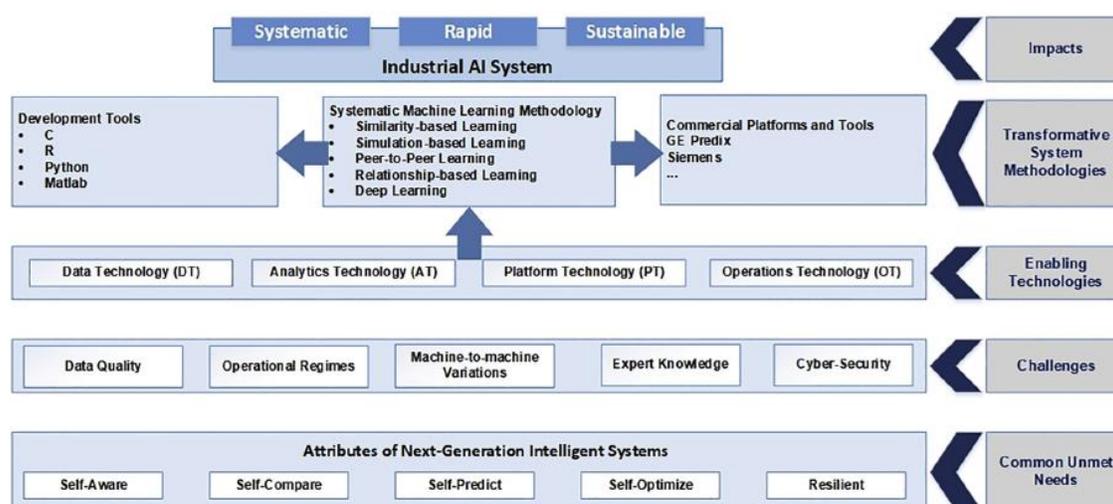


Figura 3. Estructura propuesta por Lee, J. [18] para desarrollar sistemas de IA en la industria.

En su estudio remarca que la implementación de IA puede cubrir diversas necesidades insatisfechas, como la auto predicción, auto optimización o la resiliencia. Además, señala los cuatro tipos de tecnologías habilitadoras a los que se puede recurrir para abordar estas necesidades. Estas tecnologías son:

- Tecnología de datos. Estas herramientas facilitan la generación y recopilación de datos útiles, con métricas de rendimiento significativas, provenientes de distintas máquinas del proceso o de la interacción entre ellas. También dan tratamiento a la información (revisan y corrigen el ruido que pueda existir en ella), la almacenan y comunican, desde su plataforma de operación a otras máquinas o la línea central de la planta de producción y después a la nube.
- Tecnología analítica. En ella se procesan los datos sensoriales de componentes críticos en información útil. Su objetivo radica en encontrar datos y correlacionar factores en

el proceso. Su aplicación se encuentra en el pronóstico de vida de productos, condiciones de máquinas, etc.

- Tecnología de plataforma. Se refiere al hardware o plataforma en donde se desarrollará el sistema inteligente. Su arquitectura determinará la facilidad con la que el sistema cumplirá con sus funciones y la complejidad de los eventos que podrá procesar. A través de este hardware se pretende almacenar, analizar y retroalimentar al sistema con los datos que se generan de los dispositivos con los que está interconectado. Lee comenta que hay tres tipos de configuraciones de plataforma: independiente, integrada y en la nube, esta última es la que puede proporcionar mejores características de implementación tecnológica.
- Tecnología de operaciones. Por medio de esta tecnología se pretende que los dispositivos se comuniquen entre ellos, decidan y actúen, a partir del análisis de la información recopilada. Además, se busca que las máquinas, ubicadas en la misma industria o de puntos geográficos diferentes, puedan colaborar entre sí, para conseguir los objetivos de la organización.

Lee considera la tecnología de operaciones es el punto culminante de la industria 4.0, ya que se espera que el sistema tenga autoconsciencia, auto predicción, autoconfiguración y autocomparación. Finalmente afirma que las expectativas que se tienen de la IA son altas, sin embargo, con que cumplan una parte de estos objetivos, ya representa un beneficio significativo y real de su incursión en la industria.

1.3.3 Calidad en la Industria 4.0

Así como los sistemas de producción han evolucionado con la cuarta revolución industrial; la calidad, al ser un concepto subjetivo cuya construcción se modifica conforme a los cambios del entorno, también precisa adaptarse a los cambios tecnológicos de la industria 4.0 y adoptar nuevas prácticas y sistemas de gestión. Lo anterior con el fin de concebir, conseguir y ofrecer productos con mejor nivel de calidad, al mismo tiempo que se incrementa la eficiencia operativa y sistemática de la industria [39], [42]. No obstante, esta serie de cambios se muestran como un desafío para los líderes de calidad de los entornos industriales actuales, ya que es imperativo que reaccionen oportunamente ante el dinamismo con el que operan las empresas del entorno; que involucren a sus procesos las nuevas tecnologías y que busquen constantemente la actualización de sus sistemas internos.

La denominada Calidad 4.0 pretende aprovechar todas las herramientas tecnológicas que las industrias inteligentes están adoptando, con el fin de reducir el costo total y el tiempo de entrega de las piezas producidas; e incrementar la competitividad y permanencia de la organización en el mercado. Su objetivo está enfocado principalmente en el cumplimiento e incremento de los valores específicos de producción y estándares de calidad de toda la cadena de producción [40], [42]

Con la industria 4.0 se han generado actividades que fortalecen la gestión de calidad en las organizaciones, como nuevas técnicas para asegurar la calidad de los productos, herramientas de inspección de productos y métodos de detección temprana de errores; así como sistemas

de producción que son autoadaptables (en donde el proceso ejecuta rediseños en tiempo real para satisfacer variaciones en la demanda, averías en máquinas o cambio de características por requisito de cliente) [17]. En ese sentido, se desea que el sistema de producción tenga flexibilidad, para amortiguar cambios de otras partes de la cadena, de acuerdo con los objetivos definidos por la empresa y los recursos disponibles; e interconectividad efectiva para comunicar y actuar, en tiempo real, ante cualquier evento que ocurra en los procesos. Esta interconectividad se necesita, no solo dentro de los elementos de la industria, sino también con los factores externos, como los proveedores y los clientes. De esta manera, se busca tener una mayor coordinación con estos personajes, facilitando su comunicación y mejorando los tiempos de respuesta [17], [36].

Oztemel expone las actividades más significativas de las industrias en donde se han aplicado tecnologías inteligentes, y que han ayudado mejorar los sistemas de calidad [43]. De estas actividades se pueden destacar:

- Generación de alertas por anomalías en procesos y detectar fallas.
- Predicción del comportamiento del proceso y sus componentes: máquinas, materia prima y recursos humanos, así como su posible rendimiento.
- Aviso de las actividades de mantenimiento para las máquinas y equipos de la cadena de producción, con el fin de garantizar la operabilidad de éstos durante su uso.
- Monitoreo y aseguramiento de la eficacia de la cadena de suministro, desde proveedores, hasta los clientes. Así como el estudio y la clasificación de las necesidades de los clientes.
- Optimización y manejo del inventario de la materia prima y equipo de trabajo. Además, gestión del personal operativo.
- Inspección de los productos.
- Establecimiento de sistemas inteligentes que optimicen los parámetros del proceso.

Con el fin de estudiar mejor las aplicaciones de tecnologías 4.0 en el área de calidad, se pueden ubicar las innovaciones en tres categorías, de acuerdo con el desarrollo de la cadena de producción:

A) Actividades que garantizan la calidad de los productos antes que comience el proceso productivo. En este punto se contemplan las especificaciones del proceso y productos, y la compatibilidad que existe entre ellos. De tal manera que las herramientas puedan alinearlos estos elementos de la mejor manera posible, o que puedan establecer especificaciones para mejorar la eficiencia de la organización [17], [18]. También se puede implementar en el diseño de experimentos, con el fin de conocer los parámetros críticos de los productos; en los estudios del mercado que traducen las expectativas del cliente y las tendencias en las especificaciones del producto; o en la evaluación de proveedores, con la que se comparan los productos que se adquieren, su comportamiento durante el proceso y los resultados que se tienen en los productos [18].

B) Durante la producción se puede recurrir a la tecnología inteligente para controlar los procesos. Los métodos más comunes están relacionados con las inspecciones visuales de los

productos y los procesos, como los clasificadores inteligentes de productos, controladores de parámetros en las máquinas o detectores de defectos. También se contempla la tecnología destinada al diagnóstico de fallas y monitoreo de la condición de las máquinas del proceso o de la eficiencia del personal. De esta forma se pretende tener, en tiempo real, un mayor control de todas las etapas del proceso, de sus resultados y sus componentes. Lo anterior a partir de la información histórica, análisis estadísticos, políticas de calidad y estándares (definidos en el apartado anterior), para monitorear las condiciones del proceso y anticiparse a posibles fallas, eliminando causas o amortiguando efectos negativos [17], [42].

La importancia de que la tecnología inteligente trabaje con datos en tiempo real recae en la supervisión de los procesos en todo momento. Un ejemplo de esto es la implementación de un control estadístico de proceso a partir de inteligencia artificial, el cual se efectúa de manera constante con información generada durante el proceso, y que permite monitorear el proceso, detectar anomalías y hacer diagnósticos de fallas. Este control se aplica también en los equipos para conocer posibles fallas y el nivel de deterioro de sus componentes, con el fin de tomar acciones oportunamente, sin afectar el desarrollo de los procesos [18].

Por otra parte, las características de los sensores destinados a la inspección de productos han sido cada vez más especializados, al mismo tiempo que ha aumentado la complejidad en las características de los artículos. Estas mejoras surgen de la necesidad de revisar minuciosamente un mayor número de productos, con muchas características para revisar. A pesar de que, tradicionalmente, las industrias cuentan inspecciones ejercidas mayormente por empleados, el incremento de producción, productos con más especificaciones que revisar y la dificultad de mantener constante las facultades de inspección por una persona, durante una jornada laboral, han orillado a las industrias a desarrollar herramientas tecnológicas que inspeccionen los productos de manera rápida y efectiva, utilizando información relacionada con las especificaciones del diseño, los objetivos de la empresa y las necesidades del cliente. Además, a estos dispositivos se les confiere la capacidad de tomar decisiones según el evento que se presente (si el sensor está destinado a la clasificación o detección de defectos) [18], [39].

C) Finalmente, cuando el producto ya está elaborado, se dispone de tecnología que acompañe al producto durante su almacenaje, distribución y entrega al cliente. En este punto se contempla la información disponible antes y durante la producción para prever el desempeño de los productos y, además, lo contrasta con la garantía que ofrece el producto a los clientes -con el fin de anticipar el cumplimiento de su diseño o desarrollar pautas para definir nuevas garantías- [18]. En este punto se toma en cuenta información externa a la producción, como la retroalimentación del cliente.

Por medio de un sistema que facilita la interacción con los consumidores se puede medir su nivel de satisfacción real ante los productos de la organización, los principales inconvenientes de uso o fallas en el cumplimiento de sus propósitos. Esta información permite, de manera directa, mejorar el diseño del proceso y producto, redefinir los estándares de calidad y evaluar los componentes de la organización (proveedores, procesos, máquinas y personal interno involucrado). Del mismo modo, mediante el análisis de los costos de calidad se puede

vislumbrar el desempeño y la eficiencia del sistema productivo y con ello, redefinir las estrategias para futuras producciones que permitan reducir dichos costos, al mismo tiempo que se mantiene o incrementa la calidad en la organización [39], [42].

En general, en una industria 4.0 se emplea un enfoque basado en conocimiento para operar y generar los sistemas de calidad. La información que utilizan los productos inteligentes va más allá de los datos tradicionales, ya que también se contemplan los conocimientos operativos y de calidad como herramientas de esta tecnología. Debido a lo anterior, se puede recurrir a la minería de datos para extraer el conocimiento que se necesita y entrenar la tecnología de inteligencia artificial y aprendizaje automático, con el fin de identificar y utilizar la información que apoye la calidad de la organización [43].

Oztemel propone que, para cumplir con los objetivos internos de la industria, las metas de calidad y los requerimientos del cliente, la industria inteligente debe operar considerando los siguientes lineamientos [43]:

- Reducir el trabajo implementado para la manufactura.
- Manejar información generada en tiempo real -considerando su recopilación, actualización y almacenaje-, además mantenerla disponible para su revisión y análisis, de tal modo que tenga las herramientas suficientes para decidir y actuar.
- Predecir el desarrollo de los procesos, considerando los objetivos de calidad, y monitorear las condiciones de los equipos de trabajo.
- Generar alertas, de manera oportuna, cuando los equipos no puedan decidir sobre el proceso.
- Evaluar proveedores, por medio del estudio y revisión de los recursos que suministran.
- Transportar la información disponible de los procesos a medios digitales, para facilitar su observación y manipulación.
- Mantener constantes los niveles de calidad y facilitar la adaptación a los cambios que se presenten en el diseño de los procesos.

Para cumplir estos puntos es necesario que se disponga de una estructura en el sistema tecnológico que garantice la confiabilidad operativa, es decir, que asegure que la herramienta tendrá la capacidad de realizar correctamente las funciones de su diseño, durante el tiempo definido; que se le podrán realizar actividades de mantenimiento y que su uso no afectará negativamente su entorno -equipo, instalaciones, personal o medio ambiente- [39], [43].

En general, se espera que los beneficios que se obtienen de la tecnología inteligente puedan reproducirse en cualquier tipo de industria. Para lograrlo, en la presente investigación, para definir una metodología de implementación tecnológica, se propuso inicialmente describir la industria donde se quiere implementar y después estudiar el estado actual de la tecnología en esta industria, para conocer sus características, la forma en que fue desarrollada y su funcionamiento. En el siguiente capítulo se presenta un análisis de la industria de inyección de plásticos, en donde se revisan los procesos más representativos y, con ello, se delimitan los retos principales (o fuentes de riesgo) que requieren su intervención para tener un mejor control.

Capítulo 2. La inyección de plásticos y sus principales retos

2.1 Resinas termoplásticas y su manufactura

Las resinas termoplásticas son los materiales principales que se ocupan en la industria de inyección. Su composición está formada por largas estructuras lineales o ramificadas, las cuales están unidas por fuerzas de Van der Waals, relativamente débiles. Cuando se les suministra calor a estos polímeros facilita su manipulación, ya que su estructura se vuelve más flexible por el debilitamiento de las fuerzas intermoleculares. Específicamente en el proceso de inyección, al operar con temperaturas elevadas, se transforma este plástico en una masa fundida y viscosa a la que, posteriormente, se le da una forma determinada cuando se introduce en un molde, donde este material se enfría y solidifica nuevamente [1], [44].

Las propiedades de los termoplásticos están determinadas fundamentalmente por el tamaño de la cadena de polímeros y las ramificaciones laterales en sus moléculas. Para una misma fórmula química se pueden encontrar diversos arreglos moleculares, los cuales otorgan también distintas características a los productos que deriven de ellos. Por ejemplo, las cadenas lineales del polietileno de alta densidad permiten empaquetar el polímero de mejor manera, lo que favorece que sus productos sean más resistentes mecánica y térmicamente. A diferencia de ellas, las moléculas de polietileno de baja densidad poseen ramas laterales más largas, lo cual dificulta un acomodo compacto del polímero y da lugar a piezas más flexibles. Los arreglos moleculares no solo influyen en las características del termoplástico que se produzca, también influye en las condiciones de operación. Retomando el caso del polietileno de alta y baja densidad, el cambio en su operabilidad se puede observar por sus diversas propiedades, ya que mientras la temperatura de fusión del polietileno de alta densidad puede ser mayor a los 125°C, para el material de baja densidad dicha temperatura no sobrepasa los 115°C [1], [44], [45].

2.2 Inyección de plástico

El moldeo por inyección es uno de los procesos más versátiles en la manufactura de productos termoplásticos. Su popularidad resulta de la diversidad y el alto nivel de complejidad que pueden tener los materiales fabricados por dicha industria [1]. Por ejemplo, se pueden producir desde productos pequeños, destinados a la industria de computación y con pesos cercanos a la fracción de gramo; hasta piezas de gran tamaño, con pesos mayores a los 100kg, requeridas por la industria automotriz o de construcción. En este sentido, la industria de inyección ha demostrado ser capaz de producir en masa, con alta precisión y en una sola operación cualquier pieza con características geométricas específicas [44].

Durante el proceso general de inyección, una cantidad delimitada del material termoplástico (en forma de pellets o polvo), pasa de una tolva de alimentación a un cilindro de calentamiento, en donde es fundido. Después, por medio de un pistón, el material se inyecta a las cavidades de un molde, en donde se enfría y solidifica, hasta que adquiere la

forma del producto específico. Finalmente, el molde se abre y expulsa el material terminado. Este ciclo se repite las veces necesarias hasta cumplir su objetivo de producción [44], [45], [46].

2.3 Proceso estándar de inyección de plásticos

El proceso industrial de inyección considera una serie de etapas que interactúan entre sí, de forma dinámica y precisa, para entregar al cliente una pieza plástica con propiedades específicas. En este documento se presentan dichas actividades, a partir de información obtenida en la literatura, con el objetivo de establecer adecuadamente un proceso estándar de inyección de plásticos.

A lo largo del proceso de inyección se involucran distintas áreas que tienen por objeto asegurar la calidad de los productos, a la vez que permiten un beneficio económico para la industria inyectora. A grosso modo, las condiciones normales de producción de la industria de inyección incluyen: a) la generación de órdenes de producción por parte del área de planeación, b) revisión de materia dentro del almacén de materia prima, c) gestión de los recursos necesarios para el proceso de inyección, d) adecuación de la máquina de inyección previo a su uso (pruebas de acondicionamiento), e) inyección de productos plásticos f) Inspección de los productos, g) acondicionamiento de la zona después de la producción (espacio de inyección, máquinas y moldes), h) resguardo de producto terminado; y finalmente, i) remisión de piezas a cliente, figura 4 [12].

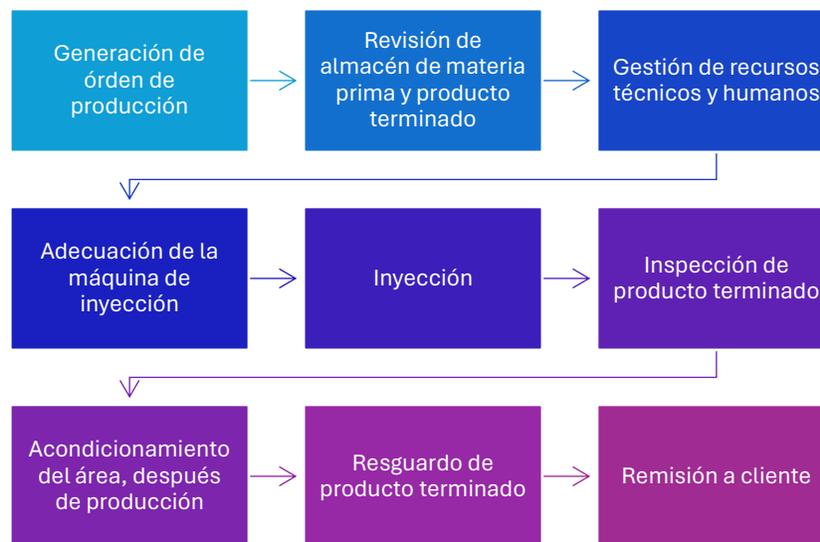


Figura 4. Diagrama de las etapas que se consideran en la inyección de plásticos.

Con el fin de tener una comprensión de las etapas de la cadena de valor, resulta conveniente dividir el sistema de fabricación en tres fases: antes, durante y después de la inyección [1], figura 5. De esta forma, antes de la inyección se referirá a las actividades de planificación y gestión de los recursos para conseguir una producción apropiada. La inyección estará relacionada con la generación de los productos, a nivel técnico y humano. Y finalmente, la

tercera etapa contemplará la disposición de los productos, su remisión y las actividades posteriores del área productiva.

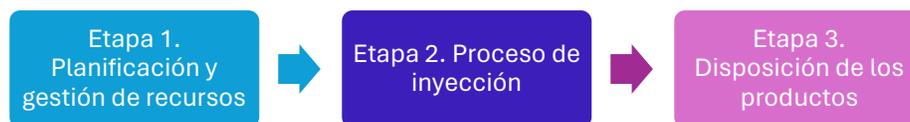


Figura 5. Representación simplificada del proceso de inyección.

Etapa 1. Antes de la inyección

Durante esta etapa se revisa la logística del proceso de inyección que se desea iniciar. Primero, se elaboran las órdenes de producción, a partir de la información que se tiene de los almacenes de materia prima y de producto terminado; también se considera el estado de los moldes y la capacidad operativa para completar los pedidos en el tiempo establecido. Después se especifica, en el plan de producción, el tipo de producto a inyectar, la cantidad de piezas necesarias para completar la orden y el tiempo en el que se debe cumplir con el pedido. Esta información es transmitida al control de producción para gestionar la materia prima, el equipo y personal que se necesitará para llevar a cabo el proceso de inyección y define tiempo que se destinará a esta actividad. Del mismo modo, se especifica si el producto inyectado debe ser ensamblado adicionalmente en procesos posteriores o si se puede disponer solamente de la unidad inyectada para su entrega al cliente [47].

Con base en la orden de fabricación se revisa el inventario actual de los almacenes de materia prima. Esta área se encarga de mantener en condiciones óptimas los materiales que resguarda, con el fin del conservarlos libres de contaminación y humedad para su uso. En los almacenes se tiene control de los distintos materiales poliméricos y pigmentos que alimentan las máquinas de inyección de plásticos y de otros componentes que son indispensables para realizar la inyección del producto¹⁴, además de diversos accesorios pertenecientes a operaciones secundarias, como etiquetas, películas plásticas termo adheribles o materiales que complementan los productos ya inyectados [48]. La información de la planificación se utiliza para solicitar materiales suficientes y adecuados, que permitan la producción de las piezas sin contratiempos, ya sea porque la materia prima sea equivocada o insuficiente.

En la zona de producción se gestiona el personal que llevará a cabo cada una de las actividades del proceso de inyección. Asimismo, se contempla si se cuenta con la preparación adecuada para realizar todas las tareas apropiadamente, como preparar el material de alimentación, operar y ajustar las máquinas, montar los moldes en las inyectoras, manipular los productos inyectados y embalarlos para sus posteriores etapas. Las personas involucradas deben estar en constante capacitación para conocer los nuevos productos, herramientas, y

¹⁴ Existen productos que se consiguen a partir del recubrimiento con plástico inyectado, de forma total o parcial, a una superficie ya elaborada. Por ejemplo, se pueden producir materiales de construcción compuestos en su interior por fibra de vidrio y cubiertos de polietileno de alta densidad. La combinación de estos materiales se hace con el objetivo de mejorar las propiedades mecánicas del producto.

máquinas que deben manipular, con el fin de que puedan trabajar con las mejores prácticas que les permitan cumplir sus labores de la mejor manera [47], [48].

Debido a que en las industrias de inyección se puede contar con una o varias máquinas de inyección (dedicadas a diferentes productos), para responder a una orden de producción es necesario identificar las unidades que deben ser utilizadas (como las inyectoras o moldes), y revisar su disponibilidad respecto a las actividades que puedan tener en ese momento. Del mismo modo, si se trata de productos que requieren ensamble con otras piezas inyectadas por la misma industria, se deben contemplar los elementos que necesita el producto para entregarse al cliente y la forma en que se deben programar para realizar su construcción [47].

Los moldes generalmente reciben un interés particular, debido a la delicadeza de sus acabados y sus componentes que, en un estado óptimo, permiten una inyección sin contratiempos. Por este motivo, su preparación y montaje son actividades que deben revisarse previo a la inyección, ya que repercute completamente en el rendimiento del proceso. En estas actividades se debe asegurar: que el molde sea el correcto y que esté en las mejores condiciones posibles para su uso; que la máquina donde se instale se acople adecuadamente a la unidad y que los operadores tengan la habilidad para instalarlo, ajustarle sus parámetros y, una vez en marcha la producción, de saber la forma en que deben operar en condiciones normales¹⁵ [10], [46].

El acondicionamiento de la materia prima se realiza considerando el producto establecido en la orden de fabricación. La importancia de este punto radica en que las características del producto se modifican de acuerdo con las formulaciones del polímero y pigmento utilizado en la inyección, así como de las condiciones en las que se encuentra (como el nivel de humedad). Por lo tanto, se debe asegurar que se utiliza el polímero y el pigmento adecuado, y que se alimenta la máquina con una mezcla homogénea de los elementos que componen el material de alimentación. Después de preparar dicho material, se introduce a la tolva de alimentación de la máquina inyectora, en donde generalmente se realiza una fase de precalentamiento, con el fin de eliminar la mayor cantidad de humedad posible.

Finalmente, antes de iniciar la etapa de inyección, los responsables del manejo de las máquinas de inyección ajustan y calibran los parámetros de estas unidades según el producto que se desea obtener. Una vez definidas las condiciones de operación se pueden realizar inyecciones de arranque, para verificar el funcionamiento del equipo y comprobar el buen funcionamiento del proceso [10].

Etapa 2. Durante la inyección

La fase de inyección se puede estudiar desde dos perspectivas: a través del funcionamiento de la máquina inyectora y mediante las actividades del personal a su cargo.

¹⁵ Normalmente, el producto inyectado se expulsa automáticamente del molde, por medio de sus botadores; sin embargo, en ocasiones se debe extraer la pieza manualmente de la máquina (por característica general de la inyección o porque la estructura de la pieza inyectada se traba dentro del molde).

El proceso de inyección en la máquina se lleva a cabo en cuatro etapas principales: inyección, sujeción, enfriamiento y eyección [49]. En la etapa de inyección se funden los pellets del polímero que fueron introducidos a la tolva de la inyectora. Dicha fundición se lleva a cabo en el cilindro de calentamiento, por medio de la fricción que tiene el material con el husillo interno y al calentamiento generado por calentadores eléctricos. Después, durante la sujeción se inyecta una cantidad específica de material fundido en el molde, que se mantiene cerrado hasta la última fase. El enfriamiento se desarrolla desde que el material ingresa en el molde y se completa cuando el molde se encuentra lleno y el material está solidificado en su totalidad. Finalmente, la pieza se eyecta del molde y da lugar el inicio de un nuevo ciclo de inyección¹⁶ [10], [49].

Por otra parte, también resulta importante observar el proceso desde el punto de vista del personal relacionado con esta operación. Los operarios responsables de las máquinas y de los productos¹⁷ se encargan de garantizar que las unidades de inyección mantengan estable su funcionamiento y que la calidad de los productos sea la apropiada, mediante la observación y el ajuste de los parámetros y componentes físicos de los equipos. Además, se aseguran constantemente de que la tolva de alimentación contiene material suficiente para continuar con el proceso. El personal, según la configuración y comportamiento de las máquinas, debe asegurarse que las piezas caigan o sean extraídas del molde apropiadamente¹⁸. Una vez que las piezas plásticas son expulsadas, los operadores revisan las características críticas de los productos con el fin de conocer su nivel de calidad. Si las propiedades cumplen con las especificaciones, el personal debe acondicionar el producto para que continúe con las siguientes etapas del proceso (si es necesario, se ensamblan con otros componentes para completar su estado final y se embala de acuerdo con las especificaciones acordadas con el cliente). Si el operador detecta algún defecto o no conformidad en el producto, debe seguir un protocolo de calidad para solucionar rápidamente la situación¹⁹ [49].

La etapa de inyección debe ser monitoreada continuamente, ya que de forma natural el proceso no permanece constante durante todo el proceso, debido a fluctuaciones en el ambiente, a la manipulación de las máquinas, por el comportamiento del material o de la misma máquina inyectora, etc. Mediante su monitoreo se busca garantizar que se cumplen los objetivos de producción y que las piezas plásticas salen con la calidad esperada [50].

Etapa 3. Después de la inyección

Una vez que las piezas de plástico fueron inyectadas, aprobadas y acondicionadas para su remisión, se envían a las zonas determinadas según la planeación de producción. Durante

¹⁶ El proceso de inyección se revisará con mayor profundidad en el subtema referente a la máquina de inyección.

¹⁷ Generalmente se destina una persona distinta para revisar el funcionamiento de las máquinas inyectoras y otra para el aseguramiento de los productos.

¹⁸ Algunos equipos, por su nivel de desempeño o por la estructura de las piezas que inyectan, no son capaces de expulsar completamente las piezas plásticas, por lo que los operadores deben extraerlas manualmente. No obstante, esta actividad conlleva una probabilidad alta de generar accidentes.

¹⁹ Esta decisión es basada en la criticidad del defecto y la política de la empresa. Se determina si se continúa la producción, mientras se ajustan los parámetros de la inyectora, o si es necesario detener el proceso, seleccionar y segregar los elementos que no cumplen con las características definidas.

esta etapa se contabilizan las piezas producidas y se compara este valor con la orden de producción inicial. También se reporta a los encargados de almacén, con el fin de controlar y resguardar el producto, antes enviarlo a su ubicación posterior. Si el producto es guardado en almacén o en un área delimitada para producto terminado, se debe garantizar la protección de sus propiedades, hasta que sean enviadas al cliente. Para ello, se pueden realizar inspecciones a los productos almacenados, a las zonas donde se resguarda y a los procedimientos de manejo que se utilizan dentro del almacén [49].

En el área de producción, una vez finalizada la corrida de fabricación, se dispone a desmontar el molde y asear el área de trabajo. Durante esta etapa, se observan las condiciones del molde y la máquina inyectora, y se determina el nivel de mantenimiento que debe tener cada uno (de ser necesario). El mantenimiento de estos elementos permite prevenir contratiempos en producciones posteriores por mala fabricación o por daños en las unidades mencionadas. Las personas involucradas en este ejercicio deben estar capacitadas para solucionar las especificaciones del mantenimiento, tratar con equipo delicado (considerando la criticidad de los componentes de los moldes) y no exponerse a situaciones que comprometan su integridad física, ya que los moldes o los componentes de las inyectoras, por su tamaño, pueden ser fuentes de accidentes. Una vez realizado esto, también deben hacerse pruebas que demuestren el cumplimiento del mantenimiento, con el fin de avalar su uso en las producciones siguientes.

Al remitir el producto, se coteja la información de envío con el material que se tiene realmente, con el fin de enviar el producto adecuado y la cantidad que solicita el cliente. Posterior a esto, se deben contemplar las características del transporte que entregará la producción al cliente para garantizar, hasta este último punto de gestión, que los productos conservan sus propiedades.

El departamento del control y aseguramiento de calidad, particularmente, se involucra a lo largo de todo el proceso de inyección. Durante su ejercicio no solo revisa y audita el cumplimiento de procedimientos y las buenas prácticas de manufactura; también inspecciona la materia prima, los productos obtenidos de la línea de inyección y los parámetros utilizados durante la producción, lo que deriva en la aprobación o rechazo de tales productos. Las personas involucradas en el control de calidad garantizan que el producto que se obtiene cumple con los estándares definidos y que la fabricación es realizada con las mejores prácticas posibles [30], [51].

La importancia de revisar brevemente el proceso de inyección radica en vislumbrar las diversas acciones que se relacionan con el desarrollo de un producto y los recursos técnicos y humanos que se necesitan para cumplir con los objetivos de la empresa. Una vez comprendidas las etapas del proceso, resulta conveniente estudiar el proceso de inyección y las máquinas inyectoras, y finalmente, indicar cuales son las problemáticas principales que surgen a lo largo del proceso de inyección.

2.4 Unidades de moldeo por inyección de plásticos

2.4.1 Componentes clave de una máquina de inyección

En general, las características de las máquinas inyectoras se pueden relacionar a los polímeros con los que se alimenta, la cantidad de materia prima que puede procesar, al tamaño de los moldes que usa, su fuerza de cierre, por su velocidad de inyección, etc. [52] Sin embargo, todos los equipos de inyección están compuestos por tres unidades básicas que se complementan entre sí: 1) la unidad de inyección donde se convierte el polímero en estado sólido en una masa fundida; 2) la sección del molde donde se forma el producto, y 3) el sistema de sujeción que mantiene el molde cerrado mientras se llena con el polímero fundido y que después permite su apertura para obtener el producto terminado [10], [45], [52]. En la figura 6 se muestra el esquema básico de una máquina de inyección.

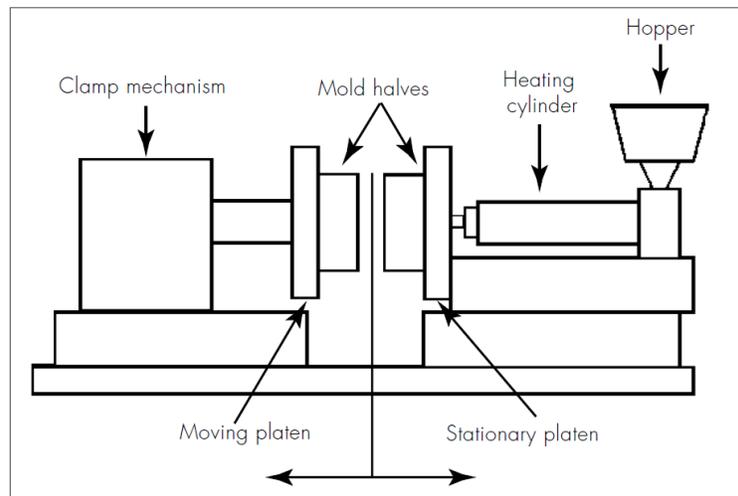


Figura 6. Esquema simplificado de una máquina de inyección por molde [10].

1) Unidad de inyección

La unidad de inyección está compuesta en primer lugar de: una tolva de alimentación, cilindro de calentamiento, tornillo de inyección, motor del tornillo, cilindros hidráulicos, válvulas de retención, bandas de calentamiento, boquilla de inyección, entre otros, figura 7. La clasificación de este segmento se realiza de acuerdo con el peso del polímero que puede contener el cilindro de calentamiento, considerando la regla del 50% de capacidad vaciada²⁰ [10], [44].

²⁰ Esta regla considera que, para el correcto funcionamiento del proceso, el tamaño del cilindro de calentamiento debe estar diseñado a fin de contener el material suficiente para dos ciclos de inyección. Es decir que, durante cada ciclo del proceso, sea posible vaciar el 50% del material total en el cilindro para introducirlo en el molde. Esta consideración se hace debido a las altas temperaturas que se manejan en el barril y con el fin de evitar el degradado de los materiales si se mantienen ahí por un largo periodo de tiempo. Aunque esta regla es ideal, se recomienda que el tamaño de este cilindro no sea inferior al 20% o superior al 80% de su capacidad de inyección [10].

Inicialmente, los polímeros son introducidos en la tolva de alimentación, donde generalmente son secados mediante calor y un flujo de aire seco. Después, desde la garganta de alimentación, los materiales son añadidos por gravedad a un cilindro de calentamiento o barril, donde se calienta el pellet o polvo hasta su fundición²¹. A lo largo del barril, el material que está derritiéndose se transporta por medio de un tornillo interno y finalmente, con la ayuda de pistón (implementado en el mismo tornillo) se impulsa y agrega al bebedero del molde, a través de una boquilla abierta. Este proceso se detiene parcialmente cuando la cavidad del molde es llenada por completo [42], [53].

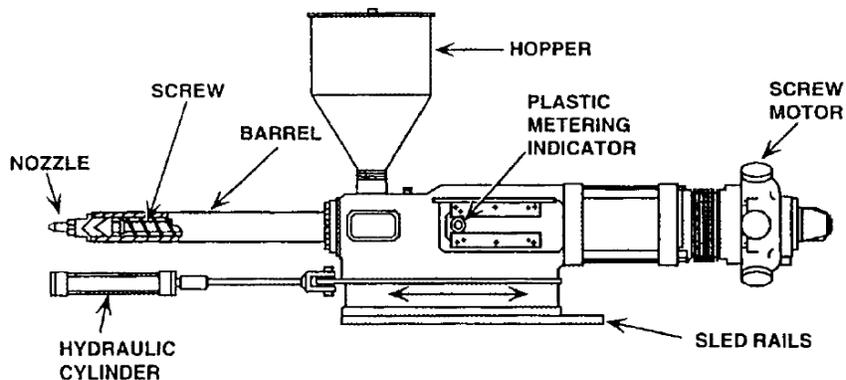


Figura 7. Unidad de inyección [53].

Tolva de alimentación

En esta sección se almacena el material antes de ser introducido al barril de calentamiento. La tolva cuenta, por lo general, con: a) una sección de pre-acondicionamiento para los materiales que necesitan un tratamiento previo a su fundición; b) un sistema de retención que dosifica la alimentación del polímero a la siguiente fase; y c) una garganta de alimentación, la cual funge como vínculo entre el cilindro de inyección y la tolva figura 8 [53].

El diseño de esta unidad depende del flujo másico del material que se procese, el tamaño de inyección de la pieza y el tiempo ciclo del proceso. Comúnmente la tolva presenta forma cónica en sus costados para facilitar la caída por gravedad del material fresco a la zona del barril. Además, en su interior generalmente se contempla la instalación de un imán (de cajón externo o suelto) que sea capaz de atrapar cualquier partícula de metal que esté suelta entre los pellets del polímero, como las limaduras provenientes de las cuchillas de los granuladores de plásticos [10], [53].

²¹ Comúnmente, la garganta de alimentación es enfriada con el fin de evitar que el material granulado se derrita en esta zona.

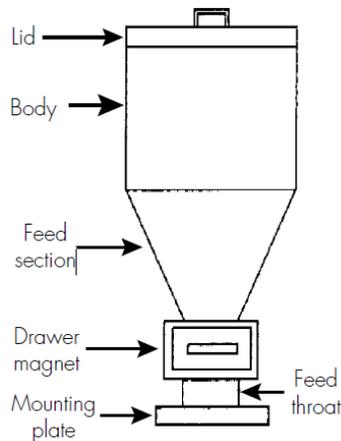


Figura 8. Tolva de alimentación básica [10].

Cilindro de calentamiento y tornillo

Después de pasar por la tolva de alimentación, el polímero ingresa al cilindro de calentamiento o barril. En éste, el flujo de los gránulos de plástico es impulsado por medio de un pistón hidráulico y un motor que hace girar el tornillo interno del barril, el cual permite fundir y transportar el plástico a través de esta zona, figura 9 [44], [53]. El diseño del cilindro de calentamiento debe asegurar que: 1) el polímero se mezcla adecuadamente en su interior, 2) el material fundido es capaz de fluir regularmente, sin tener fragmentos atrapados en las paredes o que puedan recircular; y 3) que el tiempo de residencia en esta sección no favorece la degradación del material [45].

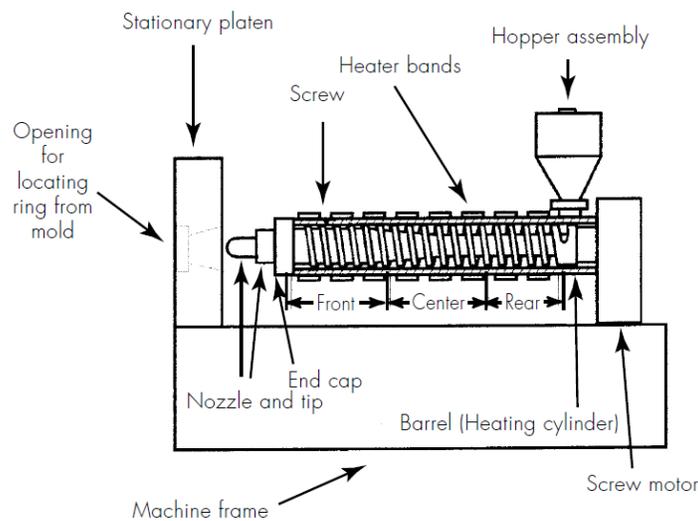


Figura 9. Cilindro de calentamiento [10].

El barril de calentamiento consiste en un cilindro largo, y de extremo abierto, que sirve como guía para el material fundido [53]. La superficie interna del barril genera fricción entre él y el plástico, lo que favorece la producción de calor para su fundición. A este calor se le puede adicionar la energía suministrada por bandas externas del cilindro, con el fin de mejorar el proceso de fundición. Estas bandas o revestimiento deben resistir a la abrasión y a la

corrosión, ya que algunos polímeros pueden desprender sustancias volátiles, que dañan la superficie del cilindro [44], [45].

A razón de que el cilindro alcance intervalos de temperatura que permitan la fundición del polímero, sin llegar a degradarlo, es necesario regular la temperatura a lo largo de su longitud. Para lograrlo, se puede modificar el flujo de energía eléctrica que pasa por las distintas secciones de las bandas de calentamiento, por medio de los termopares, de tal modo que se incremente o disminuya su temperatura [10]. Se recomienda que, al inicio del barril, la temperatura sea baja, para evitar el derretimiento prematuro de los gránulos, sin embargo, dicha variable debe aumentar conforme se avanza en la longitud de esta unidad para garantizar que no existen pellets sin fundir cuando se inyecta el polímero en las cavidades [53].

El desgaste del barril es uno de los principales problemas que se pueden encontrar en el proceso de inyección. Sus consecuencias, durante la inyección, se relacionan con la producción de piezas incompletas, debido a que el material fundido fluye de forma inversa dentro del barril, a través de las secciones desgastadas. Del mismo modo, puede provocar que se ralentice el proceso de inyección general, por la intermitencia producida en la etapa de retracción del tornillo, después de inyectar el material en el molde, ya que no se desarrolla la suficiente presión para retraer el tornillo de forma suave y uniforme [10], [44], [46].

A lo largo de la superficie del tornillo el material plástico se comprime, empaqueta y calienta debido a la fricción entre el polímero y la estructura irregular del dispositivo [44], [53]. El calor originado por tal fricción y el suministrado directamente desde el exterior del barril, por las placas de calentamiento, se complementan para fundir el plástico desde la primera mitad del cilindro de calentamiento. Particularmente, el calor proporcionado por el tornillo ayuda a reducir la cantidad de electricidad que requieren las bandas externas para calentar lo suficiente al polímero [10].

El tornillo está compuesto por una varilla con forma de barrena y se encuentra ubicado dentro del barril de calentamiento. Esta unidad se encarga de transportar, mezclar y homogeneizar el material fundido, a través de todo el cilindro, hasta llegar al molde. Además, cuenta con una válvula o punta de retención²² que impide fluir el plástico fundido hacia atrás (que el material regrese a la garganta de alimentación) [10], [53]. De esta forma, su configuración hace que la masa fundida solo pueda dirigirse hacia la boquilla abierta, que permanece localizada al otro extremo del tornillo y se mantiene en contacto directo con el molde [53].

Boquilla

La boquilla es el último dispositivo de la unidad de inyección. Su función es mantener la temperatura de fundición y guiar la masa plastificada hacia el bebedero del molde [1], [45]. Específicamente, la masa fundida del cilindro de calentamiento se inyecta desde la boquilla

²² Es posible sustituir la válvula de retención si se añade, al extremo del tornillo, una punta de frotis. El inconveniente de este tipo de materiales es que no restringen el flujo del plástico fundido. No obstante, su preferencia recae en su eficiencia para trabajar con materiales de alta viscosidad y sensibles al calor, como el PVC rígido [44].

Además de la válvula, en el tornillo se pueden agregar algunos anillos de control para evitar el reflujo en el cilindro [53].

al bebedero que alimenta un sistema de canales conectado a la cavidad a través de una compuerta (mediante un sistema de coladas que alimenta simultáneamente todas las cavidades con las que cuenta el molde) [10], [53].

El tamaño de la boquilla es pequeño y la forma de su punta es cónica, para evitar el sobrecalentamiento del material, cuando se incrementa el tiempo de residencia para la plastificación [10], [52]. Además, con el fin de tener una buena conexión entre el molde y el cilindro, dicha punta debe coincidir precisamente con la abertura del bebedero del molde, ya que de lo contrario el material puede quedar atrapado en el cilindro, lo que favorecería su degradación [53].

2) *Molde*

Los moldes de inyección dan la forma, tamaño y acabados al producto final. En ellos se distribuye y retiene el polímero fundido, hasta que se enfría y solidifica. Finalmente se expulsa como un producto terminado. El molde debe favorecer el flujo adecuado del fluido, con el fin de tener uniformidad en la pieza [52]. Además, las especificaciones de este componente deben permitir que pueda soportar la fuerza de sujeción, inyección y de expulsión, que ese ejerce en él, durante varios ciclos de operación [44], [52].

Básicamente, los moldes están conformados por cavidades y núcleos (en donde se localizan los sistemas de alimentación, eyección y de refrigeración); y por una base en donde se montan dichas cavidades y núcleos, figura 10 [44], [52]. La clasificación principal de este componente se realiza de acuerdo con el diseño final de la pieza y el número de cavidades que contiene²³, las cuales están relacionadas con el número de productos que puede producir en una sola inyección [1], [46]. En la tabla 2 se exponen los componentes básicos que integran los moldes y una breve descripción de la función que realizan.

²³ Otra forma de clasificar los moldes es a partir de sus sistemas de canales (canales fríos, aislados o calientes). Por ejemplo, en los moldes con canal frío, el bebedero y el canal se solidifica y provoca que las coladas sean expulsadas junto con la pieza final. Los canales calientes, a diferencia de los anteriores, mantienen siempre las coladas fundidas, lo cual ayuda a disminuir los desperdicios que sí se generan en el primer tipo de molde, no obstante, se dificulta la operación del sistema, ya que se debe equilibrar la solidificación en el interior del molde, con el escurrimiento que se puede presentar en las compuertas de alimentación [1].

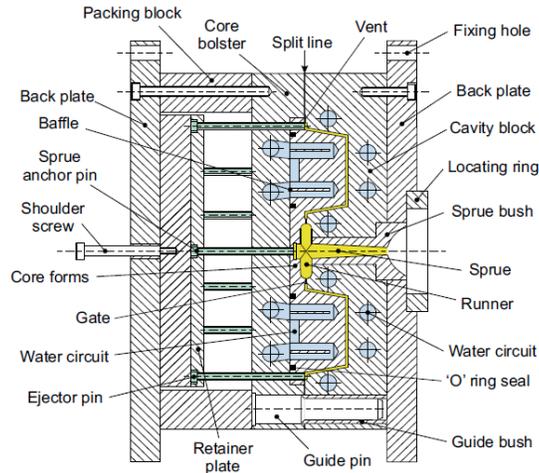


FIG. 4.41 Details of injection mould.

Figura 10. Estructura y composición de los moldes [1].

Tabla 2 Principales componentes y sus funciones de un molde para inyección de plásticos [52].

Componente del molde	Función
Base del molde	Sostener fijamente la(s) cavidad(es) en una posición determinada, con relación a la boquilla de la unidad de inyección.
Pines Guía	Mantener una alineación adecuada entre las placas del molde.
Casquillo del bebedero (bebedero)	Proporcionar los medios de entrada hacia el interior del molde.
Runners	Transportar el plástico fundido desde el bebedero hasta las cavidades.
Compuertas	Controlar el flujo del plástico en las cavidades.
Cavidades (hembra y macho)	Proporcionar el tamaño, forma y textura de la superficie del producto a fabricar.
Canales de agua - refrigerantes	Controlar la temperatura de las superficies del molde, con el fin de llevar el plástico a su solidificación.
Lados A y B (accionado por levas, engranajes o cilindros hidráulicos)	Forman orificios laterales, ranuras, muescas y secciones roscadas.
Ductos de ventilación	Permite la salida de aire atrapado o los gases formados.
Sistema de expulsión (eyectores, pasadores, cuchillas, placas separadoras)	Expulsar el artículo sólido de la cavidad.
Pines de retorno de eyección	Regresar los eyectores a la posición retraída, para el momento que se repita el ciclo y el molde se vuelva a cerrar.

La distribución de la masa plastificada, dentro del molde, se realiza desde los conductos del molde (bebederos, canales y compuertas), hacia las cavidades que dan forma a los productos²⁴ [52]. Estas cavidades, por lo general, se encuentran localizadas en el interior de

²⁴ En moldes de una sola cavidad, el bebedero introduce los polímeros fundidos directamente a la cavidad. En cambio, en los moldes de varias cavidades, el bebedero distribuye el plástico sobre un sistema de canales que conducen a las distintas cavidades del molde [52].

dos placas, de las cuales una es estacionaria y se encuentra ubicada en el lado donde se inyecta el plástico; y la otra es móvil y se localiza en el lado del cierre/expulsión de la máquina²⁵ [44], [52]. En la figura 11 se ilustra el proceso de cierre, apertura y expulsión del producto en el molde.

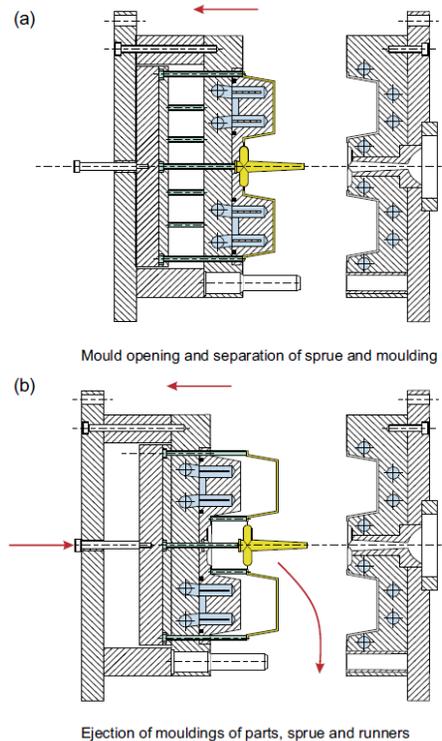


Figura 11. Apertura, cierre y expulsión de piezas en el molde [1].

Los sistemas de refrigeración que integran los moldes ayudan a disminuir el calor que recibe el molde por el polímero fundido²⁶. Comúnmente se utiliza agua para enfriar las piezas, cuyo flujo es controlado para que la pieza no se endurezca antes de llenar totalmente la(s) cavidad(es) [52], [54]. Existen otros materiales que alimentan los moldes en el proceso de inyección, por ejemplo, se puede implementar gas para elaborar piezas huecas, sin el uso de núcleos o corazones. Este núcleo hueco se produce al inyectar un gas inerte (generalmente nitrógeno) en la cavidad, que se encuentra parcialmente llena por el polímero [1], [54].

Debido a la delicadeza de esta sección, algunos autores recomiendan que se inspeccione visualmente el molde cada vez que se abre, para asegurar que: las piezas formadas se expulsan correctamente, los sistemas de refrigeración están bien conectados, no hay rebabas o restos de material en el molde, etc. De no hacerlo, mencionan que se podría afectar la

²⁵ La separación entre ambas placas se conoce como línea de separación.

En algunas ocasiones, los moldes pueden estar compuestos por tres placas y, por lo tanto, tener dos líneas de partición. Este tipo de moldes no es adecuado para todos los polímeros, ya que algunos materiales frágiles pueden fracturarse al ser expulsados [10].

²⁶ Cuando se trabaja con polímeros termoestables, en lugar de los sistemas de refrigeración, se utilizan calentadores eléctricos en el molde [52].

estructura y funcionamiento del molde y, al mismo tiempo, a la producción. Por ejemplo, si alguna pieza queda atorada en el interior del molde provocaría la fractura de alguno de los eyectores, núcleos u otros componentes frágiles, lo que representaría un gasto económico considerable para la empresa, debido a lo costosa que puede ser la reparación, y la interrupción de la producción [10], [52].

3) Sistema de sujeción

La función principal del sistema de sujeción es mantener los moldes fijamente cerrados, mientras se inyecta la masa fundida con alta presión, a fin de evitar fugas de plástico fundido en el molde. Igualmente, se encarga de abrir el molde, en un tiempo adecuado, para expulsar la pieza plástica sólida y de volver a cerrarla para iniciar otro ciclo de inyección [1], [45].

Básicamente, el molde se monta sobre las secciones, móvil y estacionaria, que conforman a la unidad de sujeción. Dichas unidades son capaces de guiar las placas del molde, para abrirlo o cerrarlo, por medio de cuatro barras de unión. La parte móvil se fija en una posición que permite la alineación correcta entre el bebedero del molde y la boquilla de la unidad de calentamiento. El segmento móvil asegura la otra mitad del molde y se encarga de cambiar la posición de esta unidad y de controlar la velocidad de los movimientos que realiza para cerrar o abrir el molde (dando el espacio necesario para sellar el molde y para que se expulse la pieza sin dificultad) [44], [52].

Las unidades de sujeción se pueden clasificar de acuerdo con la fuerza máxima que la máquina es capaz de producir. Además, estos sistemas pueden estar compuestos de sistemas hidráulicos, mecánicos, hidromecánicos, eléctricos o alguna combinación entre ellos [1], [53]. Usualmente estos sistemas de sujeción cuentan con un dispositivo tipo palanca²⁷ que se usa para amplificar la fuerza que existe en la unidad [1].

La fuerza de sujeción es la característica más importante de estas unidades, ya que permite mantener cerrado el molde durante la inyección, sin dañarlo. La magnitud de esta fuerza depende especialmente de la presión de inyección que la unidad de calentamiento ejerce para inyectar el plástico fundido [10]. Una de las consecuencias de no establecer una fuerza de sujeción adecuada, es que puede producir fuga del polímero sobre la línea de separación del molde. En este caso, donde la fuerza es baja, la presión de inyección obliga a salir al plástico a través de cualquier abertura que encuentre a su paso (incluso se puede originar un orificio al abrir ligeramente el molde debido a esta presión). Dicha fuga puede dar lugar a rebabas, las cuales necesitan una operación secundaria para eliminarla (lo que incrementa el costo de la producción). En el caso contrario, cuando la fuerza de sujeción es excesiva, puede provocar daños en el molde, lo que resulta inconveniente por el costo elevado de reparación que necesitan los moldes, en el caso que sea posible repararlo [10], [53].

²⁷ Los sistemas con palanca se utilizan especialmente en máquinas que trabajan con alta velocidad y fuerza de sujeción relativamente pequeña. Una ventaja de usar este tipo de palancas es que no es necesario mantener la presión hidráulica durante todo el ciclo de moldeo. Sin embargo, al utilizarla pueden aumentar los costos de mantenimiento [1].

Por lo regular, las máquinas de inyección pueden dividirse en tres clases según su modo de operación: manual, semiautomático (ciclo único) y automático (continuo) [45]. Estas formas de control abarcan todo el ciclo del moldeo: la alimentación del cilindro, inyección, empaque, apertura y cierre del molde; y la expulsión de la pieza terminada. La diferencia entre una y otra deriva en el nivel de intervención del personal en la operación. Mientras en el sistema manual, cada paso del proceso de inyección es activado por el operador; las unidades automáticas realizan un ciclo continuo, hasta el momento en que se abre la puerta o se activa alguna protección de la máquina. Sin importar el tipo de control que se utilice, los parámetros del proceso pueden afectar directamente el desempeño del proceso y la calidad de los productos que realizan [45], [52]. Debido a lo anterior, resulta imperante revisar las variables que más influyen en el desarrollo de la inyección y los defectos que pueden ocurrir si no se ajustan de forma correcta.

2.4.2 Parámetros en las unidades de inyección

A pesar de que la calidad de la materia prima y los insumos que se utilizan repercuten en la producción de plásticos, las condiciones que se aplican en el proceso juegan un papel significativo en la calidad de las piezas elaboradas y en la optimización de los procesos [55]. De acuerdo con la literatura, intervienen hasta más de 100 parámetros en el proceso de inyección de plásticos [10]. Sin embargo, distintos autores han reportado que solo algunos de ellos tienen un mayor impacto en la elaboración de productos con alto grado de calidad [21]. Debido a esto, resulta importante conocer los principales parámetros que se utilizan en la inyección y, además, revisar cuáles son los defectos que pueden ocurrir en los productos si no se tiene un control adecuado de ellos. Los siguientes ejemplos se tomaron como base para delimitar las variables más significativas en las máquinas de inyección por moldeo:

Dang, en 2014, desarrolló un modelo de optimización que demostró ofrecer valores positivos en los procesos. En su investigación revisó dos casos de inyección de plásticos y dos métodos de optimización, uno numérico directo y otro basado en metamodelos. En su investigación encontró a la temperatura del molde y la de fusión; el tiempo de llenado (relacionado con la velocidad de inyección), tiempo de empaque y presión de empaque como las condiciones más importantes que se operan en las unidades de inyección y, por lo tanto, deben contemplarse si se quiere realizar alguna optimización [55].

En el trabajo de investigación realizado por Ozcelik et al., se encontró que la temperatura de fusión y la presión de inyección influyen en las propiedades mecánicas de plásticos inyectados de material ABS²⁸. En este estudio, a partir de un análisis con el arreglo ortogonal de Taguchi y el análisis de varianza (ANOVA), se determinó que la presión de empaque, tiempo de enfriamiento, tiempo de llenado, temperatura de fusión y del molde; y la presión de inyección son las condiciones más importantes del proceso [21]. Similar a este estudio, Juanes-Márquez y colaboradores, para desarrollar un simulador de inyección de plásticos, consideraron como parámetros a la temperatura de fundición y del molde; tiempo de

²⁸ El término ABS es una abreviación del polímero compuesto por Acrilonitrilo-butadieno-estireno.

inyección, de refrigeración y de mantenimiento de presión; volumen de inyección y presión de inyección. Dicha consideración fue realizada a partir de información bibliográfica y con la asesoría de especialistas en la materia [56].

Rrzurumlu y Ozcelik, por medio del método de optimización de Taguchi, consideraron la temperatura del molde y de fusión; y la presión de empaque como los parámetros del proceso que intervienen principalmente en la minimización del índice de deformación y hundimiento en piezas de plástico [57]. Por otra parte, Farshi et al. realizaron un estudio acerca de los parámetros que influyen en la deformación y contracción de los productos obtenidos en el proceso de inyección. Por medio de un software especializado y del método secuencial simple, probaron la influencia de la temperatura del molde, de fusión y del refrigerante; presión de empaque y retención; tiempo de empaque y tiempo ciclo como las condiciones más significativas en la aparición de tales defectos en los productos finales [58].

En la investigación hecha por Kurt et al. se determinó que la presión de las cavidades y la temperatura del molde son los parámetros más importantes en el moldeo por inyección de plástico, ya que influyen especialmente en la calidad de los productos [59]. Zhao, Zhou y Li propusieron un algoritmo de optimización para optimizar los parámetros del proceso de inyección de manera efectiva. En su trabajo consideraron la temperatura de inyección y del molde; y el tiempo de inyección como los parámetros que influyen directamente en la calidad y el costo de los productos [60]. Bociaga, por su parte, reportó que la temperatura en la boquilla, de fusión y del molde; la presión de inyección; velocidad de inyección; tiempo ciclo y el tiempo de enfriamiento son los factores más determinantes en la calidad de los productos inyectados, en el nivel de productividad y en la energía consumida durante el proceso [61]. Jansen et al., realizaron un estudio sobre las condiciones que dan lugar a la contracción de siete tipos de polímeros termoplásticos (policarbonato, poliestireno, ABS, HIPS²⁹, PBT, PBT-GF30³⁰ y HDPE³¹). En sus conclusiones señalaron que los factores más significativos en la inyección de estos materiales son la presión de empaque, temperatura de fusión y, en menor medida, la velocidad de inyección y temperatura del molde (aunque sí influyen en el proceso, no lo hacen en la misma magnitud que los primeros) [62].

Liu, Lin y Wu realizaron un estudio para minimizar las marcas de hundimiento que surgen en los productos derivados del proceso de inyección para los materiales termoplásticos. En su estudio trabajaron con poliestireno y polietileno de baja densidad y probaron los efectos de la geometría de la pieza y el molde. Además, se consideraron la presión de empaque y de llenado; la temperatura del molde y de fundición como los parámetros más influyentes en este proceso [63]. En el artículo de Wan, Mao, Jiang y Chen, se analizaron los efectos de algunos parámetros de inyección en las propiedades de un producto de polipropileno. En dicho estudio se consideró a la temperatura del barril, presión de inyección, velocidad de

²⁹ Abreviatura para el poliestireno resistente al impacto.

³⁰ Abreviatura para el polímero tereftalato de polibutileno. El PBT-GF30 hace referencia al PBT reforzado con 30% de fibra de vidrio.

³¹ Abreviatura del polietileno de alta densidad.

inyección y tiempo de empaque como las condiciones más importantes que determinan una buena inyección de plásticos [64].

Finalmente, Pratap, B., et al., en su artículo *Plastic injection molding and its process parameters* [65], exponen los parámetros que más se han estudiado, desde 2010, para su optimización y los factores que se mejoraron como resultado. Las variables que se destacan en esta publicación son: Temperatura de molde, fundición, inyección y enfriamiento; presión de sujeción, inyección y de empaque; tiempo de inyección, retención, enfriamiento, empaque y de llenado; el tiempo ciclo, el número de cavidades, tamaño de compuerta y, finalmente, la velocidad de inyección. También en su estudio señalan que es imperativo tener un control robusto de estas variables, ya que están directamente relacionadas con las propiedades mecánicas y otras características de los productos plásticos, como el nivel de empaquetamiento del polímero (o espacio de aire entre tramas), la precisión dimensional, el nivel de encogimiento y de deformación, etc.

A partir de los ejemplos anteriores, se determinan las siguientes condiciones como las más significativas en el proceso de inyección de plásticos.

Temperatura de molde	Tiempo de enfriamiento – refrigeración
Temperatura de fusión	Flujo de material
Volumen de inyección	Presión de inyección – llenado de cavidades
Velocidad de inyección	Presión de empaque – mantenimiento
Tiempo de inyección – llenado	Contrapresión
Tiempo ciclo	Presión de sujeción
Tiempo de retención – mantenimiento	

Temperatura de fundición

La temperatura de fundición considera la temperatura que se debe tener para mantener el material fundido a lo largo de todo su recorrido por la unidad de inyección. La temperatura de fundición depende del material con el que se trabaja y es medido en la boquilla del barril, antes de salir de esta unidad. Particularmente, una forma de conservar este parámetro es por medio de mantas aislantes, la cual es ajustada alrededor del cilindro de calentamiento (sobre las bandas calentadoras), y se usa para evitar que se “pierda” calor en los alrededores [10], [52]. Los principales factores que afectan dicha temperatura son: el tiempo que el polímero permanece en el barril, el área de calentamiento de la superficie interna del cilindro y la temperatura en la zona del tornillo; la conductividad térmica del cilindro, el tornillo y el plástico; y la diferencia de temperatura entre el cilindro y la masa fundida [52].

La energía para fundir el plástico debe considerarse a lo largo de toda la unidad de inyección y también debe controlarse, principalmente, por los calentadores eléctricos que están localizados en la parte delantera, central y trasera del exterior del barril³² [10], [53]. De esta forma, se contempla que la temperatura debe conservarse desde que el plástico es alimentado

³² A este calor también se le agrega el generado por la fricción con el tornillo interno de la unidad de calentamiento y que es absorbida por el polímero [1].

al barril de calentamiento, su paso por el cilindro, su salida a través de la boquilla hacia el molde y el sistema de canales que los compone; hasta su llenado en las cavidades [10], [47].

Esta temperatura debe mantenerse durante el proceso, con el fin de no degradar el polímero y evitar una solidificación anticipada. Al inicio del barril, el calentamiento del material debe ser gradual para ablandarlo. Después, continua el incremento de la temperatura durante su recorrido por el barril hasta llegar a la boquilla, que inyectará el material en el molde (zona más caliente del cilindro). La magnitud de este parámetro debe mantenerse constante hasta terminar el llenado del molde y antes que ocurra la solidificación del plástico en las cavidades [10], [42]. Para tener un mayor control de esta temperatura y menos gasto energético, se debe maximizar la fricción del material con el cilindro, disminuir el calentamiento de las bandas, y utilizar las mantas para aprovechar el calor del sistema [52].

Temperatura de molde

Este parámetro considera la temperatura del material fundido desde que pasa de la boquilla del barril al molde y justo antes de que el material empiece a enfriarse. La velocidad con que el molde recibe el calor del material determina qué tan lejos puede fluir el plástico antes de que éste inicie su solidificación y deje de moverse. Similar al parámetro anterior, la temperatura del molde depende del polímero que se inyecta: su temperatura de fundición, su velocidad de enfriamiento y su temperatura de solidificación [10].

Con el fin mantener fundido el material el tiempo necesario para que se llenen las cavidades en su totalidad y que el enfriamiento en la pieza final se haga lo más homogéneo posible, es necesario regular esta temperatura durante todo su paso por el molde [1], [10]. La forma más común de controlar este parámetro es utilizando un sistema de enfriamiento que, generalmente, está basado en la circulación de agua (a una temperatura constante) a través de esta unidad. Dicho sistema refrigerante extrae constantemente, por conducción, el calor de la masa fundida dentro del molde, para que la temperatura del molde no se incremente con cada ciclo de producción [44], [45]. Este parámetro se mide directamente desde la superficie del molde, por medio de un pirómetro tipo sonda, y promediando los valores registrados en distintos puntos del dispositivo [1], [10].

La capacidad de enfriamiento del material en el molde influye directamente en el tiempo ciclo del proceso y en las características de la pieza, como el acabado, el nivel de distorsión y contracción; y las tensiones internas del producto. Generalmente, las altas temperaturas del molde permiten mejorar el brillo de la superficie y tienden a eliminar los vacíos que se presentan durante el llenado de las cavidades. No obstante, el exceso de calor distribuido en el molde incrementa la posibilidad de producir marcas de hundimiento, o rechupes, en las piezas finales, figura 12. En contraste, si se trabaja con temperaturas bajas se puede presentar el defecto de “congelamiento” del material en la cavidad, antes de llenarla completamente. Aunque es un punto crucial en la industria de inyección, el control de la temperatura del molde está basado en la experiencia de quien lo supervisa, del tipo de material que se inyecta, la complejidad del molde, entre otros [1].



Figura 12. Pieza plástica con defecto de rechufe [66].

Flujo de material

Durante el proceso de inyección se espera que el flujo de material fundido llene de manera homogénea las cavidades de molde, sin que se solidifique antes de que ingrese todo el material. No obstante, en la realidad, el material ya comienza a enfriarse desde que ingresa en el molde [44], [54]. En este proceso el polímero ingresa de forma progresiva en el molde, lo que provoca que el material, conforme entra en esta unidad, desplace el plástico que ingresó al inicio de la inyección. El inconveniente de esto es que dicho material se encuentra más rígido porque ha comenzado con el proceso de endurecimiento y encogimiento [52]. Es imperante controlar el flujo del material que entra en el molde y su proceso de enfriamiento, con el fin de homogeneizar el llenado y generar piezas con una buena estructura.

Aunque el tiempo de llenado de la cavidad es de algunos segundos, el cambio dinámico de la temperatura, en el polímero fundido, no es uniforme durante el llenado de las cavidades. Cuando no es controlado el flujo de entrada del plástico en el molde o se trabaja con moldes demasiado fríos, se pueden producir líneas de flujo o líneas de soldadura en el producto, figura 13. Este defecto ocurre por la solidificación en tiempos parcialmente distintos para una misma inyección. Del mismo modo, la falta de control del flujo del polímero puede provocar que las esquinas o las estructuras con mayor detalle de los productos no se llenen completamente³³ [54].

³³ Un método para mejorar el llenado de las cavidades es por medio de ventilaciones en la cavidad o pasajes mecanizados en una o más ubicaciones a lo largo de la línea de separación [54].

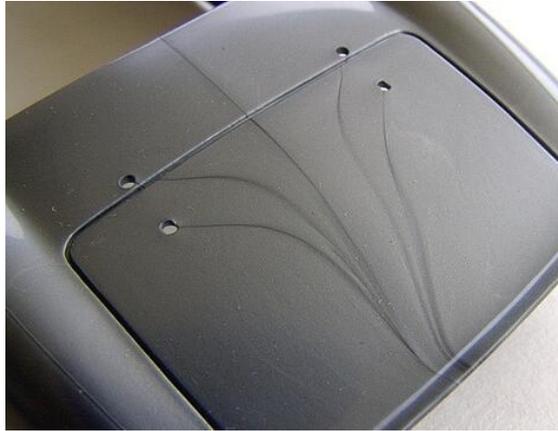


Figura 13. Ejemplo de líneas de flujo en un producto plástico [67].

Presión de inyección

Según la literatura, la presión de inyección se puede dividir en tres tipos: presión inicial, presión de mantenimiento y la contrapresión [10].

La presión de inyección inicial se refiere a la presión que se aplica al plástico fundido en el barril de calentamiento. Esta condición surge del sistema hidráulico que empuja el polímero hacia el otro extremo del cilindro (con ayuda del tornillo). Su magnitud puede ser cercana a las 2000 psi, sin embargo, puede aumentar hasta 5000 – 15000 psi en la boquilla de la unidad de inyección³⁴. La cantidad de presión requerida depende del tipo de boquilla que se utiliza, la viscosidad y fluidez del polímero; de las dimensiones de la pieza, el sistema de canales que existe entre las cavidades y las temperaturas a las que se encuentra el polímero y el molde [10], [44].

Idealmente se busca trabajar con presiones iniciales altas, ya que así, el proceso se llevaría a cabo en periodos cortos de tiempo³⁵, lo que provocaría menores tiempos de producción y un llenado de molde más eficiente (pues se evitaría que el plástico se solidifique de manera irregular en las cavidades) [44], [52]. Sin embargo, se debe considerar que trabajar con presiones elevadas implica una mayor tensión ejercida hacia el molde. Debido a esto es necesario hacer un equilibrio entre la cantidad de presión y el tiempo máximo en el que se podría inyectar el polímero [10].

La presión de mantenimiento. Si bien esta variable también está implicada en la inyección del polímero en el molde, la presión de mantenimiento considera concretamente la fuerza ejercida al final de la inyección inicial, la cual tiene por objetivo completar el llenado final del molde y mantener la presión contra el plástico que se inyectó previamente, para que permanezca denso y empaquetado. Este parámetro puede figurar la mitad de la magnitud anterior, o incluso menos. Si se trabaja con presiones elevadas se puede forzar la apertura parcial del molde y, con ello, provocar su deterioro; por el contrario, cuando la presión es ínfima, el material tiene dificultad para llenar las cavidades, lo que deriva en la obtención de

³⁴ Se ha reportado que este valor puede llegar hasta 20 000 psi. [10]

³⁵ El llenado en el molde puede realizarse en menos de tres segundos [10].

piezas incompletas [15], [46]. Una vez llenado el molde, la presión dentro de las cavidades se mantiene uniforme, respecto a la magnitud de la presión de mantenimiento [45].

Contrapresión. Este parámetro se observa cuando se completa la presión de mantenimiento. En ese momento se envía una señal a la máquina para que gire el tornillo nuevamente en el cilindro de calentamiento y de lugar a un nuevo ciclo. La contrapresión consiste en la presión ejercida hacia el lado opuesto del tornillo, durante la preparación de un disparo nuevo. Esta presión ayuda a obtener una mezcla más homogénea entre el material que ingresa al barril y el polímero que ya se encuentra dentro.³⁶ Su control, de esta forma, puede mejorar la fusión del polímero, la dispersión del color, la calidad, y la velocidad de salida [10], [52].

La contrapresión normalmente tiene la menor magnitud de las tres que componen la presión de inyección, sin embargo, su uso ayuda a garantizar la consistencia entre el peso, la densidad y la apariencia del material, ya que ayudan a que se regule la cantidad de material inyectado, y eliminar el aire atrapado y la humedad que aún puede retener la materia prima [10], [53]. Si esta presión es baja no permite tener una buena lectura de las otras presiones en el sistema, dando registros incorrectos de presión y, por consiguiente, configuraciones defectuosas en el sistema. En el caso opuesto, contrapresiones elevadas dan lugar a la degradación del plástico debido a la retención excesiva del material en el barril [10], [52].

Presión de sujeción del molde

A pesar de que la literatura sugiere que la presión de sujeción sobre el área proyectada de la moldura se encuentra entre 10 y 50 MPa, para configurar este valor se deben considerar otros factores, como la geometría y tamaño de la pieza, el grosor del molde y el tipo de polímero que se utilice durante el proceso [1], [10], [45]. Cuando el material es muy rígido o viscoso se requiere una mayor presión de inyección y, por lo tanto, una fuerza mayor de sujeción para mantener el molde cerrado y así evitar que se separen las placas del molde. A diferencia de estos, al tratar con polímeros más fluidos, la presión de inyección es menor y, del mismo modo, el de la sujeción del molde [45].

Los efectos de este parámetro se pueden observar en la calidad de los productos y en el mantenimiento de los moldes. Por ejemplo, el defecto “flash”³⁷ en las piezas inyectadas, figura 14, se ha observado que ocurre principalmente por un mal cierre entre ambas partes del molde, lo que provoca que el plástico fundido fluya fuera de la cavidad, sobre la línea de partición³⁸ [1], [52], [53]. Para solucionarlo se recomienda probar la fuerza que se utilizará a lo largo del proceso y verificar que se tiene la fuerza suficiente para mantener sellado el molde. Contrario a este caso, cuando se tiene un exceso de presión en la sujeción del molde

³⁶ Si bien este parámetro ayuda a la fundición del polímero, no debe considerarse como la única variable (o la más importante) en esa etapa [52].

³⁷ También es conocida como rebaba y se caracteriza por ser material en exceso que se proyecta sobre los bordes, o límites, de la pieza inyectada [1].

³⁸ En la aparición de este defecto también influyen la temperatura de fusión, cantidad de material inyectado o desgaste del mismo molde.

se puede tener consecuencias críticas en la estructura del molde, ya que se puede llegar a dañar su superficie y componentes [1].

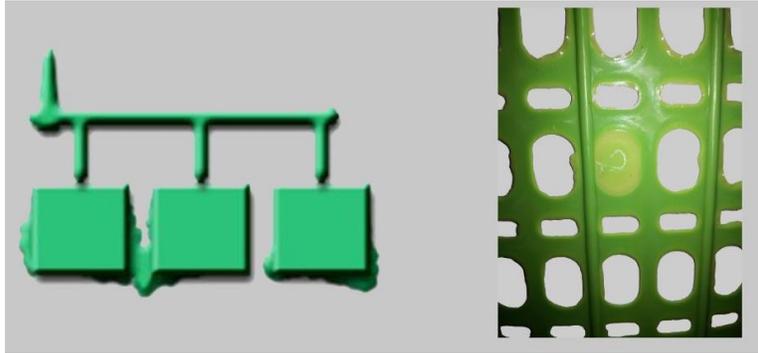


Figura 14. Ejemplos de rebaba en piezas plásticas [68].

Volumen de inyección

Este parámetro considera la cantidad máxima de polímero que se utiliza para llenar la cavidad del molde y que, preferentemente, se puede desplazar con una sola inyección del barril [46], [54]. Cerca del 95-98 % de la cavidad se llena normalmente durante la inyección inicial y el resto de la cavidad durante la segunda etapa de inyección. Sin embargo, para piezas con pared delgada, toda la cavidad es llenada durante la primera inyección porque la pieza se solidifica antes de que se realice la inyección de mantenimiento [10], [44].

Es necesario establecer un volumen correcto de inyección, de lo contrario pueden variar la cantidad de disparos que se hagan en el molde, hasta que se alcance el relleno deseado (en el caso cuando se tiene poco material en la inyección). Cuando hay exceso de material, puede provocar que el molde se abra y se filtre cierta cantidad en los bordes de la cavidad, la compuerta y los canales de inyección, lo que puede provocar también daños en el molde [44].

Tiempo ciclo

El tiempo ciclo hace referencia al tiempo requerido para hacer todas las actividades que están involucradas en la producción de una pieza (sean actividades simultaneas o de las que necesitan para iniciar que otras se completen). Es decir, el tiempo que se necesita para inyectar un producto. El conocimiento de este parámetro es fundamental para determinar el costo real para la fabricación de un objeto y, en consecuencia, para establecer los precios de venta [10].

Tiempo de inyección

El tiempo de inyección se considera desde el primer empuje que hace el tornillo (que también funge como émbolo) en el plástico y que permite la transferencia del material fundido en el molde cerrado; hasta que logra el llenado completo de sus cavidades. Durante esta actividad, la presión que se ejerce es la más alta del proceso, y corresponde a la presión de inyección inicial [10], [52].

En general, el control del tiempo de inyección está regulado por un temporizador y su valor real resulta inferior a los dos segundos (difícilmente consigue superar los tres segundos). El cambio de este valor puede atribuirse a la fluidez del material y al diseño de la máquina [10].

Tiempo de retención o mantenimiento de inyección

Similar al concepto de presión de mantenimiento, el tiempo de residencia es el tiempo en el que, por medio del tornillo ubicado en el barril, se mantiene una presión contra el plástico después de haberlo inyectado en el molde (posterior a la primera inyección). Dicha presión se mantiene el tiempo suficiente para que el material de la compuerta se solidifique. Este tiempo se considera una vez que el material, requerido para llenar las cavidades del molde, se enfría bajo una presión constante hasta su solidificación [1], [52].

Tiempo de enfriamiento

Éste es uno de los factores más importantes para la formación correcta de los productos plásticos, ya que se refiere al tiempo que requiere el material para enfriarse y cambiar al estado sólido. Del mismo modo contempla el tiempo necesario para que el producto se vuelva lo suficientemente rígido para resistir el proceso de expulsión del molde. Este punto final es crítico, porque si se expulsa antes de que la pieza sea lo suficiente rígida, tiene el riesgo de fracturarse al ser empujada por los eyectores del molde³⁹ [44], [52].

El reto principal con este parámetro es conseguir el tiempo mínimo necesario para que el producto solidifique lo suficiente dentro del molde, sin que represente un tiempo ciclo elevado, y aumente así el costo de producción. Los factores que se relacionan con el tiempo de enfriamiento son el tipo de material, la geometría del producto (por ejemplo, el espesor de pared), el sistema de refrigeración que opere en el molde, entre otros [10]. La necesidad de control de este factor radica en la susceptibilidad del polímero a solidificarse, en cualquier momento de la inyección, figura 15. De esta forma el tiempo ciclo de un proceso está influenciado en gran medida por el tiempo de enfriamiento (para evitar que no solidifique el plástico en alguna zona no deseada y que sí lo haga una vez llenado el molde) [1].

³⁹ Se considera que el 95% de la rigidez total del producto plástico se consigue en el interior del molde. El resto se consigue fuera del molde y puede tardar hasta 30 días en finalizar [10].

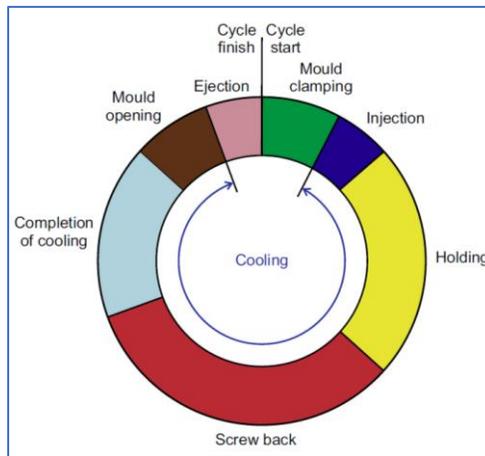


Figura 15. Etapas del ciclo de inyección de plásticos donde está presente el proceso de enfriamiento [1].

Velocidad de inyección

En la velocidad de inyección se engloban otros parámetros, especialmente la presión de inyección, la temperatura de fusión, el tiempo ciclo y las propiedades del mismo material. Esta variable contempla la velocidad con la que plástico fundido fluye desde la boquilla del barril y entra en contacto con el extremo de la cavidad. Si bien los efectos de la velocidad de inyección se consideran complejos y difíciles de predecir, por los factores que lo influyen, una mala aplicación de esta velocidad puede dar lugar a distintos defectos en la pieza inyectada. Por ejemplo, cuando se inyecta lentamente la masa fundida en las cavidades, ésta puede empezar a solidificarse sin importar que el molde no esté completamente lleno. Una velocidad elevada, por otra parte, puede favorecer la degradación del polímero en la compuerta del molde y, en algunos casos, la reducción de algunas propiedades de la pieza, como la resistencia al impacto [1], [44], [45].

Generalmente, la velocidad de inyección varía con el tamaño de la máquina inyectora. Por ejemplo, las máquinas de inyección grandes pueden manejar velocidades de inyección elevadas, ya que tienen la capacidad de trabajar con moldes grandes y producir piezas de elevado tamaño, las cuales necesitan velocidades de inyección suficientemente altas para llenar las cavidades de forma adecuada [52].

En el proceso de inyección existen muchos elementos que influyen en la calidad de los productos fabricados, la capacidad productiva y económica de la empresa. Cada uno de los componentes de una máquina de inyección y las condiciones a las que opera se deben monitorear y controlar para obtener los mejores resultados, sin embargo, esto no es siempre plausible (ni en las máquinas que operan de forma automática). El análisis de estos factores permite formar in primer plano sobre los puntos más críticos en donde se podría implementar una herramienta alterna, como la inteligencia artificial, con el fin de controlar mejor el proceso.

2.5 Principales retos del proceso de inyección

La industria de inyección de plásticos contempla diversos procesos que, como hemos señalado, pueden considerarse técnicamente complejos. Cada una de las etapas que componen la cadena de valor de esta industria involucran actividades con distintos niveles de riesgo relacionados a la capacidad y calidad productiva, y en la integridad de las personas relacionadas a estas actividades. Con esta premisa, resulta significativo distinguir los procesos que afectan, en mayor proporción a las empresas inyectoras, con el fin de distinguir las etapas donde se podrían desarrollar planes de mejora y optimización (por ejemplo, mediante el uso de tecnologías como la inteligencia artificial).

De acuerdo con Farooque [69], los temas afines a la máquina de inyección, especialmente los parámetros de inyección han sido investigados en mayor proporción para su optimización. No obstante, existen otras situaciones que también merecen atención, debido al efecto negativo que pueden provocar cuando no se tiene control sobre sus procesos. Por ejemplo, la planeación de producción y la gestión de tiempo, inspección de productos, diseño de procesos, o la estimación de costos. En este apartado se exponen algunos de los retos más representativos en la literatura sobre la industria de inyección y su nivel de importancia en la cadena de valor.

2.5.1 Materia prima

La industria de inyección cuenta con un gran número de resinas poliméricas, que están disponibles para utilizarlos en sus procesos. En general, el rango de costos en los que se encuentran estos materiales varía de acuerdo con las propiedades que poseen y a las características que pueden otorgarles a los productos que se fabriquen con ellos. La selección del material para inyectar depende de las propiedades del producto que se desee fabricar y de la capacidad que tengan las máquinas de inyección para procesar cierto tipo de resinas [10].

Específicamente, las fases de calentamiento, presión y enfriamiento del material influyen en el proceso de selección de los polímeros que se inyectarán. Por una parte, el calor aplicado en la máquina inyectora influye en la forma en que se funde el plástico y promueve el movimiento de las moléculas del polímero (el cual varía dependiendo si se trabaja con materiales amorfos o cristalinos⁴⁰). Del mismo modo, de acuerdo con el polímero que se utilice será la presión que se trabaje durante la inyección, la cual debe permitir flujo del plástico, desde el cilindro de calentamiento hasta las cavidades del molde. Finalmente, en el enfriamiento se toma en cuenta la rapidez con la que solidifica el polímero, es decir se revisa la temperatura en la que el movimiento molecular del plástico. En este caso, la selección del

⁴⁰ Los materiales plásticos amorfos, conforme reciben calor, inician su fundición de manera progresiva; mientras que los materiales cristalinos, no hay ningún cambio en su estructura hasta que se alcanza el punto de fundición [10].

polímero debe contemplar uno que permita el acomodo de moléculas adecuado⁴¹ y que evite los enfriamientos abruptos [1], [10].

A pesar de que se pueden conseguir resinas con características muy específicas, se debe tomar en cuenta que el costo de estos materiales puede incrementarse significativamente conforme aumenta su nivel de especialidad, al mismo tiempo que disminuye su procesabilidad [69]. Del mismo modo, es posible agregar rellenos o refuerzos que permitan cambiar las propiedades de las resinas bases, sin embargo, se debe considerar que su implementación puede modificar el costo del producto. Por ejemplo, se puede agregar talco o la arcilla a la resina para disminuir la cantidad de polímero que se necesita en la elaboración de un producto, y con ello su costo de producción. El níquel o las fibras de acero, por otra parte, pueden ayudar a que el plástico sea conductor, sin embargo, su uso puede incrementar significativamente el valor de la materia prima [10], [54].

La materia prima principal de las inyectoras es tan variada, que se han registrado más de 18 mil plásticos para utilizar en la producción de diferentes objetos plásticos [10]. Aunque esto representa ventajas en la disponibilidad de material y en la elaboración de productos con características muy específicas, se debe considerar que es más difícil de procesar las resinas cuando están reforzadas o poseen características especiales. En este sentido, ciertos reforzamientos, como la fibra de vidrio o el grafito pueden colocarse en el plástico para dar fuerza al producto⁴². El inconveniente de esta adición es que, aunque conlleva mejoras en las propiedades de los productos, reduce el índice de fusión del plástico, además de que desgasta el molde [52], [53].

La selección adecuada de materia prima permitirá un desarrollo adecuado del proceso. Esto favorecerá que el plástico se funda homogéneamente; que fluya adecuadamente en las cavidades del molde y que su proceso de enfriamiento permita una solidificación correcta de los productos finales.

2.5.2 Importancia de las personas en los procesos de manufactura (operación e inspección)

De todos los componentes que integran las industrias de inyección, el factor humano es uno de los que requieren más atención. A diferencia de las máquinas y equipos auxiliares que se pueden ajustar y controlar, de acuerdo con las metas que se planteen, las personas requieren diferentes consideraciones para desarrollar correctamente sus labores. En este rubro se considera especialmente a los operadores de las máquinas inyectoras y al personal encargado de las inspecciones a los productos (la cual puede ser realizada por los mismos operadores o por personal del departamento de calidad). Es importante remarcar que no hay nadie que sepa mejor el desarrollo del proceso y la calidad real de los productos que estas personas, por lo

⁴¹ Está reportado que el movimiento de las moléculas no se detiene por lo menos durante 30 días después de su inyección [10].

⁴² Otros reforzamientos pueden proveer otras características a los productos, como resistencia a la compresión, a la flexión, al impacto, entre otros.

tanto, se debe poner atención a todos los elementos que influyen en el cumplimiento de sus actividades.

Inicialmente, todo el personal, sin importar sus actividades o el cargo en el que se encuentre, debe conocer los objetivos de la organización en donde se encuentran y, con eso en mente, ayudar al cumplimiento de estas metas, con sus actividades diarias. Para lograrlo es necesario revisar constantemente la actitud y consistencia que presentan ante sus actividades diarias. La consistencia debe ser tomada en cuenta para asegurar que todos los ciclos de operación se realizan de la misma manera. Además, el manejo continuo de las máquinas inyectoras hace necesario que se ponga atención a cada operación, ya que en muchas ocasiones el manejo de las máquinas implica abrir y cerrar manualmente las compuertas de las máquinas⁴³, e incluso manipular el espacio entre los moldes. Estas actividades pueden tener consecuencias indeseables, no solo para el buen funcionamiento de las máquinas y desarrollo de los procesos, sino en mayor grado de importancia, en la integridad de cada operador [70]. Respecto al proceso, en la consistencia también se cuida que el tiempo que toma cada tarea sea el mismo en cada tarea, ya que se ha estudiado que tener diferencias de un segundo entre cada ciclo de inyección tiene como consecuencias gastos significativos para la empresa (por lo menos, \$10,000 dólares por año) [10].

En la operación de las máquinas es importante garantizar que las inyectoras funcionan adecuadamente, que sus componentes se encuentran en buen estado, y que los productos se elaboran correctamente. Los operadores, en este sentido, deben monitorear que los productos se estén inyectando de acuerdo con su diseño, que la máquina trabaja en orden; y también revisan que las unidades de la inyectora estén en óptimas condiciones y que se cuenta con la materia prima suficiente para no retrasar o afectar el proceso. Asimismo, sus actividades están involucradas con la gestión de los productos. Cuando los productos requieren de alguna operación secundaria, como la eliminación de coladas de inyección y rebabas, colocación de etiquetado, etc., o cuando se debe hacer un desmontaje del molde, se requiere que los operadores pongan la mayor atención posible, ya que no solo puede afectar la condición del producto, sino que puede poner en riesgo su salud [10], [48]. Por ejemplo, en ocasiones las personas deben sacar manualmente los productos de los moldes, antes que comience el siguiente ciclo. En ese caso, ellos deben revisar no solo que el producto salga en buen estado, sino que también que los eyectores de las máquinas no queden atorados en el molde, ya que durante el cierre del molde pueden ser dañados.

Otra actividad realizada por el personal de las plantas de inyección y que influye directamente con su desarrollo, es la inspección de los productos. En la mayoría de los casos se trata de una comprobación de especificaciones mediante la observación visual, para determinar si el objeto cumple con su diseño. Sin embargo, este ejercicio tiene diversas desventajas, de las que se pueden destacar: 1) No se pueden hacer inspecciones perfectas, ya que pueden existir unidades defectuosas que no fueron revisadas o que no fueron revisadas correctamente por los inspectores (por error o de forma premeditada). 2) Los productos complejos dificultan la efectividad de la revisión o incrementan el tiempo necesario para realizar la misma (lo cual

⁴³ Hay máquinas que son automáticas o semiautomáticas que no involucran demasiado a los operadores.

no es conveniente para producciones con ciclos cortos de inyección). 3) Si la inspección no está estandarizada, el resultado depende del criterio de cada inspector, haciendo esta práctica totalmente subjetiva. 4) La inspección rutinaria puede crear estados de aburrimiento y fatiga en las personas, facilitando la aprobación de productos defectuosos (debido a una mala revisión). 5) La inspección por sí sola no añade valor agregado al producto, sin embargo, aumenta los costos de producción debido al uso de recursos para su realización (personas, productos para pruebas destructivas, entre otras) [14], [15].

De esta manera, la gestión de las actividades en las que se relacionan las personas debe ayudar a crear herramienta que no solo le ayuden a cumplir los objetivos de producción, también debe reducir los riesgos relacionados con su salud.

2.5.3 Diseño de productos

El diseño de productos es un proceso crítico en la inyección de plásticos, ya que de sus resultados se influye en la manera en que se llevarán a cabo los procesos de manufactura y en las características que los productos ofrecerán de forma real a los consumidores. Por lo tanto, es importante que las actividades relacionadas a este proceso se desarrollen correctamente, desde la concepción de la idea del producto, la definición de los recursos que son necesarios para su elaboración, hasta la forma en que se debería inyectar [46].

El área de Ingeniería de producto habitualmente lleva a cabo el proceso de diseño, sin embargo, sus labores se deben apoyar otros grupos de la organización, como del equipo de compras, ingeniería de materiales y de manufactura, calidad y mercadotecnia. Si bien el departamento de diseño es el encargado de realizar los bocetos y definir las especificaciones de los productos, es importante que mantenga una comunicación estrecha con las demás áreas para complementar su trabajo. Por ejemplo, con el fin de delimitar un diseño del producto adecuado, desde el inicio del proceso se recomienda realizar reuniones interdepartamentales, para solicitar opiniones, discutir sobre los conceptos del diseño, indagar sus puntos buenos y malos y revisar la mejor forma para impulsar el lanzamiento del producto [15], [46].

La complejidad de las reuniones, sobre el diseño de un producto, radica en la solución de las siguientes preguntas:

- ¿Qué hace el producto? En este caso se describen las funciones principales de la pieza, y se define cómo funciona y qué hace.
- ¿Cómo se producirá? Este campo se refiere a los métodos necesarios que se deben usar para manufacturar el producto. Se discuten las cantidades de producción, las características básicas del diseño, la materia prima, el tamaño de los equipos, si requieren operaciones secundarias (y de necesitarlas, analizar si es posible reducirlas), etc.
- ¿Cuándo se debería iniciar la producción? Esta pregunta es una de las bases para todo el proceso de diseño, ya que con ella se define el programa de producción y el cronograma de actividades del propio diseño. Su respuesta está basada en las proyecciones, negociaciones del proyecto, y estudios (generalmente hechos por el departamento de márketing) sobre el tiempo probable en que el cliente podría demandarlo.

- ¿Dónde se producirá? Es importante definir si el producto se puede desarrollar totalmente en la organización o si requerirá de la intervención de otras empresas para completarse. En esta sección se contempla si se tiene todo lo necesario para elaborar el producto o si se tienen limitaciones económicas, de seguridad, tecnológicas, de personal o de tiempo (si el programa de producción no se empalma con otras operaciones).
- Finalmente, ¿cuánto deberá costar? para establecer el valor, se consideran los costos del molde, materia prima, de mantenimiento e inspección, de operación (primaria y secundaria), empaque, almacenamiento y envío de producto (también se contempla si se requieren piezas o partes elaboradas por terceros) [46], [71].

Estas preguntas se deben contemplar a lo largo de las etapas que componen el desarrollo de un producto: 1) Propuesta inicial del producto al grupo de desarrollo. 2) Definición de las especificaciones del producto. En esta etapa también se delimitan los precios objetivos, fechas de programación, información del producto, planes de prueba, procesos de fabricación, materiales necesarios, tipo de empaque, etc. Además, se establece la financiación y se comprometen los recursos iniciales. 3) Diseño del producto. En esta etapa se determinan las dimensiones iniciales y se formalizan los requisitos del producto. También se hacen revisiones del diseño para valorar posibles cambios. 4) Estrategia de suministro. Se determina dónde se fabricará el producto, si todo será en la organización o si se requerirá de algún tercero para elaborar ciertos componentes. 5) Prototipos. Se determina el número de prototipos por producir y se elaboran, por simulación o de forma física. 6) Validación del producto. Se fijan los costos finales, de acuerdo con las especificaciones que se pueden conseguir del producto, junto con la calidad real. Además, se contempla el nivel y volumen de producción que se puede alcanzar de esta unidad. 7) Inicio de producción. Se documenta los recursos establecidos y los parámetros de operación, se capacita al personal que será involucrado y se generan programas de calidad. [10], [46].

El éxito de este proceso depende de muchas variables, sin embargo, existen diversos factores que pueden dificultar significativamente su cumplimiento. Por ejemplo, si no se realizan estudios adecuados de las necesidades del cliente, o si no se contempla el funcionamiento real de los productos, se pueden elaborar unidades que realmente no desea el cliente o que no cumplan con las especificaciones con las que fue planeado.

Como en otro tipo de procesos, cuando hay desorganización y mala comunicación entre los equipos de trabajo es probable que los resultados tomen más tiempo de lo planeado o que no se cumplan con los objetivos. Una mala gestión de cambios, en donde no se tiene un procedimiento controlado sobre la implementación de las modificaciones o correcciones, puede dar como resultado que no se tomen en cuenta o que no se actualice para todas las áreas pertinentes todos los cambios que se generen en el diseño y, de este modo, se complique el proceso de desarrollo. Finalmente, al no contemplar los recursos tecnológicos y de capacidad del personal cuando se seleccione el proceso de fabricación, se puede desaprovechar el recurso interno al no definir un proceso realmente apropiado por falta de experiencia en el tema, o elevar los costos de producción debido al uso de equipos que no son adecuados para la elaboración del objeto [46].

2.5.4 Gestión de costos

Si bien en la industria de inyección se involucran una serie de costos inherentes a los procesos de la cadena de valor, existen algunos que no son tomados en cuenta, como los suministros o equipo que son esenciales para el funcionamiento de la organización. De acuerdo, con Douglas, B. [71], los principales costos en una empresa de plásticos son:

- a) Equipos primarios y auxiliares. Los costos relacionados a estas unidades contemplan su operación, mantenimiento y servicio durante toda su vida útil. En este grupo se contempla la energía y los recursos (como equipos o materiales) necesarios para hacer funcionar los equipos primarios. Por ejemplo, se incluyen los motores de velocidad variable, bombas hidráulicas, secadores de la tolva, controladores de temperatura, granuladores, abrazaderas para montaje de moldes suministro de agua, etc.
- b) Equipo secundario. Se refiere a los elementos utilizados, después de la inyección, para elaborar y acondicionar un producto. Se incluyen procesos de pintura, ensamble, decoración (como tampografía, serigrafía, estampado, entre otros), grabado, embalaje, envío e inspección. Los recursos que se usan en estas operaciones incluyen desde las etiquetas, pegamento y pistolas de pegamento, hasta las máquinas de soldadura, cabinas de pintura o equipo de serigrafiado.
- c) Depreciación. En la depreciación se contempla el tiempo de vida de los equipos, desde su adquisición, hasta antes quedar obsoletos (ya sea porque se alcanzó el tiempo de vida útil o por cambios en las operaciones o el diseño del proceso). Normalmente, el tiempo de depreciación de los equipos primarios puede ser de siete años y el de los equipos auxiliares de 10 años. Estos valores dependen del uso que se haga de estas unidades, de la exclusividad de uso para diferentes productos, de las operaciones de mantenimiento que se le hagan, etc.
- d) Mantenimiento. En este rubro se consideran todos los elementos que se necesitan para llevar a cabo las actividades de mantenimiento: los equipos, el personal, refacciones, sustancias químicas, entre otros. El costo de esta inversión depende del nivel de especialización que se le dé a esta área.
- e) Operación. Los costos provenientes de la producción dependen del tipo de producto que fabrica. Este valor varía de acuerdo con la complejidad de los productos, ya que influye en los recursos y la mano de obra que necesitará su fabricación. Otros gastos que se consideran en este campo son los provenientes de la operación de equipos (como el servicio eléctrico y de agua); la provisión de funciones de ingeniería, mantenimiento, mano de obra, capacitación y demás actividades relacionadas con áreas de recursos humanos.

La estimación de costos es un ejercicio que se realiza constantemente en una organización. Su desarrollo depende de elementos puntuales, como los señalados anteriormente, y de otros factores relacionados con el desempeño de la misma industria, como su eficiencia y el tiempo

de utilización efectivo⁴⁴. Una gestión incorrecta de costos puede derivar en pérdidas económicas y malos desempeños de la organización, ya que con esta actividad se facilitan todos los recursos que necesarios para llevar a cabo los procesos de la cadena de valor [71].

2.5.5 Gestión de tiempos

En general, puede resultar difícil programar y coordinar eficientemente las actividades de los procesos que conforman la industria de inyección, debido a la complejidad de las operaciones [71]. Existen diversos factores que pueden afectar el tiempo que se utiliza para fabricar un objeto, algunos de ellos están presentes de forma inherente en los procesos y otros son ajenos a su desarrollo. El inconveniente de estos últimos es que pueden surgir como consecuencia de planeaciones ineficientes. Por ejemplo, el tiempo que lleva el montaje de los moldes puede alargarse debido a los movimientos que se requieren para su disposición y acondicionamiento (al ser unidades delicadas y pesadas su manejo requiere el uso de grúas y de la precaución de operadores).

Del mismo modo, la mayoría de las veces la programación y configuración de las máquinas en cada arranque de producción necesita algunas corridas de prueba para obtener los parámetros apropiados. Tales pruebas se hacen con el fin de garantizar que se producirán piezas de buena calidad desde el inicio de la corrida. El problema en este caso es que su desarrollo puede tomar más tiempo del necesario, por ejemplo, si se trata de productos o materias primas nuevas, o si el personal no está capacitado para el manejo de la máquina. A pesar de que estas actividades no forman parte del propio proceso de inyección, son de gran interés para la industria, debido a su frecuencia en los procesos y las consecuencias significativas que conlleva su ocurrencia. Es por ello que, las organizaciones deben buscar la forma de contemplar e incorporar todos los factores que afectan el desarrollo de la producción, y establecer programas que efectivos y reducir los tiempos muertos [46].

Durante la formulación de los programas de producción se contemplan factores como: las cavidades del molde, el tiempo de producción de piezas plásticas (junto el tiempo de preparación de las máquinas), tiempo que se requiere para cambiar de molde y también para acondicionarlo; la disponibilidad de materia prima y tiempo de preparación del material que alimenta las unidades de inyección, etc. Bazargan-Lari, M, et al. [72] mencionan que algunas de las pautas de seguridad establecidas durante la pandemia de COVID-19, como el distanciamiento físico entre el personal de las organizaciones, han significado un reto adicional a la planeación de producción. Estas restricciones pueden ser difíciles de acatar en esta industria, debido al diseño que normalmente se tiene en las plantas, ya que el espacio entre unidades es mínimo y no permite hacer alguna modificación que aumente tal distancia. Por este motivo resulta indispensable, no solo para la industria de inyección, tener la capacidad de desarrollar programas y planificaciones de trabajos que minimicen los tiempos de producción y gestionen mejor los recursos que tienen disponibles. Además, que este tenga

⁴⁴ La eficiencia se refiere a los ciclos ejecutados y las piezas elaboradas, y se compara con las piezas que fueron enviadas. El tiempo de utilización considera el tiempo en que las máquinas inyectoras realmente producen piezas buenas, en comparación con el tiempo que tienen disponible para ello.

la adaptabilidad de afrontar restricciones no planeadas, como la derivada por la pandemia de COVID-19.

El personal relacionado con la planeación tiene una gran responsabilidad para considerar todos los eventos que influyen en el flujo del proceso. De acuerdo con Sarac, T. [73] hay tres tipos de generadores de desperdicios de tiempo en la industria de inyección. Estas fuentes son: 1) Diferencias del tiempo de configuración en las secuencias entre trabajos, 2) restricciones de elegibilidad por condiciones técnicas entre máquinas de inyección que se necesitan utilizar, y 3) impedimento del uso de recursos comunes, como moldes y materia prima. La ocurrencia de cualquiera de estas fuentes puede retrasar considerablemente cualquier producción y afectar significativamente la economía de la organización.

Yazici, K. et al., por su parte, señalan que la producción de pocos y diferentes productos incrementan las etapas de los procesos productivos y con ello, el tiempo empleado entre la fabricación de un material y otro [74]. El objetivo del departamento de planeación radica en organizar todas las actividades que son necesarias para la producción de varios productos, considerando las fuentes de retraso, internas y externas a la organización. La planeación, en este sentido, debe estar orientada en mejorar la eficiencia de los procesos y en satisfacer oportunamente la demanda en el mercado.

Uno de los puntos iniciales a considerar en la planeación de producción es la preparación de las materias primas. Esta actividad requiere de mucha atención, ya que se relaciona directamente con la elaboración de los productos y si no se prepara correctamente desde el inicio, puede acarrear con problemas en el arranque de producción y en las propiedades de los plásticos.

La elegibilidad entre máquinas y los recursos de inyección, como moldes o resinas, aunque no son factores propios del proceso de fabricación, se deben tomar en cuenta durante la planeación, ya que pueden afectar el desarrollo de la inyección y el cumplimiento de las metas productivas. Por ejemplo, si solo se tiene el molde de un producto y se desean elaborar piezas de una misma estructura, pero con diferentes colores, no es posible programar la fabricación simultánea de todos los objetos. En este caso se debe elaborar un plan de producción secuencial, en el que se considere el cambio de un color a otro ⁴⁵ Por otra parte, sería posible fabricar los productos con diferentes colores al mismo tiempo, si se tiene más de un molde disponible. Para esta situación, se debe considerar que las máquinas que se planea ocupar, y el resto de los recursos, están disponibles para su uso durante toda la producción. Es importante conocer esta disponibilidad, ya que entre un equipo y otro pueden existir restricciones de operación [71], [72].

Con base en lo anterior, los programas de producción deben contemplar los factores tradicionales (los cuales ya son complejos de analizar) y, además, ser capaces de adaptarse a

⁴⁵ Se pueden tener retrasos entre el cambio de un pigmento y otro, debido a las purgas y otros ajustes que se deben hacer para expulsar todo el material con el color anterior. En este sentido, se recomienda trabajar primero con los colores claros, hasta llegar a los más oscuros, con el fin de minimizar el tiempo de limpieza entre cambio de color [75].

nuevas condiciones y restricciones que puedan surgir. De lo contrario, es probable que se tenga ineficiencia productiva y, posiblemente, se incumpla en las fechas definidas por los clientes.

2.5.6 Parámetros y máquina de inyección (inyección de piezas plásticas)

El proceso de inyección es una de las etapas más críticas en la cadena de valor de esta industria, ya que su desarrollo influye no solo en la eficiencia operativa de la industria, sino también en el grado de cumplimiento de las necesidades de los clientes. En la literatura se ha reportado que las máquinas de inyección y los moldes son los principales generadores de defectos de la etapa de inyección, figura 16 [10]. Dentro de estas dos fuentes se contemplan problemáticas como: mal ajuste de parámetros, montaje inadecuado del molde, funcionamiento incorrecto de los componentes de las máquinas y moldes, etc.

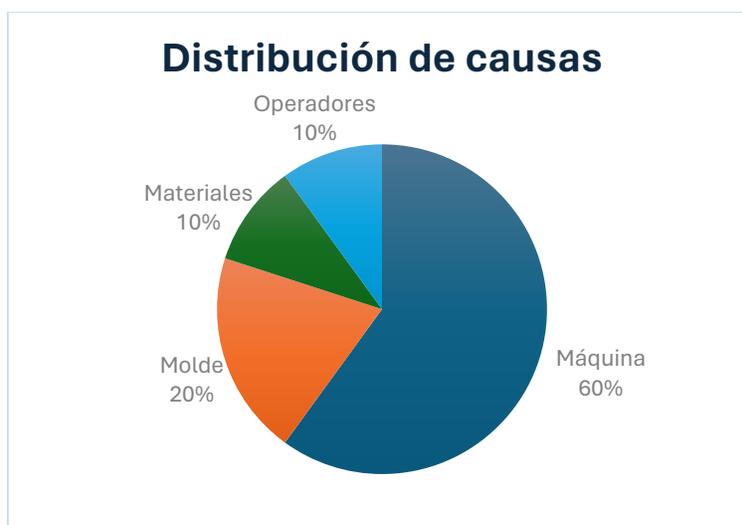


Figura 16. Distribución de causas de defectos en el proceso de inyección [10].

Como se mencionó anteriormente, una de las consecuencias de tener un control incorrecto de procesos es la fabricación de artículos con defectos de inyección, como contaminación, agrietamiento, ampollas (aire atrapado en el plástico), deformaciones, degradación de material (o material crudo), marcas de esfuerzo, líneas de flujo, etc. [10], [69]. Farooque, R. et al. [69] mencionan que el origen de estos defectos se debe especialmente a ciertos parámetros, que repercuten directamente en las características del producto final y en el rendimiento de las industrias. Estos parámetros son la presión de sujeción e inyección, el tiempo de inyección, de sujeción y de enfriamiento; la temperatura de fundición, del molde y de enfriamiento; y la rapidez de inyección.

Zhao, N., et al. [75] afirman que los defectos más frecuentes en los plásticos son la deformación y el hundimiento. Estas no conformidades son producidas por parámetros inadecuados y provocan el mayor número de desechos y pérdidas económicas en la inyección. En su trabajo describen algunas estrategias para controlar la aparición de estos defectos, como la modificación de la superficie de los productos y la optimización del sistema

de llenado, de enfriamiento y del mecanismo de expulsión de la inyectora. Además, exponen que el ajuste de parámetros, como la temperatura del molde, presión de sujeción y el tiempo de enfriamiento, puede ayudar a prevenir o corregir estos defectos.

La revisión de los parámetros se considera como un primer paso para mejorar el proceso de inyección. Los estudios que se han realizado en este sector han tenido como principal objetivo entender, de mejor manera, el funcionamiento del proceso. De este modo, se busca comprender la relación que existe entre los parámetros de inyección y los defectos más comunes. Además, por medio de estos estudios, se pretende conseguir un mejor control del proceso, reflejado en una reducción de desperdicios y un incremento del rendimiento productivo [46], [52].

A lo largo de este capítulo se revisaron, a grandes rasgos, la cadena de valor de la industria de inyección, los principales componentes de las máquinas de inyección y también se describieron los parámetros que más influyen en el proceso, de acuerdo con la literatura. Finalmente, se expusieron los retos industriales que representan un mayor riesgo para el cumplimiento de los objetivos. En la tabla 3 se presentan los retos revisados en capítulo y una breve descripción de los mismos.

Tabla 3. Resumen de los retos de mayor riesgo en la industria de inyección, agrupados por tipo.

Tipo de Reto	Descripción
Materia Prima	Las propiedades de las resinas poliméricas influyen en el costo de adquisición del material, las características de los productos plásticos y, además, en el nivel de operabilidad en el proceso de inyección. Seleccionar el material adecuado, permite conseguir materiales de buena calidad y procesos más fáciles de realizar.
Factor humano	A diferencia del resto de los retos considerados, el factor humano requiere diferentes consideraciones para que puedan desarrollar correctamente sus labores. Se debe poner atención a la consistencia y la actitud que tienen en sus actividades diarias, ya que estos personajes son los que determinan principalmente el nivel de cumplimiento de los objetivos de producción y la calidad de los productos. En el proceso de inyección, las personas están relacionadas especialmente en la operación y manejo de las máquinas inyectoras y en la inspección de los productos. En general, los operadores se encargan de revisar que las unidades operan correctamente, que se encuentran en buen estado y que los productos se están fabricando correctamente (también pueden realizar operaciones secundarias a los productos, con el fin de adecuarlos para procesos futuros o para entregarlos con los clientes). Su función no solo garantiza que se consigan buenos rendimientos del proceso, también permite reducir riesgos relacionados con su seguridad, al evitar accidentes que pueden comprometer la integridad de las personas.
Diseño de productos	Este proceso influye directamente en la manera en que se llevará el proceso de inyección y en las características que presentarán realmente los productos. Este rubro considera desde la concepción de la idea del producto, la definición

	de los recursos necesarios para su elaboración, hasta la forma en que se debería inyectar.
Gestión de costos	Para garantizar la estabilidad de las organizaciones, se deben considerar los costos que son inherentes a los procesos de la cadena de valor. De esta forma, es importante considerar los costos provenientes de los equipos primarios y auxiliares, equipos secundarios, la depreciación de las unidades, los costos por mantenimiento y los de operación, principalmente. Una gestión incorrecta de los costos puede derivar en pérdidas económicas y malos desempeños de la organización.
Gestión de tiempos	En este sector se considera la programación y coordinación de las actividades relacionadas con los procesos que conforman la industria de inyección. Del mismo modo, se deben contemplar los factores que pueden afectar el tiempo necesario para completar un pedido y su probabilidad de ocurrencia, con el fin de mitigar lo mejor posible los retrasos que se puedan derivarse por una mala planeación. Durante el desarrollo de las planeaciones se debe considerar principalmente tres tipos de generadores de desperdicios de tiempo, en la operación de inyección: diferencias de tiempo de configuración en las secuencias entre trabajos; restricciones de elegibilidad por condiciones técnicas entre máquinas; y el impedimento del uso de recursos comunes. Los programas de producción deben contemplar todos los factores relacionados con la inyección y, además, ser capaces de adaptarse a la ocurrencia de situaciones y restricciones que pueden surgir.
Parámetros y máquina de inyección	El proceso de inyección influye en la eficiencia operativa de la industria y en el nivel de cumplimiento de las necesidades de los clientes. Específicamente las máquinas de inyección y los moldes son los principales generadores de defectos, por lo que es importante poner atención en esta área para tener un mayor control del proceso. Los estudios que se han hecho en este rubro están orientados a mejorar el entendimiento que se tiene del funcionamiento del proceso, ya que se ha reportado que en las inyectoras existen más de 100 parámetros que intervienen en la producción de piezas plásticas. Además, existen diversos factores que pueden provocar fluctuaciones en las condiciones del proceso, como los ambientales. Esto provoca que no sea sencillo predecir de forma tradicional el desenvolvimiento del proceso.

Si bien todos los retos expuestos son de interés para la industria de inyección, en la actualidad no todos ellos han sido revisados con la misma intensidad. Como siguiente paso, resulta necesario conocer las áreas de la industria de inyección en donde más se ha desarrollado tecnología con IA. Esta información servirá como referencia para definir la estructura de la metodología de implementación tecnológica, y para reconocer los elementos que han ayudado a desarrollar exitosamente este tipo de innovación.

Capítulo 3. Metodología

La elaboración de esta tesis de investigación se realizó conforme al procedimiento representado en la figura 17.

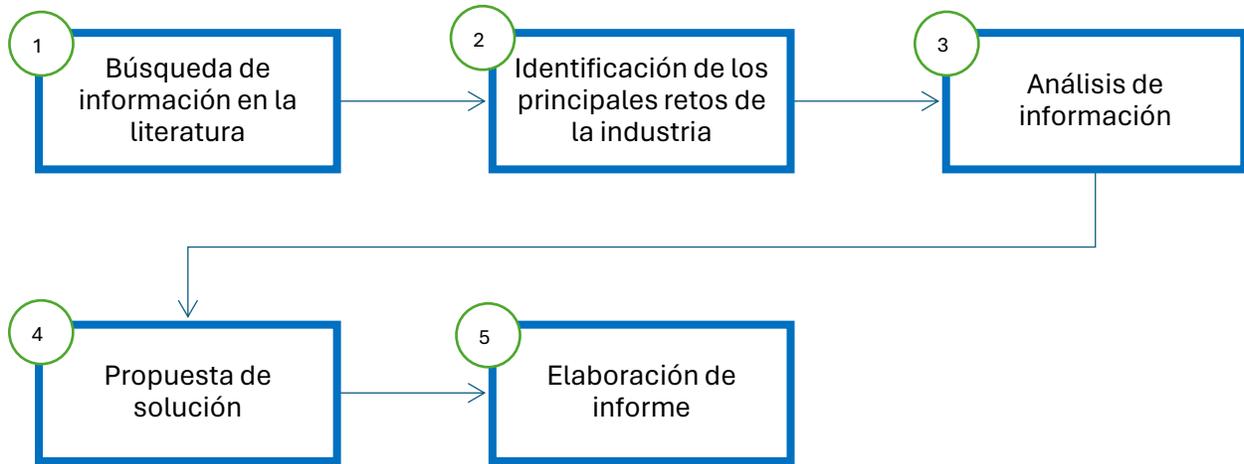


Figura 17. Metodología empleada en la presente investigación.

3.1 Búsqueda de información en la literatura: Discriminación de fuentes bibliográficas y primera exploración del tema

Las fuentes primarias de información para esta investigación fueron las bases de datos Compendex y Scopus, debido a su nivel de especialización en temas científicos, técnicos y de ingeniería. Del mismo modo, para complementar la información recabada, se revisaron otras fuentes bibliográficas como: informes gubernamentales, bibliografía especializada, manuales, publicaciones y hemerografía de organismos especializados en las industrias de plástico.

Se realizó una consulta inicial en las bases de datos con el fin de explorar los artículos relacionados a la industria de inyección. En ésta se utilizó el término “inyección de plásticos”, como descriptor base, y se obtuvieron 2575 artículos en Compendex y 2925 en Scopus. Por medio de los documentos conseguidos en esta búsqueda y de la información de otras fuentes bibliográficas se definieron cuatro descriptores⁴⁶ (“optimización”, “defectos”, “control de calidad” y “control de procesos”), los cuales fueron añadidos a la primera estrategia de búsqueda.

3.2 Delimitación de retos característicos en la industria de inyección

En la segunda exploración se redujo el número de documentos obtenidos de la búsqueda inicial a 224 y 329 documentos en Compendex y Scopus, respectivamente (tabla 4).

⁴⁶ La selección de los descriptores se realizó considerando las palabras cuyo significado esté más relacionado con el objetivo de la búsqueda y que podría ofrecer la mayor cantidad de artículos relevantes posibles.

Posteriormente, se realizó un mapeo del proceso de inyección, con la información obtenida de la segunda revisión y de otros recursos bibliográficos. Con ello, se describió el funcionamiento de las máquinas inyectoras y de los principales parámetros que influyen en ellas. Además, se describieron los defectos principales que aparecen las piezas plásticas, sus orígenes; y los diversos retos que son inherentes al proceso de inyección.

Tabla 4. Resultados obtenidos en la primera exploración bibliográfica.

Descriptor	COMPENDEX	SCOPUS
Primera búsqueda		
“Inyección de plásticos”	2575	2925
Segunda búsqueda		
“Inyección de plásticos” + (Optimización/Defectos/control de calidad/control de procesos)	224	329

Con base en la investigación anterior, se definieron las siguientes categorías en las que pueden clasificarse los retos que tiene el proceso de inyección de plástico:

1. Materia prima
2. Factor humano
3. Diseño de productos
4. Gestión de costos
5. Gestión de tiempo
6. Parámetros y máquina de inyección

3.3 Reconocimiento de los usos principales de IA en la inyección de plásticos

Debido al número de retos mencionados anteriormente, se decidió elegir aquellos que podrían ser de mayor interés para las industrias nacionales. Con este objetivo, se realizaron dos nuevas consultas en las bases de datos, en donde se revisó el grado de desarrollo de tecnologías con IA en la industria de inyección de plásticos.

En la primera estrategia de búsqueda se utilizaron dos descriptores: “inyección de plásticos” e “inteligencia artificial”, y se obtuvieron 149 documentos en Compendex y 86 en Scopus⁴⁷. Esta consulta se realizó para observar la intensidad de las actividades de investigación vinculadas al desarrollo de tecnologías con inteligencia artificial para la industria de inyección de plásticos.

Después, se definieron nuevos descriptores con el fin de relacionar los resultados de la búsqueda anterior con los retos industriales definidos. Dichos descriptores son:

⁴⁷ La cantidad de artículos encontrados con esta estrategia sugiere que la tecnología con IA, en la industria de inyección de plásticos, aún está en las primeras etapas de desarrollo. El número de innovaciones relacionadas a este tema ha incrementado significativamente en los últimos años.

1. Simulación
2. Diseño de productos
3. Diseño de procesos
4. Monitoreo de procesos
5. Mantenimiento
6. Planeación
7. Control de calidad
8. Inspección
9. Diagnóstico de fallas
10. Estimación de costos
11. Parámetros de procesamiento
12. Polímeros (material)
13. Visión computarizada
14. Optimización

Se realizó una segunda investigación con las palabras clave mencionadas y los descriptores “inyección de plásticos” e “inteligencia artificial”. Con este ejercicio se buscó recuperar documentos que expusieran casos específicos donde se ha implementado tecnología con IA en la industria de inyección. En la tabla 5 se muestra el número de artículos conseguidos, para cada descriptor, utilizando ambas bases de datos.

Tabla 5. Segunda exploración bibliográfica, relacionada con el desarrollo de tecnología con IA en la industria de inyección.

Descriptor	COMPENDEX	SCOPUS
1a Búsqueda		
“Inyección de plásticos” + “inteligencia artificial”	149	86
2a Búsqueda		
“Inyección de plásticos” + “inteligencia artificial” +		
Simulación	15	8
Diseño de producto	6	5
Diseño de procesos	2	12
Monitoreo de procesos	19	6
Mantenimiento	5	2
Planeación	4	1
Control calidad	20	14
Inspección	5	2
Diagnóstico de fallas	6	2
Estimación de costos	3	4
Parámetros de procesamiento	11	12
Polímero	6	3
Visión computarizada	5	2
Optimización	3	8

3.4 Elección de problemáticas para abordar con IA y consolidación de metodología de implementación tecnológica

Para consolidar una metodología que ofrezca información sobre los elementos y pasos para integrar tecnología inteligente en la industria, se consideró necesario delimitar los retos industriales que deben ser abordados por ella. La selección de los retos industriales se realizó con base en las fuentes secundarias especializadas y la información proveniente de las bases de datos. Asimismo, se determinó el nivel de relevancia de cada reto, por ejemplo, al revisar los efectos que se pueden obtener debido a malas prácticas.

Por otra parte, el nivel de desarrollo tecnológico se definió al clasificar los artículos conseguidos de la búsqueda bibliográfica final en cada uno de los retos propuestos. En este caso se examinó el número de innovaciones tecnológicas que se han desarrollado en los diferentes retos y se identificaron aquellos que contaban con más información disponible sobre la implementación tecnológica.

A pesar de que existen diferentes áreas de oportunidad en la industria de inyección, se decidió enfocar la investigación en dos de ellos, con el fin de ofrecer una metodología más puntual. Se tomaron en cuenta cuatro indicadores: productividad, calidad del producto, seguridad e información disponible sobre desarrollos de IA, para priorizar los retos identificados. Como resultado se encontró al “control de parámetros y máquina de inyección” y “gestión de personal” como los retos en los que se concentraría este documento. Ambos factores están relacionados con el nivel de rendimiento de las industrias y el grado de calidad que tienen sus productos, ya que se necesita del buen funcionamiento de máquinas para generar piezas con buenas características y de personal con buen desempeño para manipular las inyectoras, debido a que la mayoría de estas máquinas requieren aún de la intervención humana para funcionar. Del mismo modo, estos factores están relacionados a varias situaciones que pueden comprometer el buen estado de la infraestructura de la industria y, especialmente, la salud de las personas. Por último, para esta investigación se consideró importante la cantidad de artículos disponibles sobre IA desarrollada relacionada a los retos industriales, ya que estos documentos son clave para identificar los elementos que han sido clave para su desarrollo y que podrían servir para definir la metodología.

Posteriormente, se analizó el contenido de los artículos para establecer la metodología de implementación tecnológica. Toda la información recopilada fue examinada y organizada en el anexo 1 con el propósito de identificar los elementos clave que se han utilizado con mayor frecuencia en la implementación tecnológica. Posteriormente, se identificaron las principales funciones que ha tenido esta tecnología, las técnicas más usadas, la infraestructura tecnológica básica, la forma en que ha sido integrada a los procesos y los resultados que se han obtenido de ella. Con esto, se buscó ofrecer una metodología que permita motivar y orientar a las industrias a que implementen IA en sus sistemas de producción.

Finalmente, con los retos delimitados y la metodología propuesta definida se procedió a redactar el trabajo de tesis descrito en el presente documento.

Capítulo 4. Propuesta de metodología de implementación tecnológica

En este capítulo se presentan los resultados obtenidos del análisis de las investigaciones recopiladas en el Anexo 1. Se señalan las técnicas de IA más exploradas en la bibliografía, los diversos requisitos del sistema (físicos como los dispositivos electrónicos, e intangibles, como programas y softwares), el proceso de implementación y los resultados que se pueden conseguir al incluir esta tecnología en la industria de inyección, figura 18. Con lo anterior, se busca que la metodología formulada ofrezca información adecuada que facilite el acercamiento de las industrias de inyección nacional a la denominada industria 4.0, y a los beneficios que conlleva.

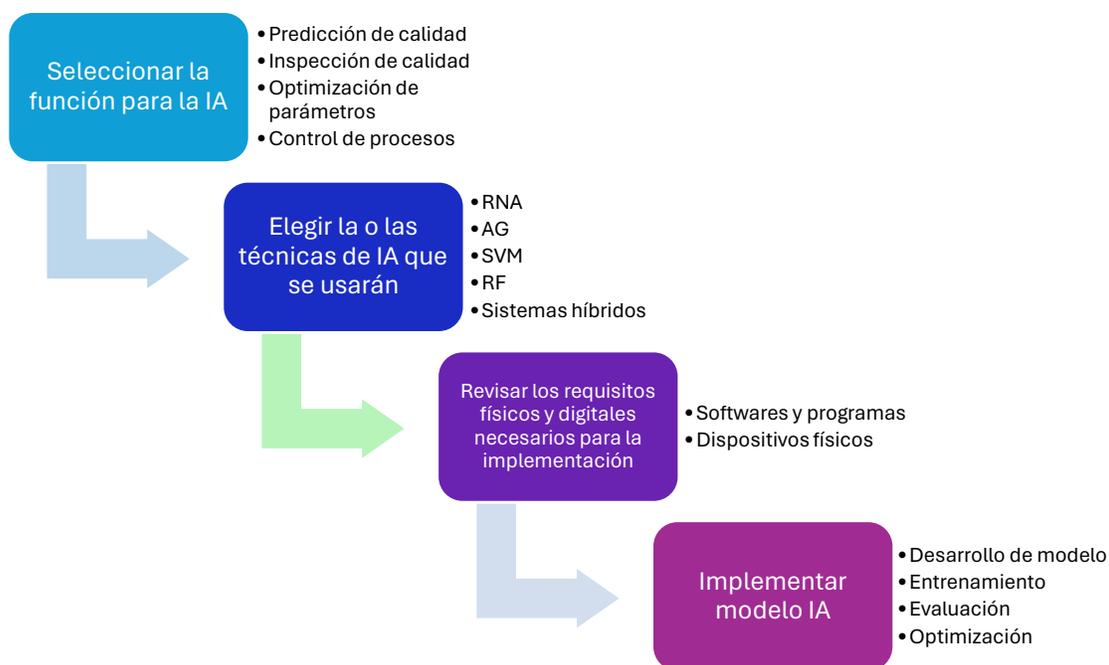


Figura 18. Proceso de implementación tecnológica propuesto.

4.1 Selección de función para la IA

En el capítulo 3 se describió de forma general el proceso de inyección y se delimitaron algunos retos de la industria de inyección, que más se han reportado en la literatura. Todos los rubros resultan de gran interés para su control, sin embargo, solo en algunos de ellos han sido abordados exitosamente con IA. Debido a esto, se seleccionaron aquellos retos que presentaron el mayor número de investigaciones relacionadas con la tecnología inteligente. Tales retos son: Gestión de personal (relacionados con la operación de máquinas e inspección de productos) y el funcionamiento de la máquina de inyección y parámetros de procesamiento. Con esta información se buscó identificar las funciones de la tecnología

inteligente que más se han abordado en la inyección de plásticos y que podrían ser incluidas en la metodología de implementación.

4.1.1 La labor humana y el procesamiento de máquinas

El papel que tienen las personas en las industrias manufactureras es de tal importancia, que muchas de las actividades que se llevan a cabo en ella no podrían realizarse sin su intervención. Actualmente, todos los procesos de la cadena de valor pueden relacionarse con alguna actividad humana. Específicamente las etapas de manufactura de productos calificados están basadas casi por completo en operaciones manuales (por ejemplo, el manejo de equipos y productos). Sin embargo, esta situación puede acarrear múltiples desventajas, como bajas eficiencias de producción, poca confiabilidad y repetibilidad de procesos, y dependencia de personal con experiencia en actividades específicas. Con el objetivo de disminuir las fuentes de riesgo, se han realizado estudios para desarrollar tecnología que mejore el control de los procesos productivos.

Inspección de calidad

La inspección de calidad se basa en el manejo y evaluación de los productos terminados; y sus resultados permiten garantizar el buen funcionamiento de los procesos y del cumplimiento de especificaciones de los productos. Por lo general, esta actividad se lleva a cabo de forma manual por el personal de la industria, no obstante, existe una serie de factores que pueden afectar su cumplimiento. El desarrollo de esta práctica se considera subjetivo, aunque se tenga estandarizado el proceso de inspección, ya que depende en gran medida de las condiciones del trabajo, el tipo de proceso y del estado general de las personas. El desempeño del personal depende de factores que son propios de los sujetos, como la fatiga, el estrés y otros factores motivacionales; no obstante, también las condiciones del área de trabajo influyen en su quehacer. En ocasiones, el número de empleados por plantas operativas no es suficiente para las actividades, lo que provoca que no se detecten defectos de forma oportuna. Por tal motivo, es imperante proveer instalaciones y ambientes laborales adecuadas que permitan el cumplimiento de objetivos y minimicen los errores de esta actividad.

Aunque la inspección manual es común en las industrias manufactureras, existen diversos inconvenientes relacionados a esta ella. Al ser un proceso de ciclos continuos, el tiempo que toma revisar los productos puede ser elevado, dependiendo el tipo de proceso que se tenga, el nivel de complejidad del producto y de las características que se deseen revisar. Además, la inspección se realiza solamente a un conjunto de productos, lo que no garantiza que la totalidad de la producción tenga la misma condición (considerando que el proceso puede tener fluctuaciones) [84]. El tiempo requerido en la inspección no solo repercute en la agilidad del proceso, también puede disminuir el tiempo de respuesta ante un imprevisto, y dar como resultado la generación de productos defectuosos [89]. Si se sigue produciendo y el resultado de una muestra es negativo, implicaría que lo que se produjo desde la toma de la muestra para inspección, hasta el punto actual del proceso, debe revisarse para validar su condición. Una forma de contener esta situación es por medio del desarrollo de herramientas

tecnológicas que disminuyan el tiempo de inspección y que sean capaces de mantener, e incluso incrementar, el nivel del análisis a los productos.

Algunos desarrollos con IA permiten inspeccionar físicamente los productos, desde que son producidas; o predecir el nivel de calidad de éstos, basados en la información de los parámetros de las inyectoras. Existe la posibilidad de inspeccionar de apariencia de la superficie, de acuerdo con las características del producto y el nivel de detalle con el que se desee examinar, como la homogeneidad del color o la aparición de rayaduras [22], [83], [84], [85]. Del mismo modo, se pueden utilizar las condiciones de inyección de la máquina para conocer la calidad del producto, observado por ejemplo en el peso de las piezas (el cual se puede relacionar con defectos de rebabas o piezas incompletas) [92], [94], [97], [103]. La implementación de tecnología con IA, de esta forma, cambia totalmente la forma tradicional de inspección, basada en la revisión por lotes, a una donde se puede revisar el 100% de los productos.

Manejo de máquinas

La operación de las máquinas es un proceso crítico en la etapa productiva, ya que si se desarrolla de forma correcta se pueden obtener procesos eficientes, con productos de alta calidad. En la etapa de producción, el ajuste de máquinas comienza con la programación de los parámetros de producción y la realización de pruebas de arranque, y continua con la implementación de ajustes que permitan la estabilidad del proceso y promuevan la conservación de las unidades que componen las máquinas de inyección, con el fin de no afectar su vida útil. Esta operación se realiza, generalmente, de manera manual y, al igual que la inspección, se relaciona con una serie de riesgos que pueden comprometer su desarrollo y afectar el funcionamiento de toda la organización.

El manejo de las máquinas de inyección, tradicionalmente manual, requiere personal con conocimientos adecuados sobre su funcionamiento y los factores que influyen en ellas. En este proceso, el personal elige los parámetros de inyección de acuerdo con el material y geometría del producto. Posteriormente evalúa su ejercicio con la calidad del producto y, en el caso de no cumplir con las especificaciones, debe corregir los parámetros de forma iterativa, hasta alcanzar la calidad deseada [116]. Este proceso es básico para cualquier producto que se inyecte, no obstante, el exceso de trabajo, la falta de experiencia en el procesamiento de diversos productos, problemas motivacionales, entre otros, hacen que esta actividad se vuelva más compleja de ejercer. Las consecuencias de una mala operación de las máquinas, no solo recae en la generación de desperdicio y baja productividad, también puede comprometer la funcionalidad de las máquinas y, aún más grave, la integridad de las personas.

El tiempo que los operadores de máquinas invierten, para ajustar los parámetros y conservar el nivel de producción, depende en gran medida a la dificultad del proceso. Resulta complicado correlacionar las variables de operación de la máquina de inyección y los resultados que se puedan conseguir, debido a la gran cantidad de parámetros y elementos que componen las inyectoras, y al comportamiento de los diversos materiales.

La obtención de ajustes óptimos de las máquinas, en muchas ocasiones, implica la dependencia de personal experto que, con base en su conocimiento y al manejo de manuales de optimización, realiza modificaciones en la máquina que ayudan con el restablecimiento del proceso. Esta situación implica, que en el proceso sea indispensable contar con personal experto disponible en cualquier momento de la operación. Lo anterior se complica cuando existen máquinas que trabajan simultáneamente y no se cuenta con personal suficiente para revisarlas o que no tenga el nivel de experiencia suficiente en todas las máquinas y procesos. Para abordar tal situación, se han elaborado sistemas capaces de alertar a las personas cuando se presenta algún problema o de permitir a la máquina ajustar sus parámetros autónomamente, de tal manera que el tiempo que se invierta en revisar, diagnosticar y corregir el proceso sea mínimo [22], [77], [78], [79], [87], [101].

4.1.2 Parámetros de procesos y condiciones de proceso.

El control y manejo de las máquinas de inyección resulta complicado, desde el punto de vista técnico, por la complejidad del procesamiento, los materiales termoplásticos y del mismo proceso de inyección. En la literatura se menciona que en las máquinas de inyección existen más de 100 parámetros que intervienen en el proceso [10]. Esto ha dificultado la comprensión del procesamiento, por la influencia desproporcionada entre cada parámetro y la inyección; y la descripción de la relación que existe entre ellos, debido a que no interactúan de forma lineal [22]. Por otra parte, el proceso de inyección no permanece constante durante la producción, debido a fluctuaciones en el ambiente, a la manipulación de las máquinas o por el comportamiento del material. Lo anterior hace que la inyección de plásticos sea impredecible y que los análisis matemáticos y modelos de simulación no siempre sean totalmente precisos [22], [50].

Con el fin de tener eficiencia en el proceso y elaborar productos con calidad consistente, es fundamental tener control de los parámetros y del funcionamiento de la máquina de inyección [69]. No obstante, en la inyección de plásticos, los estados del proceso no son directamente observables y hay muchas incertidumbres que afectan estos objetivos [22]. Las consecuencias principales de no tener control en los procesos son la fabricación de productos con defectos y desperdicios; y la ocurrencia de paros de máquina. Si estas situaciones no se detectan y corrigen oportunamente pueden comprometer el rendimiento de la industria y afectar su posicionamiento en el mercado, por el gasto de recursos e insatisfacción de clientes. Por lo tanto, es primordial identificar oportunamente el origen de esta situación y, además, decidir la mejor forma de regresar al estado óptimo del proceso.

Actualmente, algunas investigaciones tecnológicas se han enfocado en el estudio de los parámetros de inyección, su correlación entre ellos y en la influencia que tienen en el producto; con el fin de conseguir un mayor control de proceso [69]. Con este objetivo, se han buscado innovaciones que facilitan el diseño, la medición, y el monitoreo del proceso, de tal modo que garanticen su consistencia y repetibilidad (observado en los indicadores de producción y en el grado de calidad de los productos) [69], [90].

El uso reciente de simuladores ha permitido conocer mejor la inyección de plásticos y, como consecuencia, ha hecho posible conseguir ajustes en menor cantidad de intentos. El inconveniente de esto es que la simulación requiere la presencia de expertos, de lo contrario esta actividad puede ser complicada y lenta de realizar, debido a la complejidad de los programas y al tiempo que toma la formulación y ejecución del software entre una simulación y otra [117]. Incluso la simulación puede generar resultados con alta incertidumbre, lo que provoca que en la prueba física en la inyectora se generen desperdicios y que se deban realizar más simulaciones para alcanzar valores aceptables.

En la bibliografía se ha reportado que la tecnología basada en inteligencia artificial es una buena opción para lograr el control de los procesos de inyección, ya que es capaz de extraer información directa de producción y desarrollar métodos de optimización y estrategias de control que promuevan el cumplimiento de estos objetivos [91], [117]. En los artículos recopilados en el anexo 1, se observan diversas funciones que se han abordado con la IA, dentro de los retos de gestión de personal y procesamiento de máquinas. Estas funciones son: el monitoreo, control y optimización de parámetros, predicción de calidad e inspección computarizada (de productos y equipos).

4.1.3 Principales funciones de la IA: monitoreo, control y optimización de parámetros; predicción e inspección de calidad.

Algunos de los objetivos principales en la implementación de tecnología con IA es crear un sistema de producción capaz de incrementar la calidad de productos, la eficiencia de producción y la seguridad del personal relacionado a los procesos [84], [117]. La forma tradicional de manufactura está rodeada de factores que comprometen la eficiencia y calidad de las organizaciones. Los modelos de *machine* y *Deep learning* han probado ser eficientes, rápidos y confiables en tareas de predicción, clasificación y optimización. Mediante su uso, se ha buscado tener mayor control del proceso, al combinar técnicas de IA, herramientas de procesamiento y captura de datos (como los sensores), con las etapas del proceso de inyección [76], [110].

Dentro de las áreas que más se han estudiado del proceso de inyección son el monitoreo, control y optimización de los procesos. Como se mencionó anteriormente, la dificultad de este procesamiento se debe a la influencia que tienen en él, un gran número de factores provenientes de la máquina de moldeo, el material de inyección y la estructura del molde. Esta situación ha llevado a la investigación a buscar herramientas, como la IA, para comprender y describir mejor el proceso de inyección y que, de esta forma, sea posible disminuir el esfuerzo humano para encontrar las fuentes de las variaciones, evitar problemas y, en el mejor de los casos, conseguir los mejores parámetros para trabajar.

En el anexo 1 se presenta un compendio de artículos que pertenecen a los retos relacionados con las actividades realizadas por el personal, en el área de inyección; y el funcionamiento y operación de las máquinas inyectoras. Con base en el contenido de cada investigación recopilada, los artículos se clasificaron en diversas funciones, con el fin de reconocer aquellas que han sido más abordadas para la implementación de inteligencia artificial. Considero que

este reconocimiento es importante, ya que ofrece un punto de partida a la hora de decidir una función específica para la IA que se quiera desarrollar en los sistemas de producción.

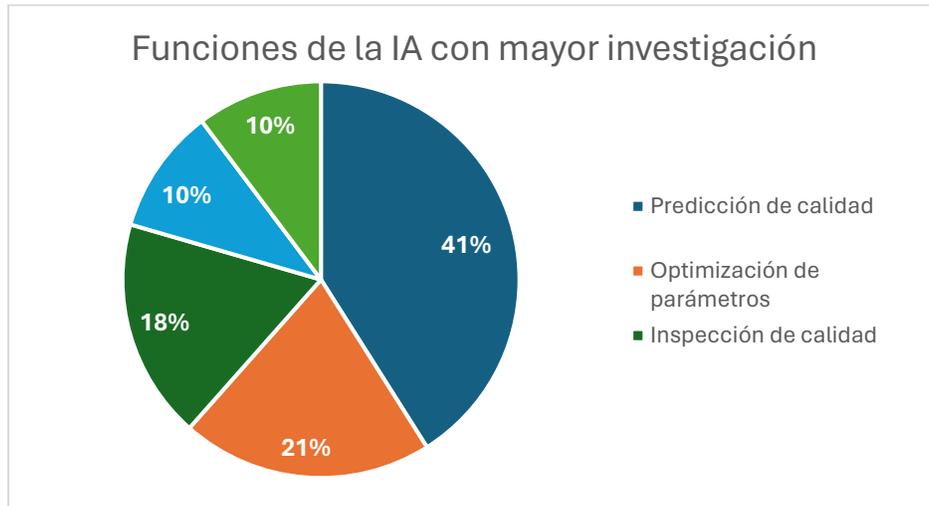


Figura 19. Gráfica que expone las áreas del proceso de inyección con mayor frecuencia de investigación.

La figura 19 se obtuvo de la clasificación de los estudios sobre IA en la industria de inyección. En ella se puede observar que la predicción de calidad es la función con mayor desarrollo en la implementación de tecnología inteligente. Resulta importante desarrollar modelos que permitan analizar eficientemente y rápidamente los parámetros del proceso, con el fin de anticipar la calidad de las piezas inyectadas. Lo anterior debido a la dificultad de analizar el desarrollo del proceso, por las relaciones no lineales entre los parámetros y sus efectos en el producto; o al comportamiento impredecible del material ante las fluctuaciones de los parámetros, resulta [108]. Con la predicción inteligente se busca identificar rápidamente las piezas defectuosas en función de la evolución de algunos parámetros de la máquina. El uso de la inteligencia artificial con esta función permite estudiar las variables del proceso en tiempo real y, con sus resultados, anticipar y reportar los resultados que se generarán, es decir, predecir si se inyectará adecuadamente o se producirá algún defecto, antes que se produzca la pieza.

Con la predicción de calidad se busca cambiar el enfoque reactivo de la mayoría de las industrias, en donde los defectos se corrigen hasta que se detectan, a una estrategia en donde se detectan e intervienen los problemas incluso antes de que ocurran. Como se mencionó anteriormente, el proceso de inyección tiene diversos factores que impiden alcanzar un estado de calidad constante, como la falta de relaciones consistentes entre los parámetros del proceso, las propiedades del material y la calidad de las piezas. Los defectos que ocurren en los productos no siempre se detectan a tiempo, debido a que los defectos no son fáciles de descubrir o porque las personas involucradas en esa máquina pueden estar ocupadas con otras actividades que requieren su atención [113], [110]. La predicción de calidad hecha con IA ayuda a incrementar la capacidad de respuesta y facilita el ajuste de parámetros, ya que permite detectar oportunamente los parámetros que están afectando el rendimiento del proceso. Con su implementación se puede ubicar precisamente los elementos que no cumplen

con la calidad esperada, de tal forma que no sea necesario retener material correctamente elaborado.

El segundo lugar de las funciones más investigadas en este tema es la optimización de procesos, con el 21% de intensidad de investigación. Generalmente, el proceso para producir piezas con alta calidad (ya sea durante el arranque de producción o a lo largo de la fabricación) se hace mediante métodos de prueba y error, en el cual se hacen ajustes a la máquina hasta alcanzar el objetivo planteado. Aunque actualmente se pueden utilizar simuladores para encontrar una buena combinación de parámetros, aún es un proceso complicado, tardado y que requiere expertos para realizarse exitosamente [99].

Las tecnologías dedicadas a la optimización se utilizan para conseguir la configuración de los parámetros más adecuada, con la cual se tienen las mejores propiedades mecánicas de los equipos del proceso, al mismo tiempo que se fabrican productos de alta calidad. Los resultados de este proceso incluyen la reducción del desperdicio de materiales y tiempo durante el procesamiento; y la disminución de defectos de las piezas producidas. De este modo, se desea que los modelos que se utilicen puedan analizar e interpretar las interrelaciones que hay entre los parámetros y las especificaciones del producto y, además, que sean capaces de sugerir el mejor conjunto de variables para trabajar. Las técnicas basadas en ML han mostrado viabilidad para adaptarse al comportamiento no lineal de los procesos de inyección y ajustarse a las relaciones entre los parámetros de entrada y salida, con el fin de optimizar procesos y diagnosticar fallas [97]. Su implementación ha ayudado a encontrar los parámetros más adecuados para trabajar y, en algunos casos, se ha adicionado la función de ajustar las inyectoras de forma autónoma.

Se ha reportado que el funcionamiento de los optimizadores inteligentes está enfocado en sistemas de un solo objetivo, en donde se busca mejorar alguna característica del producto o reducir algunos de sus defectos. Si bien, estos sistemas ayudan a mejorar la operabilidad en el proceso, aún es posible aspirar a mejorar la eficacia de la optimización. Recientemente, uno de los objetivos más buscados con esta función es poder elegir varios factores de operación como metas para el funcionamiento del modelo. De esta forma se podrían contemplar diferentes elementos, como el consumo energético o el ciclo de producción, además de las características del producto, haciendo las herramientas más completas y relacionadas estrechamente a procesos reales [99].

La inspección de calidad es la tercera área más investigada en la implementación de IA. Su funcionamiento consiste en revisar directamente características específicas de los productos. El riesgo de no cumplir con los objetivos en la inspección tradicional, derivada de los factores humanos y las condiciones laborales, han hecho que los sistemas con IA sean una opción atractiva para implementación de sistemas de inspección computarizada.

La ventaja de este tipo de dispositivos radica, no solo en el desempeño constante de sus funciones, sino en la capacidad de incrementar la capacidad de revisión, al poder revisar la totalidad de los productos y verificar detalladamente algunas características que pueden ser desapercibidas de forma tradicional. La inspección inteligente representa un cambio importante de la revisión manual, ya que permite informar la presencia de defectos en tiempo

real, y complementarse con otras funciones que facilitan la toma de decisiones para corregir problemas. Además, como lo menciona Chouchene, A. et al. en [84], la inspección con IA también puede ayudar a los procesos de ensamble, ya que puede reconocer materiales y superficies, clasificar e identificar partes antes de ensamblar y ayudar a reconocer la mejor posición para ello.

El cuarto punto que más ha atraído la atención de los investigadores para el desarrollo de inteligencia artificial es en el control de procesos. Su principal función es mantener una producción consistente y eficiente, por medio del análisis oportuno del proceso y la localización de fallas y oportunidades de mejora. En la literatura se reporta que los sistemas basados en IA han presentado avances en la detección de productos defectivos, predicciones rápidas y clasificación de productos (de acuerdo con su nivel de calidad), mediante el uso de datos del proceso, obtenidos a través de sensores en tiempo real [76]. Estos sistemas funcionan al visibilizar las variables clave de cada etapa del proceso y, mediante unidades externas, volverlas controlables para su ajuste. En caso de encontrar algún problema o un riesgo de error, estos sistemas tienen como objetivo detectar el punto de crítico y responder autónomamente para evitar llegar a una situación de riesgo (mediante el ajuste de sus parámetros) [77], [78], [79].

Los beneficios que se tienen de los sistemas de control son muy atractivos, sin embargo, aún es un tema en desarrollo, debido a la complejidad del proceso y los parámetros de entrada y salida que se relacionan a él [79]. Esto se puede observar en la figura 19, donde el control de procesos tiene menos investigaciones realizadas en la implementación de tecnología con IA, comparado con funciones anteriores. Cui, Z. y Wang, J. realizaron un sistema inteligente para controlar las unidades de inyección [77]. Ambos autores remarcan que, aunque el control de procesos es importante, en la actualidad se abordan funciones específicas (como la inspección) de forma independiente, debido a la dificultad de controlar en red varias máquinas de inyección.

Dentro del rubro “otros” de la figura 19, se incluyen otras áreas de producción, como planeación de producción, diseño de parámetros, monitoreo de procesos, inspección de moldes y cuidado y protección de componentes de equipo. Estos campos, aunque han sido estudiados en la implementación de IA, se puede considerar que están aún en desarrollo, debido a la poca cantidad de investigaciones que se tienen disponibles. No obstante, resulta importante mencionar de qué forma la tecnología inteligente está interviniendo en estos sectores y cuáles son los beneficios de su implementación. Las funciones que componen este rubro son:

- Revisión de moldes:
 - 1) Inspección de superficies: similar a la inspección de los productos, se basa en la examinación mediante un sistema de visión computarizada. Debido a la delicadeza de la superficie y a la relación directa que tienen con la calidad de los productos, resulta necesario desarrollar sistemas que permitan evaluar el estado en el que se encuentran los moldes. En [89] Librantz et al. elaboraron un modelo capaz de mapear la superficie pulida de los moldes, y de detectar y clasificar los daños que podrían estar en ella. Este

sistema pretende ser una alternativa a la inspección tradicional de los moldes, lo que puede reducir el costo y el tiempo dedicado a esta tarea.

2) Valoración del tiempo de vida del molde. En general, los componentes de las inyectoras, al estar en procesos cíclicos que varían constantemente, están propensos a la degradación continua. Con el uso de inteligencia artificial, especialmente en los moldes, se ha buscado identificar el nivel de degradación y, con ello, estimar su tiempo de vida útil restante. Böttjer et al. en [80] desarrollaron un modelo con la capacidad de clasificar el nivel de desgaste del molde, por medio de datos de producción. Dicha cuantificación resulta importante para mejorar las actividades de mantenimiento preventivo que permiten extender y conservar el tiempo de vida del molde, como la limpieza o el reacondicionamiento; y minimizar los tiempos de inactividad y la generación de desperdicios, debido a situaciones no planificadas.

- En el diseño de parámetros se busca definir y establecer un punto de partida para la producción, que derive en artículos de buena calidad. De este modo, de acuerdo con el nivel de precisión que ofrezcan los parámetros iniciales de producción, serán los ajustes posteriores que se harán a la máquina. Si esta actividad se realiza de manera adecuada, los ajustes que se realicen inmediatamente después del arranque serán menos. El uso de IA en este tema aprovecha las funciones de algunas técnicas, como CBR (razonamiento basado en casos), donde los modelos recuperan casos anteriores, de una biblioteca de casos y, por medio de reglas de modificación, adapta las soluciones de esos trabajos para proponer nuevas condiciones de producción [81], [82].
- Monitoreo de procesos. Esta actividad se encarga de revisar las condiciones de las inyectoras durante todo el proceso, con el fin conocer el funcionamiento real del proceso y del nivel de calidad del producto que se está elaborando. Debido a que durante la inyección pueden ocurrir diversos problemas de calidad, por la dinámica no lineal del proceso, es importante identificar rápidamente cuando se presenta alguna situación crítica y solucionarla. El reconocimiento oportuno de eventos no deseados ayuda a la eficiencia del proceso, no solo para reducir el esfuerzo humano en encontrar las fuentes de los problemas, sino también en evitar el progreso del evento, al reducir el tiempo invertido en la detección de problemas y toma de decisiones [22].

En general, aunque las investigaciones encontradas están relacionadas a diversas funciones, la mayoría de ellas están basadas en el monitoreo de producción. Para lograr el monitoreo eficiente en sus sistemas inteligentes, es necesario que los modelos capturen y analicen, en tiempo real, los patrones significativos de la operación. De los artículos localizados, solo se encontró uno que se dedica exclusivamente al monitoreo de procesos. El estudio realizado por Tsai, Hsu y Chang [90] se enfocó en desarrollar un sistema de monitoreo, basado en la visión artificial. Su objetivo era reconocer y procesar la información contenida en los paneles de control de diversas máquinas de inyección, y finalmente, transmitir sus resultados para el monitoreo general de las máquinas. En el estudio se menciona que el reconocimiento de dígitos del panel operación puede ser el primer paso en el estudio de operación de las inyectoras, ya que existen más elementos que también se pueden incluir en análisis de los procesos, como el estado de

interruptores, señales de luz, punteros, gráficos de barras, contadores mecánicos, textos, etc., que se encuentran en otros dispositivos de control.

Aunque el monitoreo de procesos puede contemplarse como un acercamiento a la inteligencia artificial en las industrias, con el resto de las investigaciones reportadas se remarca la posibilidad de integrar sistemas inteligentes que puedan tener más funciones.

- La planeación de actividades de operación corresponde a la asignación de trabajos a un conjunto de máquinas. Su objetivo consiste en delimitar el uso óptimo de los recursos disponibles, considerando las restricciones de elegibilidad de las máquinas y otros elementos que intervienen en el proceso. La programación tradicional de actividades considera a la máquina como el único recurso que se debe contemplar [100], sin embargo, con las tecnologías inteligentes se propone adicionar más factores, como la mano de obra, herramientas disponibles, materia prima, entre otros (los cuales son utilizados en el proceso y también pueden estar restringidos). Esta consideración vuelve el proceso de programación más realistas y prácticos para implementar.

Las restricciones originadas por la reciente pandemia de COVID-19 han orillado a todas las industrias a buscar nuevas formas de programar las actividades del personal, considerando el distanciamiento físico que se recomienda para proteger su salud. Ante esta situación, Bazargan-Lari, et al. desarrollaron un modelo capaz de programar las actividades de inyección, considerando el distanciamiento entre el personal recomendado por pandemia, la calidad de las piezas y el beneficio productivo [72]. En el estudio se remarca que, en la programación de operaciones de inyección es difícil contemplar gran parte de los factores que influyen en el proceso, como las cavidades del molde, las especificaciones de cada equipo de inyección (como su tasa de producción), el tiempo de preparación de las máquinas entre cambios de una producción a otra, el pretratamiento de los materiales, etc. No obstante, mediante la IA, estos elementos, además de la distribución de los operadores, se pueden integrar los modelos de planeación de la producción diaria, los cuales ofrecen información del tipo de pieza que se debe producir en determinada máquina y el intervalo de tiempo diario que requerirá para ello.

En gran parte de los artículos recabados se menciona el manejo de una función para la inteligencia artificial (incluso se manejan dos, para los casos donde incluyen también el monitoreo de procesos). No obstante, también se puede apreciar una búsqueda para que las tecnologías puedan tener más enfoques, con el fin de acercarse a la creación de industrias más autónomas. En la mayoría de las investigaciones se percibe el control de procesos como un paso a futuro en la implementación de cualquier IA. Por ejemplo, en el caso de los predictores de calidad se propone, después de anticipar la producción de piezas incorrectas, usar controladores para ajustar automáticamente los parámetros a valores de operación óptima [108]. El trabajo realizado por Lau, H. et al. [94] está enfocado en la optimización de parámetros y predicción de calidad, sin embargo, su desarrollo está relacionado directamente con el control del proceso. En este caso el sistema, cuando predice un defecto o una disminución en la calidad del producto, genera una sugerencia de la mejor combinación de parámetros que puede minimizar las variaciones del proceso. A pesar de que cubre una forma de control del proceso, menciona que el siguiente paso consistirá en implementar el sistema

en los controladores de la máquina, para que realice de forma autónoma los cambios en sus parámetros.

La información proveniente de las investigaciones ayuda a contemplar las diversas funciones que más se han abordado en el desarrollo tecnológico. Estos estudios han demostrado la posibilidad de integrar exitosamente tecnología con IA en los procesos de inyección. Tan solo en las áreas relacionadas con la operación de máquinas y gestión de las actividades del personal se han encontrado diversos alcances donde el uso de tecnología inteligente ha ayudado a facilitar y mejorar las actividades que tradicionalmente son realizadas de forma manual. Con base en el análisis del conjunto de artículos, las inyectoras que deseen acercarse a las innovaciones de la industria 4.0 tienen más elementos para decidir, a partir de sus necesidades y objetivos, la función que podría cubrirse con inteligencia artificial.

Los rubros donde se incluye la IA son muy específicos, como la predicción de calidad o la optimización de procesos, no obstante, existen estudios donde se ha buscado combinar distintas funciones en un mismo sistema. Considero que, para las industrias que buscan adentrarse en la industria 4.0, el cumplimiento de una función es adecuado para comenzar a percibir mejoras en sus rendimientos. Una vez que la organización se haya familiarizado con estas innovaciones resulta importante plantear la réplica del desarrollo en toda la planta operativa y mejorar las funciones de los sistemas inteligentes.

4.2 Procedimiento y recursos necesarios para la implementación

Anteriormente se describieron las funciones que se han abordado con mayor frecuencia tecnología la inteligencia artificial, en la inyección de plásticos. Como siguiente paso, resulta necesario analizar y exponer las técnicas de IA que más se están empleando, los recursos (programas y equipos), y la metodología general que se requiere para su implementación. En los siguientes apartados se mencionan estos elementos y se describen algunos otros puntos que son necesarios para que los modelos inteligentes puedan funcionar correctamente. Finalmente se presenta la gama de resultados que se ha reportado a partir de la implementación de IA en este sector industrial.

4.2.1 Técnicas de inteligencia artificial

Las investigaciones que se han realizado para llevar a las industrias a la fabricación inteligente han derivado en el desarrollo y especialización de las técnicas de inteligencia artificial. Se puede apreciar que estas técnicas han podido implementarse en varias etapas de la línea de producción, desde el diseño, la producción, hasta los servicios de atención con los clientes. Cualquier actividad en donde se integre, se busca que los sistemas con IA, a través de métodos de detección, optimización y control, puedan mejorar la eficiencia de producción

y calidad del producto [117]. Por lo tanto, definir y aplicar la técnica correcta es indispensable para cumplir con los principales objetivos de producción.

Los sistemas inteligentes para el moldeo por inyección, basados en las funciones planteadas en el punto anterior, constan generalmente de tres fases: detección, control y optimización. En la detección se desea que los sistemas perciban y colecten, en tiempo real, las variables del proceso que tenga programadas y, posteriormente, analicen y diagnostiquen las características del proceso. Con el control de las actividades se pretende tener repetibilidad y precisión del funcionamiento del modelo y de las máquinas, con el fin de conservar la estabilidad de la fabricación. La optimización busca determinar las mejores condiciones de inyección para alcanzar los objetivos planteados (alta calidad o mayor productividad) [117]. Cualquier modelo que se desee implementar con alguna técnica de IA debe incluir, por lo menos, los dos primeros para que sea efectivo su funcionamiento. En la figura 20 se presentan las proporciones de las técnicas de IA más utilizadas en la industria de inyección de plásticos

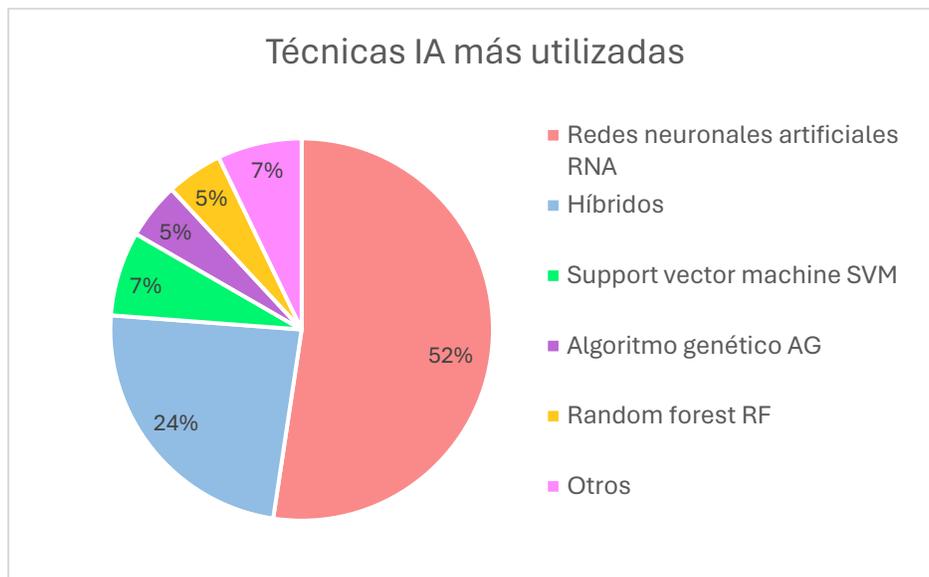


Figura 20. Técnicas IA más utilizadas en la inyección de plásticos.

Redes neuronales artificiales

Las redes neuronales artificiales (RNA) ocupan, con el 52%, el primer lugar de las técnicas de IA más utilizadas. Esta técnica ha demostrado ser capaz de correlacionar los parámetros y los objetivos del proceso. Es por ello que, con los artículos recopilados en el anexo 1, se puede observar que su uso en el proceso de inyección abarca la mayoría de los retos delimitados, principalmente en las funciones relacionadas con la predicción, optimización, e inspección.

Las RNA son un tipo de modelo de IA, ampliamente utilizado, capaz de combinar varias funciones no lineales y capturar de ellas las relaciones no lineales entre los datos de entrada y una etiqueta [118]. En general, la estructura de la RNA se compone de tres tipos de capas: una de entrada; una o más capas ocultas y una de salida. Cada una de ellas está compuesta por unidades de procesamiento, nodos o neuronas, que están interconectadas entre sí. Estos

modelos se clasifican según su estructura y el propósito que persiguen. De acuerdo con los artículos recopilados de las bases de datos se puede observar que los tipos de RNA más utilizados en la industria son: perceptrón multicapa y redes convolucionales.

- El Perceptrón multicapa (MLP por sus siglas en inglés de *multilayer perceptron*) es una red neuronal de avance general y aprendizaje supervisado. Esta clase de RNA se compone de una capa de entrada y de salida; y de una o varias capas ocultas. Este tipo de modelo se basa en una secuencia de capas de neuronas interconectadas entre sí, donde se activa el mapeo capa a capa con una función de activación. Su implementación se puede observar especialmente en las tareas de predicción de calidad debido a su buen modelado de funciones complejas y su capacidad de adaptarse a diversos dominios, por su flexibilidad en su arquitectura [22], [113].
- Las redes neuronales convolucionales, RNC, son similares a las MLP, pero se utilizan principalmente en el campo de visión computarizada, por su capacidad de extraer patrones jerárquicos en el reconocimiento de imágenes y videos [119], [22]. Las RNC pueden encontrar relaciones locales y de composición dentro de los datos de entrada, a través de la aplicación de varias capas convolucionales y otras capas de agrupación. Su aplicación se asocia especialmente a la inspección de calidad, en donde se revisan y clasifican algunas características de los productos por medio de imágenes.

Existen otros tipos de redes neuronales que también se están utilizando en la industria de inyección, estas son las multicapas recursivas y Resnet. Aunque no han sido utilizadas considerablemente en las investigaciones recopiladas, los resultados que se consiguen con ella reflejan un buen desempeño.

- Las redes neuronales residuales, ResNet por sus siglas en inglés de *Residual network*, es un tipo de configuraciones relacionado principalmente por su eficiencia en el reconocimiento de imágenes [83]. Debido a ello, en la inyección de plásticos, se ha utilizado en la inspección de calidad, para funciones de visión computarizada. Las ResNet han demostrado tener capacidad para extraer características de imagen de regiones de interés, mediante conexiones “de salto” o “atajo” para moverse entre varias capas hacia la salida. Dichos saltos incrementan la agilidad de la red, haciéndola más simple, y aceleran el aprendizaje, disminuyendo los efectos de desaparición de gradiente [120].
- Las redes neuronales recurrentes, RNN por sus siglas *Recurrent neural network*, se caracterizan por procesar una secuencia de valores de series de tiempo para hacer predicciones sobre resultados. Estos modelos toman como entrada los valores de marcas de tiempo pasadas y predice valores de la próxima marca de tiempo o el valor de una marca más en el futuro [110], [118]. Se puede observar su uso en proyectos relacionados con la predicción de calidad.

El papel que tiene la estructura de la red neuronal es de gran importancia, ya que su correcta configuración facilitará el grado de convergencia del modelo o dará lugar a un algoritmo defectuoso, que sobreajuste los datos [105]. Dentro de la estructura de las redes neuronales, la capa de entrada incluye un nodo por cada parámetro que se define influyente del proceso.

En la o las capas ocultas, por lo general, el número de neuronas es especificado por los usuarios. Por último, las neuronas de la capa de salida representan los objetivos de la red [105], [111]. Las conexiones entre los nodos de las diferentes capas tienen diferente valor de peso, generado durante el entrenamiento, el cual determina la fuerza de señal transportada a través de los enlaces [111].

La delimitación de la estructura debe realizarse correctamente, ya que se ha encontrado que, por ejemplo, los sistemas MLP con demasiados nodos y capas pueden requerir numerosos cálculos para conseguir valores de ponderación, lo cual puede causar divergencias entre los valores predichos y los reales. Por lo contrario, una estructura con pocos elementos puede no generar conexiones correctas entre las capas de entrada y salida y, por lo tanto, los valores predichos pueden ser inestables [102]. Por lo tanto, es indispensable definir la configuración correcta para asegurar la calidad de funcionamiento del modelo.

En la tabla 6 se muestran algunas de las estructuras empleadas en los estudios de implementación de IA. En ella se puede apreciar una gran variedad de configuraciones en las redes neuronales, debido a los diversos retos industriales que se tratan y el tipo de red neuronal que utilizan.

Tabla 6. Tipo de RNA y estructura de red, utilizadas en la industria de inyección de plásticos

Referencia bibliográfica	Reto industrial	Tipo de RNA	Estructura	
			Capas	Configuración
[83]	Inspección	RNC	50	
[85]		ResNet	8	
[86]		RNC	8	
[89]		MLP	3	6\12\4
[90]	Monitoreo	ResNet	50	
[91]	Optimización	BP	3	7\13\6
[93]		BP	3	4\6\1
[96]		BP	4	6\10\10\1
[97]		RNA	3	6\7\1
[99]		BP	4	5\9\9\2
[102]	Predicción	MLP	3	4\4\3
[103]		MLP	7	5/10/10/10/10/10/1
[105]		MLP	4	5/(32-256)/(32-256)/1
[106]		MLP	4	6\20\20\1
[107]			4	5\3\3\1
[108]		BP	3	9\8\1
[111]		MLP	3	9\9\2
[115]		RNA	3	5/200/2

Los estudios recopilados coinciden en la forma de establecer los nodos para la capa de entrada y de salida. Dicha delimitación se realiza de acuerdo con los parámetros que más influyen en el problema planteado y los objetivos del modelo, respectivamente. No obstante, las

variaciones más significativas ocurren en la delimitación del número de neuronas y capas ocultas.

Aunque se han propuesto criterios y métodos para determinar el número de capas y neuronas ocultas [108], en general, este tipo de capa es seleccionada por los usuarios. Debido a esto, podemos ver una gran variedad de elementos en la estructura de RNA. Por ejemplo, se puede observar en la tabla 6 que las redes ResNet presentan la mayor cantidad de capas ocultas. Las MLP, en la predicción de calidad, no presentan tantas capas como las RNC o ResNet, sin embargo, el número de neuronas que utilizan las capas ocultas pueden ser elevadas (como en el caso del estudio hecho por Silva, Sousa y Alenya, en donde su sistema estaba compuesto por una capa oculta con 200 nodos) [115]. Ke y Huang, por su parte, mencionan que el número de capas ocultas suele estar determinado por el número de intervalos de calidad que se buscan solucionar [102]. Sin importar la red que se decida implementar, es importante ver que la selección de la estructura no tiene una fórmula específica para obtener buenos resultados. Esto lo podemos observar al comparar las estructuras de un mismo tipo de red, por ejemplo, en el estudio hecho por Ke y Huang, implementaron una red MLP, con configuración 4/4/3, para realizar predicciones de calidad; mientras que en la investigación hecha por Kim et al. [103] para la misma función de predicción, aplicaron una estructura 5/10/10/10/10/10/1.

Además del estudio de la estructura y el tipo de red neuronal, se debe poner atención en la configuración del modelo, ya que su funcionamiento y eficiencia están influidos por la programación que se le realice. El estudio de los hiperparámetros⁴⁸ que componen los modelos de RNA permite crear una referencia sustentada para elegir la forma en que desarrollará el modelo inteligente. En la tabla 7 se presentan algunos hiperparámetros que fueron utilizados en la elaboración de las RNA, de los artículos expuestos en el Anexo 1.

Tabla 7. Principales hiperparámetros empleados en las tecnologías con IA para la industria de inyección de plásticos.

Referencia	Reto industrial	Tipo de red	Función activación	Ubicación de función	Optimizador	Tasa de aprendizaje	Función de pérdida	Número de épocas/ciclos
[76]	Control de proceso		ReLU	Capas ocultas	Optimizador Adam	0.0001	Error absoluto medio	100
			Lineal	Capa de salida				
[86]	Inspección de calidad	RNC	ReLU	-	Optimizador Adam	0.0001	-	100
[85]		RNC	ReLU	-	Optimizador Adam	-	-	-
			Lineal					
[89]		MLP	Sigmoidal	-	-	0.1	-	-
		lineal						

⁴⁸ Los hiperparámetros son parte de los algoritmos de *machine learning* y se utilizan para ajustar y controlar el proceso de entrenamiento de un modelo. Dichos hiperparámetros se pueden configurar manualmente y optimizar mediante prueba y error. A diferencia de ellos, los parámetros de los modelos son elementos internos, derivados de manera automática durante el proceso de aprendizaje (su configuración no es hecha por las personas) [121], [122].

[90]	Monitoreo de parámetros	ResNet	ReLu	Capa convolucional	Optimizador Adam	-	L2 o error cuadrático medio	100	
			Softmax	Capa salida					
[91]	Optimización de parámetros	BPRNA	Lineal	capa oculta	-	-	-	-	
				tanh					Capa salida
[93]			BPRNA	Sigmoidal	Capa oculta/salida		0.01		2000
[96]		BPRNA	Sigmoidal	Entre entrada y oculta	-	-	-	-	
			Lineal	Entre oculta y salida					
[97]		RNA	Elu	Entrada y oculta	RMSProp	-	-	-	2000
	Lineal		Salida						
[103]	Predicción de calidad	MLP	ReLu	-	-	0.001	-	30	
[102]		MLP	Sigmoidal	Capa oculta	Descenso de gradiente estocástico	0.1	Entropía cruzada categórica	5000	
			Softmax	Capa salida					
[106]			MLP	ReLu	-	Optimizador Adam	0.001	-	50
[107]			BPRNA	Sigmoidal	-	-	0.01	-	1000000
[108]			BPRNA	Sigmoidal	-	-	0.7	-	25000
[110]			RNR - LSTM	Sigmoidal	Capa de salida	-	-	entropía cruzada	-
[112]			RNC - LSTM	ReLu	-	Optimizador Adam	0.001	L1	100
[113]			MLP	Sigmoidal	-	-	-	-	-

Generalmente, las redes neuronales constan de una fase de alimentación hacia adelante y una fase de retropropagación, o *backpropagation* (BP). En la primera los datos de entrada se propagan hacia adelante, mediante la multiplicación de los parámetros de los nodos de la entrada, por el peso de la línea de conexión y la adición del resultado al valor de sesgo específico del nodo de la capa oculta. Después, este valor pasa por una función de activación y se adiciona el peso asignado a la línea de conexión entre el nodo de la capa oculta y el de la capa de salida. La suma se compara con el punto de datos experimental, en forma de una función de pérdida que penaliza la predicción incorrecta. Debido a que cada conexión tiene su propio peso, relativo a la importancia de la entrada, si una entrada es más importante que otra, tendrá mayor efecto sobre el procesamiento de la neurona que, al combinarse con las otras entradas, producirá una respuesta que transmitirá a la siguiente capa, hasta la salida. Los pesos o coeficientes determinan la intensidad de la señal y son una medida de la fuerza de una conexión con la entrada [105]. En la segunda fase, se aplica el algoritmo de aprendizaje BP, en donde la derivada de la función de pérdida, con respecto a cada peso se calcula en la dirección inversa, es decir, la salida obtenida se compara con la salida deseada, produciendo una señal de error. Este error se propaga de la capa de salida a la de entrada. Finalmente, los pesos sinápticos de las neuronas se ajustan para encontrar los pesos óptimos, con técnicas de optimización, de modo que la respuesta real de la red se aproxime a la respuesta deseada [89], [118].

Como se mencionó anteriormente, además de la arquitectura del modelo, los hiperparámetros o configuración interna de la red también influyen en el éxito del modelo, en su capacidad y el rendimiento. En la tabla 7 se presentan algunos de los hiperparámetros más utilizados en los estudios y su relación con los retos industriales. Esta clasificación se hace para conocer algunos de los hiperparámetros que han demostrado ser útiles en el desarrollo de tecnología inteligente para la industria de inyección.

La función de activación es una representación del método de procesamiento y transmisión de la información de red. Existen diferentes tipos de funciones de activación, que se pueden usar en diferentes regiones del modelo. Con base en la información recopilada, se pueden destacar tres funciones: sigmoideal, ReLu y lineal. Asimismo, existen modelos en donde se utilizan dos funciones a la vez, ubicadas en distintas capas de la red.

La función de activación sigmoideal es la más utilizada y aunque se observa su uso para modelos de inspección, optimización y predicción de calidad, es en este último donde se prefiere su uso, ya que es interpretada como una probabilidad, ya que asigna el resumen de la función de la capa anterior en un intervalo entre 1 y 0. Su uso se aprecia principalmente en las capas ocultas y de salidas, de las redes MLP y BP-RNA, debido a su capacidad para clasificar datos [102], [110]. La función “unidad lineal rectificadora” ReLu (por sus siglas en inglés), de acuerdo con la tabla 7, tiene una mayor diversidad de uso, ya que se puede implementar tanto en ResNet, MLP, como en redes RNC y, al igual que las sigmoideales, cubren varios retos industriales. Esta función se implementa específicamente en las capas ocultas y su uso se debe, en especial, por su rapidez de aprendizaje y su simplicidad de cálculo, debido a la similitud que tiene con la función lineal (lo cual vuelve fácil su optimización).

Las redes neuronales pueden tener en su configuración más de una función de activación, ubicada en distintas capas de la red. La función lineal, por ejemplo, es la tercera función más utilizada y su ubicación se puede observar en la capa de salida o entre las capas ocultas y de salida. Su programación se hace principalmente para aplicaciones de inspección de calidad y optimización de parámetros. Aunque esta función de activación es usada con frecuencia, se puede apreciar que su implementación se complementa de otras funciones, como la sigmoideal, ReLu o Elu. La función softmax o función exponencial normalizada, por su parte, se puede localizar en las capas de salida, en modelos dedicados a la predicción y monitoreo de procesos. Esta función, similar a la lineal, es usada en conjunto con otras funciones como la ReLu o sigmoideal, en redes ResNet y MLP. Aunque se existen diferentes opciones de funciones de activación, es importante elegir la o las funciones que favorezcan el procesamiento de la red y su capacidad de aprendizaje

Los optimizadores son encargados de mejorar los resultados que obtiene el modelo neuronal, para que se acerquen cada vez más a los objetivos planteados, a través de la mejora de los pesos en las conexiones que tiene la red. De la tabla 7 se puede notar que el optimizador Adam es el más utilizado para cualquier tipo de red neuronal. Además, ha demostrado funcionar en modelos destinados a la predicción e inspección de calidad, monitoreo de procesos y control de procesos. Este optimizador actualiza los parámetros, como pesos y

tasas de aprendizaje de la red y facilita su adaptación a los datos del entrenamiento. Además, se caracteriza por ser computacionalmente eficiente, tener pocos requisitos de memoria y ser adecuado para tratar problemas con muchos datos y parámetros [123].

La tasa de aprendizaje (TA) es otro hiperparámetro que se menciona en algunos artículos de investigación. Su objetivo es controlar los cambios que experimenta la configuración del modelo durante las actualizaciones, como respuesta al error estimado cada que se modifican los pesos de la red. De acuerdo con los datos de la tabla 7 se aprecia que los valores de este hiperparámetro se encuentran en un rango de 0.7 a 0.0001. La delimitación es realizada por el usuario, sin embargo, se puede apreciar que los valores cambian de acuerdo con la función de activación, el tipo de red neuronal que se utiliza y el tipo de reto que se aborda. Por ejemplo, se puede observar que las redes MLP trabajan con un rango amplio de este hiperparámetro, de 0.1 a 0.001, mientras que las RNC utilizan un menor número de valores (entre 0.001 y 0.0001). Respecto a los retos industriales, la predicción de calidad es donde se pueden trabajar un rango mayor de tasas de aprendizaje. Por otro lado, podemos observar que las funciones de activación sigmoidales son capaces de trabajar con TA elevados (0.1-0.01), a diferencia de las funciones ReLu (0.01-0.0001). La razón de evitar valores altos de este parámetro es debido a la inestabilidad que puede ocurrir durante el proceso de aprendizaje. La preferencia de trabajar con valores de TA pequeños radica en facilitar la obtención de los valores óptimos para los pesos de la red, al tener un incremento menor de los parámetros de configuración, entre las iteraciones de aprendizaje. El inconveniente de trabajar con valores demasiado pequeños es que puede significar el incremento de iteraciones para llegar a los objetivos, lo que puede aplazar la convergencia.

Finalmente, el número de épocas o ciclos de aprendizaje se refiere a las iteraciones que hace la red para ajustar las variables, es decir, el número de veces en los que se ejecutan los algoritmos, hacia adelante y hacia atrás, para que la red neuronal aprenda sobre los conjuntos de datos de entrenamiento. Al final de cada época se varían los pesos de las conexiones para mejorar las respuestas del modelo. De acuerdo con los artículos recabados, se tiene mayor impacto en el número de épocas del sistema, según la función de activación que se utilice. Esto podemos observarlo principalmente con la función ReLu, que requiere máximo 100 épocas para entrenar su red, incluso en redes que incluyen dos funciones, como en el modelo hecho por Hsu et al. [90], en donde utilizaron una función ReLu en capas convolucionales, y Softmax en la de salida. Contrario este caso, las funciones sigmoidales requieren de un mayor número de ciclos para su aprendizaje, como en el modelo desarrollado por Chen, Guo y Wang, [58] en el que se requirió de un millón de épocas de aprendizaje.

Sistemas híbridos

Si bien utilizar una técnica de IA, por ejemplo, RNA, parece funcionar adecuadamente para aprender y correlacionar la información proveniente de los procesos de inyección, recientemente se ha optado por implementar modelos híbridos, en donde se utiliza más de una técnica de IA. La combinación de estos métodos se utiliza con el fin de aprovechar las funciones de los sistemas individuales y así abordar de mejor forma las principales problemáticas industriales (a diferencia de solo trabajar con uno).

El diseño de los sistemas híbridos tiene la ventaja que, en su estructura, puede albergar diversas técnicas de IA. No obstante, la determinación de los modelos que se decidan combinar puede representar un reto significativo en la implementación. En el Anexo 1 se pueden observar los diferentes tipos de sistemas híbridos que se han implementado en los retos delimitados de la industria de inyección. Aunque existe una notoria variedad de las técnicas implementadas (como RBC + LD, RBR + RBC, RNA + SVM) se pueden distinguir los siguientes hechos: los sistemas híbridos más utilizados son la combinación de RNA y AG (algoritmo genético); y las redes neuronales parecen ser las técnicas con mayor oportunidad de combinación con otras técnicas y, además, son capaces de ofrecer altos índices de eficiencia.

Los modelos de red neuronal parecen ser más amigables para combinarlas con otra técnica de calidad. Esto lo podemos observar en diferentes investigaciones, en donde se combinan las RNA con AG, VSM o con otros tipos de redes neuronales en un mismo sistema inteligente. Además, estas innovaciones cubren diversas funciones industriales, como la inspección y predicción de calidad, y la optimización de parámetros. La preferencia de este modelo recae en su capacidad de análisis para el proceso de proceso de inyección, que resulta en la caracterización de las relaciones entre los parámetros y las especificaciones del producto. Por ejemplo, los sistemas híbridos que combinan RNA y AG se utilizan principalmente para la optimización de parámetros. Li et al. en [96] desarrollaron un sistema híbrido capaz de encontrar los mejores parámetros para evitar la deformación en los productos. En su modelo decidieron utilizar RNA por su capacidad para modelar sistemas no lineales altamente complejos y GA por su capacidad de optimización. Su combinación permitió obtener un modelo predictivo, para el nivel de deformación de las piezas, y deducir los parámetros con los cuales se puede disminuir este defecto.

Debido a que las diferentes clases de RNA ofrecen funciones específicas a los sistemas inteligentes, se han realizado estudios en donde se ha buscado mejorar el nivel de precisión y eficiencia de este tipo de tecnología, a través de la combinación de diferentes tipos de redes. Kim, et al. desarrollaron un modelo para detectar defectos en los productos [22]. Para ello, propusieron un sistema con tres tipos de redes neuronales: RNC, MLP y GRU (por sus siglas en inglés de unidades recurrentes cerradas), en un entorno de aprendizaje multimodal. Estos tres submodelos se colocaron en paralelo y se programaron para tomar individualmente un tipo de entrada correspondiente a la vez. Es decir, los submodelos mapeaban las características de entrada sin procesar, en un espacio latente, y en una fase de agregación de características, las representaciones de datos transformados se integraban en las capas superiores para conseguir una sola predicción fusionada. Una ventaja que se menciona de este tipo de modelo es que su entrenamiento se podía hacer para el sistema completo, en lugar de entrenar cada submodelo por separado. Para validar los resultados, compararon el rendimiento del sistema con tres modelos, contra otras técnicas de IA, además de otros modelos combinados. Los investigadores concluyeron que el modelo con tres modelos de RNA proporcionó un rendimiento de detección de fallas notable y estable, con una precisión mejorada, comparada con los modelos individuales y los provenientes de otras técnicas de IA.

Máquina de vectores de soporte

La SVM, por sus siglas en inglés de *Support vector machine*, es una técnica que permite la clasificación y regresión de información de sistemas no lineales. El uso de este modelo se muestra como una alternativa, por ejemplo, a las redes neuronales, ya que éstas últimas pueden ser sensibles a la estructura que se le implemente, como el número de capas ocultas. Además, se ha destacado que SVM tiene mayor precisión de las RNA, cuando se tienen bases de datos pequeñas [92], [94]. Aunque se muestran como una opción atractiva para la tecnología inteligente en la industria de inyección, como los algoritmos genéticos, se puede observar todavía como un tema en desarrollo, ya que no se tiene información suficiente sobre casos exitosos de implementación que puedan utilizarse como referencia.

El uso de esta técnica abarca diversas funciones como la predicción de resultados, gestión de relaciones de datos, reconocimiento y análisis de imágenes, extracción de conceptos de minería de datos, etc. [88], [92] En la inyección de plásticos se puede observar especialmente en los retos de inspección, predicción de calidad y optimización de parámetros. Tseng, et al. desarrollaron un sistema inteligente con SVM capaz de monitorear las dimensiones de los productos y clasificarlos de forma automática, en piezas conformes o no conformes [88]. Por su parte, Ribeiro [50] implementó un modelo inteligente, con esta técnica, para monitorear los parámetros del proceso y predecir la calidad de los productos, con el fin de detectar y responder rápidamente ante algún problema.

La programación de los modelos SVM, específicamente en los retos seleccionados, representa un desafío en el establecimiento de sistemas inteligentes. De los estudios recopilados aún se distinguen discrepancias entre las magnitudes de sus hiperparámetros, como el tipo de kernel⁴⁹, el valor gama y el parámetro de regularización. Esta situación complica la delimitación de una referencia para establecer un sistema inteligente, ya que la magnitud de los hiperparámetros influye directamente en la actividad y el desempeño de los modelos [50].

Como se pudo observar, el uso de redes neuronales facilita el abordaje de la mayoría de los retos industriales planteados. La flexibilidad del modelo ha demostrado su capacidad para adaptarse a diversas tareas del proceso y conseguir buenos rendimientos. Aunque su uso resulta atractivo, su implementación requiere la delimitación de varios hiperparámetros que influyen directamente en el éxito del modelo. Los sistemas híbridos muestran un desempeño atractivo, sin embargo, la programación puede representar una dificultad mayor, en comparación con las RNA, para las industrias que recién abordan este tipo de tecnología. Por lo tanto, considero que, si se quiere iniciar con el desarrollo de IA en los procesos, sería conveniente trabajar con técnicas individuales, especialmente con aquellas que han demostrado excelentes desempeños y que podrían ser más amigables en el proceso de implementación.

La integración de la tecnología inteligente, a pesar de que se basa en técnicas de IA para su funcionamiento, necesitan de otros elementos para trabajar. Por lo que una vez revisadas las

⁴⁹ De los artículos compilados se puede apreciar la función RBF como el kernel más utilizado.

técnicas más importantes resulta oportuno mencionar los softwares y equipos que más se han utilizado para desarrollar sistemas inteligentes, con el fin de utilizarlos como referencia.

4.2.2 Requisitos para el sistema

Los sistemas inteligentes, además de la determinación de los modelos que le dan sentido a su funcionamiento, necesitan ciertos elementos que permiten programar los algoritmos de las técnicas de IA, obtener datos para el aprendizaje de los modelos, etc. Es importante contemplar estos elementos antes de su anticipación, con el fin de facilitar la implementación de la tecnología con inteligencia artificial.

4.2.2.1 Softwares y programas

Con el fin de implementar correctamente los modelos inteligentes, se utilizan diversas herramientas computacionales que proveen diversas funciones a los sistemas. Aunque existe una gran variedad de softwares, lenguajes de programación, simuladores, etc. para el desarrollo de IA, en la tabla 8 se presentan los más utilizados en los sistemas inteligentes de la industria de inyección. Además, se incluye el tipo de técnica, la función de las herramientas y la aplicación del modelo inteligente que tratan. Esta información se considera indispensable para aquellos que deseen integrar IA en sus procesos, ya que es la base con la que trabajan los sistemas inteligentes.

Tabla 8. Herramientas computacionales utilizadas en la implementación de tecnología inteligente (clasificadas por su función).

Referencia	Técnica IA	Reto industrial	Herramienta	Función
[95]	RNA	Optimización	Software LabWindows CVI	Adquisición y gestión de datos de los sensores.
[114]	RF	Predicción	Hadoop cluster	Almacenamiento de datos y ejecución de aplicaciones en clúster de hardware comercial.
[114]	RF	Predicción	Elasticsearch database	Almacenamiento y visualización de datos.
[109]	RF	Predicción	Grafana	Plataforma para visualizar datos.
[114]	RF	Predicción	Notebook Jupyter	Análisis de datos en tiempo real, desde Elasticsearch.
[76]	RNA	Control	Notebook Jupyter	Análisis de datos en tiempo real. Evaluación de modelo.
[83]	RNA	Inspección	GitHub	Fuente de proyectos donde se obtuvo el código abierto de modelo TensorFlow.
[104]	AD	Predicción	MES (manufacturing execution system)	Gestión de información recopilada del proceso.
[22]	RNA	Inspección	MES (manufacturing execution system)	Gestión de información recopilada del proceso.
[98]	H: AG + RSM	Optimización	Design Expert	Implementación de DOE.
[113]	RNA	Predicción	ModeFRONTIER	Implementación de DOE.
[109]	RF	Predicción	Open platform communications	Plataforma para comunicar datos entre PLC y módulos del sistema.
[79]	-	Control	Interfaz digital de comunicación	Interfaz permite integrar el sistema de control desarrollado con el sistema de control de la máquina.
[15]	H: RNA + SVM	Predicción	Python	Lenguaje de programación (librería Scikit-learn, solvers: lbfgs y sgd, Adam, para RNA; y gridsearchcv para SVM).
[79]	-	Control	Python	lenguaje de Programación del modelo, para análisis, comparación y estimación de parámetros.
[101]	RNA	Predicción	Python	Lenguaje para desarrollar interfaz gráfica, biblioteca: PyQTgraph, PyDaqmx, Numpy y os

[109]	RF	Predicción	Python	Lenguaje para desarrollar modelo.
[102]	RNA	Predicción	Python	Lenguaje para desarrollar modelo.
[76]	RNA	Control	Python	Lenguaje para desarrollar modelo, biblioteca Scikit-learn, TensorFlow, pandas e interfaz keras.
[112]	RNA	Predicción	Python	Lenguaje para implementar modelos, biblioteca SeaBorn. Con Scikit-learn se desarrollaron los modelos; TensorFlow para desarrollar modelos MLP y RNC.
[97]	RNA	Optimización	Python	Lenguaje para implementar modelos, biblioteca: keras (2.3.1), Scikit-learn (0.21.3), TensorFlow (2.0.0).
[22]	RNA	Inspección	Python	Lenguaje para implementar modelos, bibliotecas TensorFlow y keras (para desarrollar y probar modelos).
[106]	RNA	Predicción	Pytorch	Librería de código abierto, donde se implementan métodos para DeepL.
[83]	RNA	Inspección	TensorFlow	Librería de código abierto, donde se implementan métodos para DeepL.
[105]	RNA	Predicción	TensorFlow	Librería de código abierto. Proceso de optimización bayesiana, biblioteca Keras.
[105]	RNA	Predicción	Matlab	Programación de modelo, análisis de fotografías, ejecución de modelos de aprendizaje y determinación de estructura de RNA.
[87]	SVM	Inspección	Matlab	Programación de modelo, también para leer y analizar imágenes. Uso de caja de herramientas "procesamiento de imágenes".
[98]	H: AG + RSM	Optimización	Matlab	Programación del modelo.
[116]	H: RBC + CBR	Diseño	Programador C++	Programación del modelo.
[100]	AG	Planeación	Matlab	Programación del modelo (con toolbox R2012a).
[93]	H: RNA + AG	Optimización	Matlab	Programación del modelo (con toolbox R2012b).
[72]	AG	Planeación	Matlab	Programación del modelo (con toolbox R2019b).
[91]	H: RNA + PSO	Optimización	Matlab	Programación del modelo y mapeo proceso.
[102]	RNA	Predicción	Google colab	Programación y ejecución de python. Plataforma libre
[88]	SVM	Inspección	Statistica 8.0	Programación del modelo. Gestión, minería y análisis de los datos recopilados, para determinar kernel y parámetro C.
[106]	RNA	Predicción	Cadmould 3D-F	Simulación de productos para formar base de datos.
[103]	RNA	Predicción	Software Maps 3D-computer-aided engineering (CAE)	Simulador para conocer información geométrica del molde y del proceso.
[97]	RNA	Optimización	Cadmould 3D-F	Simulador para generar datos.
[87]	SVM	Inspección	CAE MOLDEX 3D	Simulación de defectos de la pieza, se adiciona el método de IA para mejorar el desempeño del software.
[76]	RNA	Control	CAE MOLDEX 3D	Simular e Identificar condiciones óptimas de procesamiento.
[99]	H: RNA + AG	Optimización	Moldflow	Simular el proceso de inyección, con información del polímero empleado.
[91]	H: RNA + PSO	Optimización	Moldflow	Simular proceso y establecer rangos de parámetros (para minimizar defectos).
[98]	H: AG + RSM	Optimización	Moldflow	Simular y analizar el proceso.
[116]	H: RBC + CBR	Diseño	Moldflow	Simular y analizar el proceso (para determinar los casos preliminares para la biblioteca de casos del sistema).
[96]	H: RNA + AG	Optimización	Moldflow	Simular y analizar sobre resultado de procesos con diferentes parámetros.

Inicialmente se debe contemplar un lenguaje de programación para desarrollar el sistema inteligente. Para este rubro, se puede observar en la tabla 8 que Python es el lenguaje que más se utiliza debido a su eficiencia y su flexibilidad de uso en diversas plataformas. Sin importar el tipo de reto industrial que se desee abordar, el uso de este lenguaje resulta útil

para la programación. Con base en la información disponible, se identifica que este lenguaje parece ser común para el desarrollo de modelos con RNA.

La elaboración de los modelos IA se realiza con la ayuda de bibliotecas de programación. Estas librerías son conjuntos de módulos que facilitan la escritura de las funciones que son necesarias para la programación del modelo y reducen los errores en los códigos. En los artículos recabados se aprecia el uso de las bibliotecas, TensorFlow, Keras y Scikit-Learn para desarrollar sistemas de RNA. El primero de ellos es una librería de código abierto de Google Cloud, la cual se puede utilizar en procesadores GPU y CPU, basados en el flujo de datos y programación diferencial. Keras es una interfaz de programación de aplicaciones de alto nivel, de la librería TensorFlow, para aprendizaje profundo. La última librería permite construir un modelo fácilmente, ya que cuenta con algoritmos y módulos, para realizar clasificaciones regresiones, clustering y reducción de dimensionalidad, los cuales se pueden combinar y depurar con otras estructuras de datos y aplicaciones externas, también se puede usar para modelar SVM, con la clase GridSearchCV [124]. Existen otras librerías que también se pueden considerar en el desarrollo de los programas. Estas son: Pytorch, SeaBorn, PyQTgraph, PyDaqmx, Numpy y os, para RNA. El objetivo de mencionar estas bibliotecas es para tener en consideración los recursos que pueden facilitar la programación de los modelos inteligentes.

Aunque se ha podido apreciar el lenguaje Python y sus librerías como los primeros recursos para desarrollar sistemas basados en redes neuronales, existen otras herramientas que también ayudan a esta tarea. Para otras técnicas de IA implementadas, se ha preferido utilizar la plataforma MATLAB como el medio de programación⁵⁰. En la tabla 8 se observa esta aplicación para modelos con AG, SVM, e incluso RNA, en cualquiera de las funciones definidas. De acuerdo con su portal de internet, “Matlab facilita el paso de modelos de Deep learning a sistemas basados en inteligencia artificial del mundo real” [125]. En ella se pueden preprocesar datos en menor tiempo, entrenar y evaluar modelos, simular datos, analizar imágenes, desplegar modelos entrenados en sistemas integrados, etc. Su implementación se complementa con el uso de cajas de herramientas (o *toolbox*) de la plataforma, como R2012a y b, y R2019b. También se utilizan otras plataformas para implementar modelos, como Statistica 8.0 para SVM o Google Colab para RNA, sin embargo, no se tiene suficiente información para usarse como referencia.

Otro elemento que, aunque no interviene en la programación de los códigos de los modelos, permite el desarrollo de los sistemas, son los simuladores. Su importancia recae en las funciones que realiza en diferentes etapas del proceso de creación. Por ejemplo, se puede utilizar para crear la base de datos con la que se entrenará el modelo, al realizar experimentos sin utilizar recursos de las industrias y con mayor rapidez. También se puede usar para identificar los rangos operativos del proceso, es decir, las condiciones óptimas del procesamiento y las condiciones en las que se pueden desarrollar defectos; además los

⁵⁰ Aunque en los artículos recopilados no se cuenta con referencias sobre el uso combinado del lenguaje Python con Matlab en la implementación de IA, es posible desarrollar sistemas inteligentes mediante el uso de ambos recursos. Por ejemplo, es posible importar modelos predefinidos, basados en Python, desde TensorFlow a Matlab [124].

simuladores se pueden usar como herramienta para validar los resultados, cuando se concluya el modelo inteligente. Los principales programas relacionados con esta función son: Cadmould 3D-F, CAE MOLDEX 3D y Moldflow. Estos elementos tienen la ventaja de relacionarse con los procesos de diseño y fabricación mediante la inyección de plásticos, por lo tanto, se puede utilizar información de los polímeros o simular la forma en que se llenará una pieza o los defectos que se desarrollarán en los productos, de acuerdo con los parámetros del proceso.

Los siguientes recursos, aunque no se utilizan con gran frecuencia, se han reportado eficientes para la implementación de sistemas inteligentes: 1) *LabWindows/CVI* se utilizó para crear aplicaciones personalizadas relacionadas con la adquisición y gestión de datos provenientes de los sensores, ya que permite obtener datos desde instrumentos GPIB, USB, serial, Ethernet, etc. [126] 2) Para el almacenamiento de datos se han utilizado *Hadoop Cluster* y *Elasticsearch*, los cuales, además de funcionar como bases de datos también permiten la ejecución de aplicaciones [114]. 3) El uso de Notebook Jupyter permitió el análisis de datos, desde Elasticsearch y la evaluación de los modelos, a través de la revisión y ejecución de fragmentos del código del modelo. Una ventaja de esta aplicación web es su compatibilidad con diferentes lenguajes de programación, como Python [104], [114], [127]. 4) El sistema MES (*manufacturing execution system*) es un software que permite monitorear, recolectar y documentar la información del proceso de producción, en tiempo real [22]. 5) Para la ejecución de diseño de experimentos (DOE por sus siglas en inglés) se utilizan programas como *Design Expert* o *ModeFRONTIER* [98], [113], [128]. 6) La implementación de plataformas de comunicación digitales facilita la conexión y el intercambio de datos entre las unidades y dispositivos que componen el proceso.

Según el modelo inteligente que se desee integrar, es importante considerar los diferentes elementos que permiten la ejecución de los modelos inteligentes, a través de los lenguajes, bibliotecas y plataformas de programación. No obstante, también es oportuno seleccionar los softwares y plataformas que complementan estos modelos, como los simuladores, bases de datos, gestores de información, plataformas de comunicación, entre otros. La delimitación de los elementos digitales que compondrán los sistemas inteligentes determinará la dinámica que se genere en el entorno, ya que la tecnología inteligente no se compone solamente de un modelo inteligente, sino que se integra de otros recursos que permiten su interacción con el proceso y su autonomía de procesamiento.

4.2.2.2 Equipos

Después de revisar los modelos inteligentes y los softwares y herramientas digitales más utilizados, el último punto por estudiar son los equipos y dispositivos. Su papel en los sistemas es tal que permite el funcionamiento del propio sistema, desde la recolección de información, hasta la ejecución de los programas inteligentes. Es importante mencionar que, aunque en la actualidad existen máquinas inyectoras que ya tienen integrados dispositivos capaces de obtener y analizar información de distintas partes del proceso, el objetivo es mostrar que existen diversas opciones que se pueden acoplar a las inyectoras con las que ya cuenta una industria, sin necesidad de invertir en una nueva máquina de inyección. En la

siguiente tabla se muestran los dispositivos más utilizados en los estudios para todas las técnicas de IA.

Tabla 9. Dispositivos utilizados en la implementación de tecnología con IA, en la industria de inyección de plásticos.

Referencia	Técnica IA	Reto industrial	Dispositivo	Función / especificaciones
[88]	SVM	Inspección	Robots de ensamble	Acomodo de productos, según la decisión si se acepta o no el producto.
[94]	H: RNA + SVM	Optimización	Grabadora Hioi (hicorder)	Almacenamiento de datos.
[90]	RNA	Monitoreo	Módulo (válvula) electromagnética (controlador de Arduino)	Controla la entrada de material plástico y sistema de refrigeración por agua.
[94]	H: RNA + SVM	Optimización	Computadora	Dispositivo donde se ejecutaron los programas del modelo IA.
[99]	H: RNA + AG	Optimización	Computadora HP personal workstation	Dispositivo donde se ejecutaron los programas del modelo IA (programación, simulación y entrenamiento de los modelos).
[77]	RBC	Control	Computadora base y de servicio	Dispositivo donde se ejecutaron los programas del modelo IA. Contiene Tarjetas PCL841 con controlador SJA-1000, la tarjeta PCL y controlador SJA. que pueden convertir la RAM en memoria física.
[102]	RNA	Predicción	Computadora	Dispositivo donde se ejecutaron y evaluaron los programas del modelo IA.
[72]	AG	Planeación	Computadora con Intel® Core™ i7-4500U CPU, a 1.80 GHz, 8 GB de RAM	Dispositivo donde se ejecutaron y evaluaron los programas del modelo IA.
[100]	AG	Planeación	Computadora con Intel Core i5, 2.27 Ghz y 3 GB de RAM	Dispositivo donde se ejecutaron y evaluaron los programas del modelo IA.
[86]	RNA	Inspección	Computadora con Intel i7 - 7700HQ, 2.80 GHz, 16 GB RAM	Dispositivo donde se ejecutaron y evaluaron los programas del modelo IA.
[22]	RNA	Inspección	Computadora con tarjeta gráfica GPU: GTX 1080 Ti	Dispositivo donde se ejecutaron y evaluaron los programas del modelo IA.
[104]	AD	Predicción	Notebook con windows 10	Dispositivo donde se ejecutaron y evaluaron los programas del modelo IA.
[90]	RNA	Monitoreo	Field Programmable Gate Array (FPGA)	Dispositivo programable. DE10 Lite es un tipo de FPGA que permite programación y comunicación por redes entre dispositivos.
[79]	-	Control	Interfaz de comunicación y controlador	Integra sistema de control desarrollado, con el sistema de control de la máquina.
[109]	RF	Predicción	PLC	Lee y comunica datos del proceso
[101]	RNA	Predicción	Tarjeta National instruments	Interconecta los sensores y la electrónica de apoyo
[89]	RNA	Inspección	Cámara y motores paso a paso	Obtención de imágenes de la superficie.
[112]	RNA	Predicción	Cámara térmica en línea	Obtención de imágenes de los productos.
[89]	RNA	Inspección	Cámara ccd /lente focal 12mm	Obtención de imágenes del producto. Cámara de 2592x1944 pixeles / Con lente con aumento óptico 0.042, campo de visión 135mmx101mm y resolución imagen 71µm/pixel.
[90]	RNA	Monitoreo	Cámara Pcam 5c	Obtención de imágenes. Es usada como módulo de visión, donde se integraría la placa de desarrollo.
[88]	SVM	Inspección	cámara con resolución 640 x 480	Obtención de imágenes; detecta y mide los objetos en distintas orientaciones, e intercambia información en la red de datos.
[111]	RNA	Predicción	Interfaz gráfica	Permite monitorear en línea los parámetros
[104]	AD	Predicción	Sensores	Recopila datos, en tiempo real, sobre condiciones proceso.
[79]	-	Control	Sensores (T y P)	Recopila datos, en tiempo real, sobre condiciones proceso.

[106]	RNA	Predicción	Sensores (T y P)	Recopila datos, en tiempo real, sobre condiciones proceso.
[22]	RNA	Inspección	Sensores (T y P)	Recopila datos, en tiempo real, sobre condiciones proceso.
[77]	RBC	Control	Sensores (T)	Recopila datos, en tiempo real, sobre condiciones proceso.
[94]	H: RNA + SVM	Optimización	Sensor (P)	Recopila datos, en tiempo real, sobre condiciones proceso (Pboquilla Kistler (modelo 4083A) / Sensor de Phidráulica "Kistler", modelo RAG25A200BV1H).
[107]	RNA	Predicción	Sensores (T y P)	Recopila datos, en tiempo real, sobre condiciones proceso. Cuatro sensores de T _{fusión} , y dos de P _{fusión} en la cavidad del molde y dos conjuntos de sensores tipo bayoneta en la entrada y salida del agua, dos juegos de sensores de P _{hidráulica} en compuerta posterior y extremo de calidad.
[102]	RNA	Predicción	Sensores (P _{molde})	Recopila datos, en tiempo real, sobre condiciones proceso. obtiene información sobre la presión de la cavidad.
[76]	RNA	Control	Sensores (T y P)	Recopila datos, en tiempo real, sobre condiciones proceso. Obtiene información de T y P cav del molde. Sensores marca Kistler, tipo 6190C.
[111]	RNA	Predicción	Sensores (T y P)	Recopila datos, en tiempo real, sobre condiciones proceso. Sensores Kistler.
[95]	RNA	Optimización	Sensores transductores (P, Q _{refrigerante} , Termopares)	Recopila datos, en tiempo real, sobre condiciones proceso. .
[112]	RNA	Predicción	Sensores (T y P)	Recopila datos, en tiempo real, sobre condiciones proceso. TyP molde, P iny, posición tornillo.
[101]	RNA	Predicción	Sensores (T, P, vel., posición, flujo)	Recopila datos, en tiempo real, sobre condiciones proceso.
[95]	RNA	Optimización	Tarjeta DAQ (PC-6123)	Se usó en combinación con el software LabWindowsCVI para adquirir y gestionar los datos provenientes de los moldes y así saber la dinámica del sistema.
[88]	SVM	Inspección	Sensores de visión Cognex DVT 540	Hacen inspecciones y mediciones de las piezas.
[76]	RNA	Control	Interfaz-microcontrolador Arduino Mega (tipo Arduino-Atmega-2560) + ESP32D	Sirve como vínculo entre los sensores y el centro de operación del sistema inteligente, para procesar, almacenar, manejar los datos y comunicarlos al modelo de IA y a la tarjeta de memoria. Ambas interfaces son marca Kistler (tipo 6190C).

Equipo de cómputo

Las computadoras son uno de los productos más importantes en los sistemas inteligentes. Aunque su uso se puede considerar evidente, es importante reconocer su importancia. En la tabla 9 se presentan algunas de las especificaciones de los equipos de cómputo. Estas características pueden variar o ser más especializadas, de acuerdo con el reto que se trabaje y los requerimientos del mismo sistema inteligente. Básicamente, su función es ejecutar los programas del modelo IA (además de los otros softwares que se requieran) y facilitar la conexión con los equipos que integran el sistema, como los sensores, tarjetas de control, PLC, entre otros.

Sensores y cámaras

Uno de los requisitos para trabajar con la tecnología de la industria 4.0 consiste en recopilar y manejar una gran cantidad de datos para controlar el proceso de inyección. De acuerdo con Ageyeva [129], aunque los datos provenientes del panel de control de las máquinas son importantes para el monitoreo del proceso, los datos del molde son más precisos para el estudio de la eficiencia del proceso y de la calidad de los productos, ya que es en este punto donde los productos son formados. Con este propósito, actualmente existe disponible una amplia gama de sensores que facilitan el montaje de los sistemas informáticos y la obtención

de información proveniente de distintas etapas del proceso y zonas de la máquina de inyección (como las cavidades del molde). Su funcionamiento está basado en la percepción del entorno y la transformación de estos estímulos en información [76]. La versatilidad de estas herramientas permite, no solo la inspección de los productos, también de las condiciones operativas de la máquina en tiempo real, como los parámetros y los estados de los equipos y sus componentes [90].

Una de las ventajas que se tiene con los sensores modernos es que se pueden utilizar dispositivos de alta calidad y bajos costos. Su aplicación permite el procesamiento de altas cantidades de datos y la evaluación de sistemas productivos complejos, en donde se involucran datos e imágenes [84], [89], [90]. La dificultad de obtener información del procesamiento del material resulta especialmente de dos desafíos: la presión de fusión, que puede ser mayor a los 150MPa; y el medio donde se procesa puede ser corrosivo y abrasivo para cualquier material, ya que se manejan temperaturas altas (la cuales cambian rápidamente y llegan a sobrepasar los 300°C). Con esto en mente, se busca que los sensores tengan características especiales que le permita funcionar adecuadamente bajo todas las condiciones que se manejen en los moldes y que tengan un amplio alcance (por las diferencias de temperatura para una misma área del molde). Debido a esto, si se decide utilizar sensores en el sistema, el proceso de selección debe realizarse cuidadosamente con el fin de obtener información precisa de la inyección.

Las cámaras, por otro lado, son capaces de obtener imágenes de los productos, en tiempo real. Su uso está relacionado principalmente con el reto de inspección de calidad y, como se puede apreciar en la tabla 9, existe una amplia gama de unidades que se pueden implementar. Las imágenes que se obtienen generalmente son de la superficie de los productos, sin embargo, hay estudios en donde su finalidad es obtener imágenes sobre los tableros de control de las máquinas de inyección, para monitorear el proceso [90]. En el estudio hecho por Nagorny et al. [112] utilizaron cámaras térmicas para ayudar a predecir la geometría de los productos, y con ello su calidad, al relacionar el proceso de enfriamiento de las piezas con el cambio de dimensiones. Las cámaras, similares a los sensores, precisan la elección del dispositivo adecuado y una ubicación adecuada, que le permita conseguir la información más precisa.

De la tabla 9 se puede observar que los sensores más utilizados en los sistemas inteligentes están relacionados con la temperatura y presión. Su ubicación se establece principalmente en la cavidad del molde y en la boquilla de la máquina de inyección. Los equipos más utilizados para revisar estos parámetros son los transductores piezoeléctricos, para estudiar la presión; y los termopares para revisar la temperatura. Los medidores de flujo son otro tipo de sensores de gran uso, cuyo objetivo es conocer la dinámica de enfriamiento del refrigerante. Específicamente, los sensores Kistler son los más utilizados por su nivel de precisión, rango de operabilidad y por el tiempo de respuesta con el que trabajan. Su uso está destinado principalmente para las funciones de predicción de calidad, optimización y control de parámetros.

El uso de estos dispositivos tiene grandes ventajas, debido a los diversos rangos de alcance de medición, no obstante, su posición debe localizarse correctamente, con el objetivo de medir los parámetros de la mejor manera posible. Aunque se podría creer que utilizar más sensores en una zona, como las cavidades del molde, ayuda a tener mayor conocimiento del desarrollo de la inyección, Ke y Huang [102] demostraron que se pueden conseguir resultados precisos, con pocos dispositivos, siempre y cuando se ubiquen de forma óptima. Esta situación también favorece económicamente la implementación, ya que no se precisa la adquisición de muchas unidades para conseguir buenos resultados. Por lo tanto, la ubicación correcta de estos sensores debe facilitar una buena percepción del entorno.

En algunas ocasiones los sensores son complementados con otros dispositivos para procesar y traducir las características obtenidas en información adecuada para utilizarse por los modelos inteligentes. Por ejemplo, el sistema desarrollado por Chen et al. [76] se basó en la técnica RNA y su objetivo consistió en monitorear y pronosticar la calidad del producto y el funcionamiento del proceso. En este sistema se utilizaron sensores para capturar información sobre la presión y temperatura de las cavidades de los moldes. También implementaron un circuito de acondicionamiento de señal con el que se amplificaron las señales de los sensores para que, de esta forma, pudieran ser utilizables por el sistema con microcontrolador. Del mismo modo se pueden emplear grabadoras para registrar los datos del proceso, como en el estudio hecho por Lau, Li y Du, en la que utilizaron una grabadora Hicorder, de Hioki, para capturar las señales percibidas por los sensores y transmitir las a la computadora, a una frecuencia de muestreo de 1 kHz [94].

Con el fin de vincular los distintos dispositivos del sistema inteligente, se utilizan interfaces de comunicación y control. Estas unidades permiten integrar todos los sensores, cámaras, PLC, controladores de Arduino, etc., en un centro de operación del sistema. Lo anterior se hace con el objetivo de tener un mayor control en el sistema, de tal manera que se pueda procesar, almacenar, manejar y comunicar los datos del proceso al modelo IA y que los resultados de éste también puedan transmitirse al resto de los dispositivos para ejecutar las acciones debidas. En el estudio hecho por Everett y Dubay [95] se utilizó como interfaz una tarjeta DAQ (PC-6123), en combinación con el software LabWindowsCVI, para comunicar las señales de los sensores a una computadora central, que las procesaría y dejaría disponibles para el modelo inteligente.

Los equipos que se seleccionen para los sistemas inteligentes tienen gran influencia sobre su funcionamiento. Esta selección debe contemplar los requisitos de las funciones que se aborden con el sistema y del modelo inteligente que se utilice. Asimismo, el número de dispositivos debe ser suficiente para que el sistema opere de forma esperada y no represente una inversión excesiva para la organización. Con base en la información recopilada, los principales dispositivos que se necesitan son un ordenador central, dispositivos para obtener datos (sensores o cámaras) e interfaces de comunicación y control. También se puede hacer uso de dispositivos para que realicen acciones de forma autónoma, como brazos robóticos, controladores de Arduino, etc.

4.2.3 Estrategia de instalación o programación

Una vez revisados los componentes clave que integran los sistemas inteligentes (modelos, software y dispositivos), el siguiente paso es estudiar la mejor forma de integrarlos, de tal forma que permitan el funcionamiento esperado de las innovaciones. Para ello, se estudiaron las metodologías de implementación que siguieron cada una de las investigaciones recopiladas y se delimitaron algunas etapas que fueron claves del proceso, figura 21.



Figura 21. Proceso de implementación de modelo inteligente, basado en casos reportados en la literatura.

A continuación, se describe cada fase y algunas consideraciones que se debe tener en cuenta para implementar con éxito los sistemas inteligentes:

4.2.3.1 Recopilación de información

Una de las etapas con las que los estudios recopilados inician es la recopilación de la información del proceso de inyección. Lee et al. mencionan esto como uno de los elementos clave de la IA industrial: el conocimiento del dominio [130]. En este factor se busca comprender el problema o reto que se quiere solucionar y su contexto, con el fin de centrar las funciones de la IA en resolverlo. Para ello se recopilan datos que, inicialmente, se consideran correctos y relacionados con el reto a abordar. Con esta información se busca comprender el significado físico de los parámetros y la forma en que se relacionan con la calidad del producto y la eficiencia del proceso. Del mismo modo mencionan que, en las industrias donde manejan varias máquinas de inyección, es importante conocer el procesamiento todas las máquinas con las que se cuenta, ya que los parámetros pueden variar distinto entre el procesamiento de uno y otro (la IA que se implemente debe ser capaz de adaptarse a esta situación).

Además de tener una mayor comprensión del proceso con la información recopilada, se busca mejorar los modelos de IA, con el fin de hacerlo más preciso y completo. Para este propósito se recurre a la tecnología de datos, la cual permite adquirir datos útiles que se determinan influyentes en el rendimiento del proceso. Las herramientas que se ocupan para esta actividad son un facilitador para la conexión inteligente de la industria 4.0 [130]. Para lograr lo anterior, se deben definir los equipos y mecanismos para adquirir información de calidad y, además, comunicar estos datos a la sección del sistema inteligente donde se hará el procesamiento de los datos.

El sistema de comunicación que se defina debe favorecer la transferencia y almacenamiento de datos capturados, de las máquinas de inyección a la nube y viceversa. Por ejemplo, el sistema que desarrolló Chen et al. [76] estaba compuesto por un sistema de adquisición de datos y monitoreo, conformado por sensores de P y T. Estos equipos fueron instalados a un circuito de acondicionamiento de señal, mediante un amplificador. En éste, la señal de respuesta se conducía a la entrada analógica del microcontrolador para iniciar una operación computacional. Después, los datos del sensor eran convertidos en mediciones reales que posteriormente eran utilizados por el modelo inteligente para controlar el proceso de inyección.

En general, los datos que se colectan provienen de los parámetros de proceso y de las características de los productos, en diferentes formatos. Además, su obtención puede provenir de distintas fuentes, como los sensores, cámaras o simuladores. En este proceso se debe contemplar el formato con el que se obtiene la información. En el caso de los sensores se debe considerar el área desde donde se obtienen los datos. En el sistema inteligente realizado por Ke y Huan [102] se hizo un análisis de las zonas desde donde se puede obtener información de las cavidades del molde, y sobre la influencia que tiene el uso de uno o varios sensores en la calidad de la información. El estudio hecho por Chen, et al. [83] tuvo como propósito inspeccionar en tiempo real la calidad de los productos y detectar rayaduras en la superficie. Para ello se capturaron 10 mil imágenes para cada situación (con y sin defecto), por medio de un espacio desarrollado para la captura y registro de imágenes, en donde se regulaba la iluminación de la zona para tener un mejor reconocimiento de defectos.

Aunque la cantidad de información puede variar entre uno y otro caso, los modelos inteligentes se caracterizan por necesitar un gran número de datos. Ante esto, las industrias pueden utilizar información generada por ellos mismos o por terceros. Por ejemplo, Böttjer, et al. utilizaron una base de datos, obtenida de su socio industrial, para desarrollar el sistema inteligente capaz de identificar el tiempo de vida útil y el tiempo de degradación de los moldes de inyección [80]. Esta base de datos incluía información de 13 moldes distintos, acerca de puntos geométricos del producto, revisada cada tres semanas; características de la construcción de los moldes y datos de los ciclos de producción. Con esta información se relacionó la calidad del producto con seis etapas del ciclo de vida del molde.

Es importante mencionar que esta actividad puede representar una inversión considerable, debido a los recursos que se necesitan para completar los estudios. En algunos estudios se utilizan simuladores u otros métodos, para conseguir información de la inyección sin desperdiciar recursos. Shelesh-Nezhad y Siores construyeron una biblioteca del sistema, compuesta por casos históricos exitosos del proceso, para desarrollar su sistema híbrido inteligente compuesto por los modelos RBC y RBR [116]. En ella se incluyeron los parámetros de operación óptimos y condiciones iniciales del polímero utilizado, es decir se creó el espacio del problema, en donde se definieron algunas restricciones relacionadas con variables del proceso y defectos que ocurren al pasar estos límites. Los casos de la biblioteca fueron obtenidos por medio de un simulador, en el que se definieron problemas preliminares y, mediante acciones iterativas se definió su optimización. También se establecieron rangos en donde se localizan los parámetros con los que se encuentran las soluciones para dichos

problemas. Esta biblioteca fue definida para desarrollar la parte del modelo que se basaba en la técnica RBC, ya que ésta necesita referencias para relacionar características de nuevos problemas con características existentes.

Por otra parte, también se pueden construir casos a partir de información real del proceso. En la investigación hecha por Haselmann y Gruber [85] se crearon muestras con defectos a partir de imágenes de los productos a distintas direcciones. Esta base de datos fue completada con fotos buenas de los productos y otras en donde se les implantaron defectos a las imágenes, por medio de un algoritmo desarrollado por también por Haselmann y Gruber. El objetivo de esta adición de defectos fue cubrir la mayoría de los defectos que pueden ocurrir en un procesamiento real, con diferentes contrastes; sin tener que invertir demasiados recursos en producir piezas con defectos.

4.2.3.2 Preprocesamiento y Análisis de datos

Una vez que se tiene recopilada la información, se realizan dos procesos: preprocesamiento y análisis de datos. El objetivo del primero es normalizar la información que se tiene en la base de datos ya que, al provenir de distintas fuentes, puede haber discrepancias entre los formatos de cada valor o, en un mismo conjunto de datos, puede haber ruido, redundancias y errores entre las señales recopiladas. El preprocesamiento se realiza para reducir la cantidad de datos en el sistema y limitar los requisitos de memoria y disminuir el tiempo de cálculo. De esta forma se busca ayudar a los modelos inteligentes a que manejen y analicen la información con mayor facilidad e incrementen el rendimiento del algoritmo de aprendizaje. Para ello se utilizan algoritmos cuyas principales funciones consisten en normalizar y limpiar los datos, con el fin de reducir su dimensionalidad, corregir o evitar datos incompletos, faltantes o redundantes [131].

De acuerdo con Kim, Na, Yun y Lee [103] el preprocesamiento está compuesto por dos fases: la normalización de características de entrada y la separación de datos en conjuntos para entrenamiento y validación. El propósito del preprocesamiento consiste en volver uniforme la escala de los datos de entrada, para que el modelo tenga una convergencia estable (lo que mejora su velocidad de aprendizaje y su rendimiento). En su estudio aplicaron una normalización tipo min-máx. a las características de entrada, para que los datos estuvieran en un rango específico (en este caso se propuso una escala de 0 a 1). Por otra parte, Kim, et al. [22] señalan que es necesario estandarizar los datos por normalización, antes de alimentar los modelos. En su estudio ajustaron la información que tenían recopilada, ya que los sensores que usaron generaban datos multimodales: tubulares y datos de series de tiempo, y algunos modelos, como las CNN no son capaces de manejar series temporales de longitud variable. En este caso se realizó un relleno de ceros, para que las series temporales tuvieran una longitud equivalente. De esta manera, mediante esta fase se busca conseguir datos de entrada con la mejor calidad posible y con el menor número de valores atípicos, antes que sean procesadas por los modelos.

El preprocesamiento debe realizarse considerando el formato de la información y los modelos inteligentes en los que se quiere utilizar. En el caso de las imágenes, su análisis puede ser

complicado, debido a la cantidad de factores que influyen en la calidad de información. En este caso, el preprocesamiento es una etapa útil para mejorar la calidad de la información. Por ejemplo, en el estudio realizado por Chouchene et al. [84], se realizó un preprocesamiento con el que se disminuyó el ruido, mejoró el contraste, se hizo una binarización, etc., para mejorar la calidad de la imagen. Por su parte, Haselmann y Gruber [85], como parte del procesamiento, definieron máscaras para ennegrecer el fondo visible de las imágenes capturadas y separar este segmento de la superficie del producto. Del mismo modo, Mei y Wu [87] aplicaron un método de selección para separar el fondo de la superficie objetivo. Primero, ajustaron el brillo y el fondo de las imágenes en una escala de grises y, a partir de este ajuste, la composición del objeto y los píxeles del fondo se dividieron en dos grupos diferentes. Después, realizaron una intercepción de regiones con líneas de soldadura, mediante la modificación de las imágenes, con el fin de resaltar el área donde se ubicaba este tipo de defecto. Librantz et al. [89] transformaron las imágenes con color a un formato en escala de grises, al promediar los componentes de cada píxel. Como segundo paso, realizaron una segmentación de las imágenes por medio un análisis de textura, a través de funciones Gabor, para reducir la dimensionalidad del vector de características, clasificar las texturas y detectar las regiones de interés.

En el análisis de datos se desea identificar y remarcar las variables que más influyen en el proceso. De este modo, se intenta incrementar la expresividad de las características originales y ayudar el procesamiento de los modelos. En los artículos se puede observar la aplicación de diseño de experimentos (DOE por sus siglas en inglés) para resolver esta situación. Raimee, et al. [98] utilizaron un diseño experimental para determinar la configuración inicial de los parámetros del proceso. Después utilizaron un método RSM y ANOVA para modelar la relación entre la respuesta (calidad del producto, observada como nivel de deformación) y los parámetros del proceso (temperatura del molde y de fusión, presión y tiempo de empaque, y tiempo de enfriamiento). Bensingh, et al. [91] implementaron un diseño ortogonal de Taguchi con el fin de conocer los parámetros que tienen mayor efecto en las dimensiones del producto. Este diseño se consideró como primer acercamiento en el mapeo del proceso y para definir las variables que se usarían en la capa de entrada de la red neuronal. Tsai y Luo desarrollaron un sistema híbrido con RNA y AG para identificar los parámetros óptimos de procesamiento [93]. Ellos también aplicaron un diseño ortogonal de Taguchi para reconocer los factores que más afectan la precisión de la forma del producto en el proceso de inyección, así como para tener un primer acertamiento en la determinación de los parámetros óptimos. Los factores significativos después se utilizaron para realizar un experimento factorial y sus resultados se aprovecharon para establecer un modelo de predicción de RNA.

Aunque el diseño de experimentos es una de las herramientas más utilizadas, algunos estudios utilizan otros métodos para estudiar la influencia de las variables en el proceso de inyección. Ogorodnyk, et al. [113] aplicaron un método de selección (con el algoritmo InfoGain) a los 41 parámetros de la base de datos, para identificar las variables que contienen la mayor cantidad de información del proceso. Con esta aplicación se redujeron a 18 los parámetros que serían ingresados al modelo de RNA. Similar a este caso, Román et al. [105] determinaron el número de parámetros que serían utilizados en el modelo, con pruebas

reológicas, revisión de literatura y por medio de un análisis dimensional “Buckingham Pi”. Como resultado, inicialmente se encontraron siete variables determinantes en el proceso, como el contenido de comonomero y de agente de procesamiento, la velocidad de inyección, etc.

Después de conseguir datos con la calidad adecuada y de mapear el proceso, el siguiente paso, antes de programar el modelo, consiste en separar los datos que se usarán para entrenar y evaluar el modelo inteligente. De acuerdo con la información de los artículos obtenidos, los datos de entrenamiento son entre el 70 y 80% de los datos totales, mientras que el resto (20-30%) es destinado para la evaluación de los modelos. La razón de esta relación es ayudar a conseguir los parámetros más adecuados para el modelo y que se evite el sobreajuste. Los datos de prueba se pueden permitir ser menos, ya que con ellos solo se comprueba el funcionamiento y evalúa el rendimiento del modelo (es decir, si logra describir el proceso de inyección lo más cercano a la realidad).

4.2.3.3 Desarrollo, entrenamiento y prueba de modelo

En general, las técnicas de IA funcionan mejor en diversas áreas industriales, por lo tanto, su selección debe ayudar a resolver el reto que se proponga y aprovechar los elementos con los que se cuenta, como los formatos de datos y dispositivos. Si bien en este estudio no se hace énfasis en los códigos de programación, sí se expondrán algunos puntos que se han identificado necesarios para la implementación de los modelos. Ya que cada modelo inteligente requiere parámetros específicos para su funcionamiento, en este segmento se hará énfasis en el desarrollo de las RNA, la cual es la técnica con mayor utilización en la industria de inyección.

Como se mencionó antes, el funcionamiento y rendimiento de las redes neuronales depende totalmente de su estructura y de los hiperparámetros que se implementen. El análisis de parámetros, de la etapa anterior, sirve para iniciar la definición de la configuración de la red. Las variables que se encontraron influyentes del proceso, de acuerdo con el problema que se quiere tratar, se utilizarán como los nodos de entrada del modelo; mientras que la salida será definida por la función objetivo. En el caso del número de nodos y capas ocultas, su definición puede resultar más complicada, ya que los valores que se utilicen afectarán la convergencia del modelo. En algunos estudios, la obtención de estos elementos se realiza mediante ensayos de prueba y error. Como en el estudio hecho por Librantz et al. [89], en donde para determinar las neuronas de la capa oculta se realizaron varios experimentos modificando este parámetro y comparando su eficiencia, mediante el cálculo del error cuadrático medio.

Ke y Huang [102] indican que la cantidad de capas ocultas del modelo basado en MLP se puede determinar por el número de los intervalos de calidad que se manejan en el sistema. Además, comentan que el número de neuronas se puede ajustar mediante múltiplos de la cantidad de nodos en la capa de entrada. En su investigación, para determinar el número de nodos, propusieron tres ensayos basados en una relación entre las neuronas de la capa oculta y las de la entrada (1:1, 2:1, 3:1). Como resultado, hallaron que la configuración óptima de

la red está conformada por el mismo número de neuronas de la capa de entrada. Otras investigaciones han utilizado otros métodos para delimitar la estructura del modelo. Chen et al. [180] encontraron que, para su caso, el número de capas ocultas no tenía ningún efecto significativo en la convergencia del sistema, por lo que el número se determinó como 1. Respecto al número de neuronas en esta capa, su obtención se realizó mediante el método propuesto por Khaw et al. y Haykin.

4.2.3.4 Entrenamiento del modelo

El entrenamiento de los modelos es una etapa de gran importancia para la implementación de tecnología inteligente eficaz y precisa. Este proceso consiste en ajustar los valores de los parámetros de los modelos, a partir de un conjunto de datos reales, preprocesados, cuyos resultados ya son conocidos. Mediante este ajuste se busca que el modelo pueda identificar las neuronas y conexiones que tienen mayor influencia en el proceso, y su relación entre ellos y la variable de respuesta. Con este objetivo se pretende que el funcionamiento del sistema consiga el menor error posible en sus resultados, al comparar el valor de salida del modelo y el valor del conjunto de datos reales. En el caso de las RNA, el entrenamiento de los parámetros conlleva la modificación de los pesos y sesgos de las neuronas⁵¹. Al finalizar este proceso, el modelo almacena estos parámetros para ejecuciones posteriores, en los que se utilizarán nuevos datos de entrada. Este procesamiento se acompaña de métodos matemáticos que favorecen su desarrollo, entre los que destacan el algoritmo *backpropagation* y optimización por descenso de gradiente [133].

Durante esta etapa, la reasignación de pesos y sesgos requiere múltiples iteraciones y puntos de datos para crear una representación válida del proceso, lo que vuelve este proceso complicado [105]. Con el fin de evitar que el sistema se sobreajuste⁵² y, por lo tanto, pueda aprender correctamente el proceso, se deben tomar en cuenta algunos métodos y situaciones que facilitan el entrenamiento. La técnica de abandono (o *dropout*) es una de las técnicas que se más utiliza durante el entrenamiento para evitar el sobreajuste, ya que permite en esta etapa desactivar los valores de neuronas, elegidas al azar. Por ejemplo, esta técnica de regularización fue utilizada en [86], por Muresan, Cireap y Giosan, para desarrollar un sistema de inspección inteligente. El entrenamiento lo realizaron sobre un conjunto de datos, provenientes de imágenes de los casquillos ubicados en diferentes posiciones, durante 100 épocas, con un optimizador Adam, la técnica *dropout* y una tasa de aprendizaje de 0.0001.

El método de parada temprana (*early stopping*) también es utilizado en la etapa de entrenamiento de los modelos para evitar el sobreajuste. Esta técnica consiste en pausar el

⁵¹ Antes de realizar el entrenamiento de las RNA se recomienda inicializar estos parámetros, ya que la falta de valores de inicio para estas variables puede dificultar el proceso de aprendizaje, al requerir más tiempo de procesamiento. Para ello, se pueden delimitar aleatoriamente los pesos, por ejemplo, a partir de métodos estadísticos, como la distribución estándar o la distribución uniforme, con el fin de lograr una convergencia más rápida durante el entrenamiento [132].

⁵² El sobreajuste u *overfitting* sucede cuando el modelo se ajusta exactamente a los datos de entrenamiento. Esto puede ocurrir cuando el modelo se entrena durante demasiado tiempo, cuando el modelo es demasiado complejo o si se utilizan pocos datos en durante el entrenamiento. En este caso, el modelo ya no puede efectuar las tareas para las que fue diseñado, ya que no puede generalizarse a nuevos datos [134], [135].

proceso de entrenamiento antes de que el modelo comience a aprender del ruido presente en los datos, con el fin de mantener el proceso de entrenamiento al mínimo oportuno [97]. Dentro de los artículos recabados, es posible observar el uso de dropout junto con la parada temprana. Kim et al. [22] desarrollaron un sistema inteligente, compuesto por tres tipos de redes posicionados en forma paralela: MLP, RNC y GRU, para abordar la inspección de calidad. El dropout lo aplicaron a una capa de la red MLP, con el fin de convertir la red en varias subredes y, con ello, mejorar los errores de generalización. Por otra parte, el método *early stopping* fue implementado durante la etapa de entrenamiento, la cual realizaron para todo el sistema híbrido, en lugar de entrenar cada red de forma individual. Estos recursos favorecieron el aprendizaje del modelo inteligente, el cual demostró tener mejor rendimiento que los sistemas con una sola técnica y que otros sistemas híbridos de RNA.

Otro recurso que influyen determinantemente en el aprendizaje del sistema durante el entrenamiento es la cantidad de datos que se emplean en esta etapa. Es importante que los datos que se recopilen contengan información que haya sido preprocesada y que esté relacionada con el proceso (como las variables que pueden influir en él y sus resultados), para tener un aprendizaje correcto y eliminar las posibles fuentes de error.

Se ha reportado que una causa común del sobreajuste en el entrenamiento es el poco volumen de información con el que se dispone en esta etapa, por lo que es imperante que cualquier implementación de IA que se desee hacer incluya una suficiente cantidad de datos [134], [135]. Esto lo podemos apreciar en las bases de datos empleadas en la creación de los sistemas inteligentes, las cuales contienen conjuntos de cientos, hasta miles⁵³, de datos que fueron utilizados para el entrenamiento y la evaluación de los modelos.

Tabla 10. Datos utilizados en la implementación de modelos basados en IA.

Ref.	Técnica IA	Reto industrial	Datos totales	Datos para entrenamiento	Datos para evaluación
[76]	RNA	Control parámetros	4529	3623	906
[22]	RNA	Inspección calidad	2000	-	-
[86]	RNA	Inspección calidad	8000	-	-
[88]	SVM	Inspección calidad	966	644	322
[89]	RNA	Inspección calidad	3420	-	-
[90]	RNA	Monitoreo parámetros	54688	-	-
[91]	RNA	Optimización	572	520	52
[93]	RNA+AG	Optimización	729	540	189
[101]	RNA	Predicción de calidad	12420	-	-
[102]	RNA	Predicción de calidad	4895	3949	946
[104]	AD	Predicción de calidad	24667	-	-
[105]	RNA	Predicción de calidad	2313	1917	396
[108]	RNA	Predicción de calidad	1600	1200	400
[109]	RF	Predicción de calidad	18354	13202	5152

⁵³ Existen casos en los que utilizaron más datos para la implementación, sin embargo, estos se exponen aparte, ya que utilizaron técnicas para generar información.

[111]	RNA	Predicción de calidad	2970	1981	989
[112]	RNA	Predicción de calidad	204	177	27
[113]	RNA	Predicción de calidad	2880	-	-
[114]	RF	Predicción de calidad	14106	10484	3622
[115]	RNA+SVM	Predicción de calidad	238962	191170	47792
[80]	AD	Protección componentes	17203		

De la tabla 10 se puede notar que la técnica de los árboles de decisión y los bosques aleatorios, en la inyección de plásticos, son las técnicas que necesitan más información para su elaboración. Las investigaciones que utilizaron estos modelos utilizaron desde 14000 hasta 24000 datos para desarrollar el sistema inteligente. Lo anterior favorece a trabajar con otras técnicas como RNA, en donde se tiene un rango más amplio de datos para su desarrollo.

De los estudios relacionados con las redes neuronales (sin estar combinadas con otra técnica de IA) encontramos uno, en donde se utilizaron solamente 204 imágenes para entrenar y validar un modelo dedicado a la predicción de calidad [112], y otro que necesitó menos de 600 datos para elaborar un sistema capaz de optimizar parámetros [9]. No obstante, también existen otros casos en donde se necesitó más información para construir el modelo, como en el trabajo hecho por Hsu et al. [90], en donde se aplicaron 54688 datos para desarrollar un modelo dedicado al monitoreo de parámetros.

La cantidad de datos que deben recopilarse, para la implementación de los modelos inteligentes, varía entre un caso y otro. Esto puede atribuirse a la complejidad de los problemas, el tipo de técnica usada y la propia capacidad de la industria para producir los datos. Debido a que la creación de bases de datos amplias puede ser un proceso tardado y costoso, resulta necesario mencionar que existen otras opciones para conseguir datos de buena cantidad y calidad. Por ejemplo, Böttjer et al. [90] utilizaron la base de datos de un socio industrial, compuesta por 17203 muestras, para implementar un modelo con XGBoost (basado en árboles de decisión). El contenido de la base de datos estaba formado por revisiones hechas a 13 moldes distintos, con la misma geometría dentro de sus cavidades y usados en diferentes máquinas de inyección; y también por datos normalizados sobre las causas de mantenimientos realizados al molde. Aunque el proceso de obtención de datos requirió una gran cantidad de tiempo (9 años), esta información fue de gran utilidad para los autores. El uso de estos datos ayudó no solo a desarrollar un sistema capaz de clasificar el nivel de desgaste de los moldes, sino también a confirmar que una de las consecuencias de trabajar con equipos degradados es provocar que las dimensiones de los productos cambien sistemáticamente con el tiempo.

Otro modelo que requirió una gran cantidad de información fue el desarrollado por Silva, Sousa y Alenya [115]. Mediante su sistema inteligente, basado en RNA y SVM, se buscó predecir la calidad de los productos por medio de su peso y anticiparse a la producción de piezas con defectos de rebaba o incompletas. Estos investigadores crearon una base de datos que incluía 39827 ciclos de inyección, con 892 muestras de piezas con no conformidades. El contenido de esta base estaba compuesto por la producción industrial de cinco días y el control de calidad hecho para todas las piezas elaboradas durante esos días. La información

compilada incluyó cinco parámetros de operación: tiempo de inyección, tiempo de plastificación, tiempo ciclo, cojín (o *cushion*) y presión máxima de inyección; y una variable de calidad relacionada con el peso del material. En este caso, el tiempo de obtención de datos fue mucho menor que los nueve años del estudio anterior, no obstante, es importante remarcar que, a nivel industrial, dedicar cinco días para inyectar piezas de prueba puede significar una pérdida económica considerable. Esto se debe a que, a pesar de que las muestras inyectadas buenas pueden aprovecharse después del estudio, la generación de piezas malas representa un desperdicio considerable de recursos.

En general, en la industria no es sencillo crear una base de datos extensa. Los datos experimentales, al relacionarse con la producción de piezas buenas y con defectos, pueden representar un alto costo, ya que para conseguirlos se requiere el involucramiento de una gran cantidad de recursos (materia prima, tiempo o mano de obra). Esta situación representa un gran inconveniente para cualquier industria, especialmente para las pequeñas y medianas, las cuales no disponen fácilmente de todos estos recursos. Por este motivo, se ha buscado implementar otros métodos y herramientas para conseguir datos útiles en el desarrollo de tecnología inteligente. Haselmann y Gruber desarrollaron un su sistema inteligente con la función de detectar de la superficie de los productos [85]. Para ello, crearon una base de datos compuesta por 1055862 imágenes de productos, obtenidas de cuatro direcciones distintas de visualización. Un punto interesante de este set de datos es que fue formado mediante la implementación del método de Haselmann y Gruber, el cual consiste en utilizar un algoritmo para sintetizar defectos artificiales en imágenes de productos de buena calidad. Por medio de este método, se logró insertar una gran diversidad de defectos morfológicos del producto y cubrir diferentes características de las imágenes, como contrastes y cambios en la intensidad. Esta herramienta representa un gran apoyo para la construcción de bases de datos, ya que para la creación de imágenes con defectos, solo es necesario utilizar piezas buenas, lo que implica que no haya desperdicio de recursos.

Lockner y Hopmann utilizaron una técnica de transferencia de aprendizaje (TA) para reducir la cantidad de datos necesaria en la implementación de una red neuronal [97]. En esta investigación se abordó el caso en el que se requiere ajustar una red neuronal, basada en otra red ya formada, para incluir productos desconocidos. En este estudio compararon el entrenamiento tradicional, con el uso de la técnica de transferencia de aprendizaje en redes neuronales ya creadas, para el aprendizaje de nuevos productos. Esta implementación fue dividida en tres escenarios en donde una RNA fue transferida con: 1) la capa de entrada, ya entrenada, y la capa oculta y de salida sin entrenar; 2) las capas de entrada y oculta entrenadas, y la capa de salida sin entrenar; y 3) todas las capas ya entrenadas. En el documento mencionan que, una de las ventajas de trabajar con esta técnica es la posibilidad de elaborar nuevos modelos inteligentes, con un buen funcionamiento, que sean capaces de adaptarse rápido y que requieran menor esfuerzo de entrenamiento, en comparación con los entrenamientos convencionales. En sus conclusiones señalan que es posible conseguir efectos positivos en el funcionamiento del modelo, con cualquiera de los tres tipos de transferencia que se recurra. Específicamente, cuando se hace una transferencia total del modelo y se hace un reentrenamiento posterior, se puede superar la capacidad del resto de

los enfoques (especialmente del aprendizaje convencional). Por lo tanto, la transferencia de aprendizaje es una buena técnica para reducir la cantidad de datos necesarios en el entrenamiento de los modelos, ya que con ella lograron reducir el 88% de los datos que se necesitaron con el entrenamiento normal.

La etapa de entrenamiento es indispensable para generar modelos inteligentes con alta capacidad de funcionamiento. En general, en esta etapa se busca que los modelos consigan un buen aprendizaje del problema que se quiere abordar y eviten problemas como el sobreajuste. Con este objetivo, en los estudios compilados utilizaron técnicas y métodos que facilitaron el entrenamiento de los modelos, como dropout y *early stopping*, no obstante, el factor determinante para el éxito de esta etapa fue la cantidad de datos que usaron. Chen et al. [108] señalan que la terminación del aprendizaje de los modelos puede ocurrir cuando se completaron los ciclos de entrenamiento, y cuando el error cuadrático medio entre el valor esperado y el valor de salida de la red se ha reducido a un valor determinado. Una vez que el modelo fue entrenado, y que se delimitaron sus hiperparámetros, los siguientes pasos consistieron en hacer un proceso de validación y evaluación del sistema inteligente⁵⁴.

4.2.3.5 Evaluación y optimización

El objetivo de la evaluación es verificar la capacidad real que tiene el modelo inteligente para cumplir las funciones que se le programaron. Durante esta fase se utiliza un conjunto de datos para alimentar los modelos ya entrenados, con el fin de comprobar su nivel de precisión, al comparar los resultados del modelo con los valores reales del conjunto de evaluación. En general, este grupo de datos es independiente de los datos empleados durante el entrenamiento y, además, está compuesto por una menor cantidad de valores.

Las métricas de evaluación que se utilizan en esta etapa permiten la obtención de la capacidad del modelo y, además, sirven como indicador para seleccionar el sistema con los mejores resultados (esto a razón de que, en la implementación de IA, es común proponer distintos modelos inteligentes). En los artículos recopilados se apreció principalmente el uso de las métricas: matriz de confusión, nivel de precisión, recall, puntuación F1 y la curva ROC, como primer acercamiento para conocer el rendimiento de los modelos con IA.

Uğuroğlu desarrolló diferentes técnicas inteligentes capaces de clasificar los productos de inyección en piezas buenas y malas [114]. En su investigación, utilizó la matriz de confusión para seleccionar el mejor modelo inteligente. Esto al revisar el número de predicciones verdaderas y falsas que podían generar. Dicha métrica se complementó con un estudio de precisión, sensibilidad (recall), exactitud y de la curva ROC para cada técnica. A partir de los resultados obtenidos, Uğuroğlu señala que, para mejorar la precisión de los modelos fue necesario disminuir los casos relacionados con los falsos negativos detectados en la matriz de confusión. Esto resulta del significado de este escenario, el cual se refiere de los casos en

⁵⁴ Aunque la validación permite realizar ajustes de los parámetros del modelo después de la evaluación, se tiene el inconveniente de necesitar un conjunto de datos que podrían ser utilizados en el entrenamiento. Esta situación puede ser un problema para el desarrollo de los modelos, especialmente cuando se cuenta con un set de datos pequeño.

los que el modelo etiqueta como OK un producto que tiene defectos (y que posteriormente será enviado al cliente). El otro error que puede detectarse en la matriz de confusión es cuando se produce un falso negativo, sin embargo, el autor indica que este caso no es grave, ya que se trata del escenario en el que se clasifica un producto incorrecto, pero que en realidad es de buena calidad. La razón de aceptar este tipo de error es por su nivel de criticidad, ya que sugiere que el personal de la planta podría hacer una inspección visual de los productos que fueron etiquetados como defectuosos y separar aquellos que no fueron clasificados correctamente. De esta manera, la decisión de preferir entre un modelo y otro consiste en distinguir aquel que presente la menor cantidad de falsos positivos.

La técnica de validación cruzada, VC (o cross validation) es una de las técnicas más importantes en la implementación de técnicas de IA, ya que prohíbe el ajuste excesivo del modelo y garantiza el rendimiento de generalización, además que es una buena herramienta para los casos en los que no se tiene un gran volumen de datos [103]. De acuerdo con Chen et al. [107], la técnica CV es especialmente útil para estimar qué tan precisos son los modelos dedicados a la predicción. Básicamente, en esta técnica se divide la muestra de datos en subconjuntos complementarios, también llamados capas o pliegues, los cuales son utilizados como subconjuntos de entrenamiento y evaluación. Después, se entrena y evalúa el modelo, de acuerdo con el número de pliegues definidos, y se obtiene el valor de error de cada iteración. Finalmente, se conoce el valor del rendimiento real del modelo, al promediar el error de cada proceso. El interés en usar esta técnica es que permite la estimación de los parámetros en los modelos, al evaluar sus rendimientos, y facilita la selección de los sistemas que presentan el menor error. En los artículos recopilados, se puede apreciar el uso de esta técnica con cinco [50], [101], [104], [110], [131] y 10 capas [88], [113], [136].

Maarif et al. [111] desarrollaron dos modelos de RNA, dedicados a la predicción de calidad: una red tradicional con BP y otra en la que se implementó un algoritmo de aprendizaje SLF (aprendizaje estructural con olvido, por sus siglas en inglés). En dicho estudio, se utilizó la matriz de confusión como primera opción para determinar que el arreglo neuronal con el algoritmo de aprendizaje presentaba los mejores resultados de predicción. Con esta herramienta se pretendió conocer, de forma sencilla, si los modelos podían predecir correctamente los casos en donde se inyectaban productos buenos y con defectos. Para tener una comprensión mejor de los modelos que se querían comparar, también calcularon las métricas: precisión, sensibilidad, exactitud y el puntaje F (todas basadas en los valores obtenidos de la matriz de confusión), y además implementaron un método de validación cruzada de 10 capas. A partir de tales análisis se obtuvo que las diferencias estadísticas entre una red y otra no eran significativas, lo que significaba que la técnica de aprendizaje permitió obtener un modelo más simple, en donde se aprovechaban las conexiones entre neuronas que tenían un atributo significativo en la precisión de las predicciones.

Existen técnicas de optimización pueden facilitar el ajuste de estos hiperparámetros y que han demostrado ser efectivos en los sistemas para la industria de inyección. Mediante este enfoque se ha buscado favorecer el funcionamiento de los modelos, al obtener la mejor configuración posible. De la información reportada en el Anexo 1, las herramientas que han sido reportadas con mayor uso son: la búsqueda en cuadrícula (o rejilla) y la búsqueda

aleatoria.⁵⁵ La primera técnica considera exhaustivamente todas las combinaciones de parámetros para determinados valores del modelo. Aunque se puede tomar como el algoritmo más simple para el ajuste de hiperparámetros, su procesamiento puede ser lento. En la búsqueda aleatoria se muestrea un número determinado de posibles ajustes, a partir de una distribución de valores especificada. En este caso se puede establecer un rango de valores posibles para cada hiperparámetro o una lista de valores discretos, que se muestrean de forma uniforme a lo largo del proceso⁵⁶ [137].

De los artículos recopilados, la técnica de optimización más utilizada, para la inyección de plásticos, es la búsqueda de cuadrícula. Su uso puede apreciarse especialmente en la predicción de calidad, para modelos de redes neuronales [103], [104], [106] y SVM [115], [50]. Por ejemplo, Tercan, Deibert y Meisen [106] desarrollaron un sistema para predecir la calidad del producto, mediante RNA. Ellos utilizaron la búsqueda de cuadrícula en los datos para encontrar la topología e hiperparámetros de mejor rendimiento. Como resultado obtuvieron una RML de dos capas ocultas, con 20 neuronas en cada una de ellas y función de activación ReLU. Del mismo modo, Ribeiro [50] utilizó este método para seleccionar los hiperparámetros que funcionarían mejor en un modelo SVM y así evitar un sobreajuste. En el artículo remarca que el parámetro de regularización, C , es un hiperparámetro difícil de seleccionar para SVM, ya que puede conducir fácilmente a un sobreajuste del modelo, por lo que es de gran utilidad usar métodos de optimización para encontrar el mejor valor de este término.

El método de búsqueda aleatoria ha sido utilizado en retos de inspección de calidad y optimización de parámetros. Kim et al. crearon un sistema inteligente dedicado a la inspección de calidad [22]. Para desarrollarlo aplicaron un método de búsqueda aleatoria, con el propósito de mejorar los hiperparámetros del modelo RNC. Aunque su implementación puede apreciarse en sistemas basados en redes neuronales, este método también puede funcionar con otras técnicas de IA.

Otro método para delimitar los mejores hiperparámetros, utilizado igualmente en la inyección de plástico, es la optimización bayesiana. Mediante esta optimización se propone un nuevo conjunto de hiperparámetros en cada iteración, utilizando un proceso gaussiano, y se evalúa el rendimiento del modelo con los hiperparámetros propuestos, hasta conseguir los valores óptimos. Román et al., en [105], lo implementaron para determinar la mejor configuración del RNA. En su documento reportan que este método permitió a los hiperparámetros converger con menos recursos computacionales y en menos tiempo, en comparación con la búsqueda de cuadrícula. También agregan que, aunque otras herramientas, como la búsqueda

⁵⁵ El optimizador Adam se utiliza principalmente en la configuración de las redes neuronales y se especializa en mejorar el proceso de aprendizaje del modelo, al adaptar la tasa de aprendizaje de cada parámetro individualmente en cada iteración. Su uso no debe confundirse con los métodos de optimización “búsqueda aleatoria y en cuadrícula”, ya que éstos permiten el ajuste de hiperparámetros de la arquitectura y del entrenamiento, para diferentes técnicas de IA. Sin embargo, es posible desarrollar un sistema inteligente utilizando ambos métodos, como en [22] donde utilizaron el método de búsqueda aleatoria y el optimizador Adam.

⁵⁶ Una ventaja que se tiene al considerar estas técnicas de optimización es que, en la biblioteca Sckit-learn y Keras se proporcionan en su forma genérica para la búsqueda de parámetros [137], [138].

aleatoria, pueden superar la optimización bayesiana, generalmente se necesita más información para reducir el espacio de búsqueda entre los hiperparámetros [131].

El uso de una validación cruzada, junto con el método de búsqueda de cuadrícula son útiles para la evaluación y mejora de los modelos inteligentes. Zhao et al. [92] menciona que con estos métodos es posible modificar los hiperparámetros, hasta conseguir el mejor funcionamiento del sistema. No obstante, señalan que el inconveniente para su aplicación es que se requiere una gran cantidad de muestras para que se tengan buenos resultados. Esta situación motivó al desarrollo de su estudio, en donde implementaron un criterio distinto para ajustar un modelo SVC (clasificador de vectores de soporte, por sus siglas en inglés), el cual es derivado del SVM. En su estudio, después de entrenar y seleccionar las funciones kernel del modelo, aplicaron el algoritmo PSO ⁵⁷(optimización por enjambre de partículas) para determinar los mejores hiperparámetros y mejorar la precisión del modelo. De forma similar, en [115], Silva, Sousa y Alenya utilizaron PSO para encontrar la mejor configuración de una red neuronal con BP, ya que señalan que esta técnica permite conseguir una mayor tasa de convergencia, con menos pasos operativos. Sin importar el método que se elija, la optimización de modelos es una actividad que ayudará a mejorar la capacidad del sistema que se desarrolle, al disminuir el error e incrementar la precisión de sus resultados.

4.3 Resultados de un modelo inteligente óptimo

El resultado de realizar cada una de las etapas de desarrollo adecuadamente es la creación de un sistema inteligente óptimo, capaz de abordar las funciones que se le tienen delimitadas. Mediante su creación se ha buscado mejorar la forma en que se realizan los procesos, al reducir riesgos laborales, aprovechar los recursos e incrementar el rendimiento. Con esto en mente, los estudios que se han hecho para incluir tecnología con IA en la industria de inyección han demostrado ser capaces de adaptarse en diversas actividades involucradas proceso de inyección.

A partir de la información recopilada en el anexo 1, se puede notar que este tipo de tecnología ha sido implementada exitosamente en diversos retos industriales. La predicción de calidad es una de las áreas más tratadas en la inyección de plásticos. En ella se pretende anticipar el resultado de la producción (en términos de calidad del producto), al monitorear la evolución de los parámetros en las máquinas. Por ejemplo, en la investigación hecha por Chen, et al. [108] se elaboró un modelo capaz de predecir la calidad del producto, contemplada con el peso de la pieza. Su modelo final consideró el monitoreo de solo seis parámetros de la operación para conseguir resultados atractivos, con raíz del error cuadrático medio de 0.0017. Charest, Finn y Dubay también implementaron un sistema basado en RNA para la predicción de calidad [101]. No obstante, su innovación se basó en la predicción de la presión máxima de la cavidad, considerada como un indicador de piezas defectuosas por disparos de inyección cortos. Al detectar una pieza errónea, se programó al sistema para indicar que podía

⁵⁷ El objetivo de este algoritmo es encontrar la solución óptima mediante la colaboración y el intercambio de información entre los individuos de un grupo. El grupo de partículas o soluciones se inicializa aleatoriamente en el espacio de la solución y a cada partícula se evalúa su valor de aptitud.

sucedier un problema y, ademas, sealar los parametros que se deban cambiar para resolverlo. El porcentaje de clasificacion que alcanzo fue de 87% que, aunque no parece ser considerablemente alto, representa un resultado alentador, ya que con la forma tradicional con que se enfrentan los problemas se pueden desperdiciar muchos recursos, debido a la dificultad para encontrar el origen del evento no deseado.

Otro reto que tambien resalta en la generacion de tecnologa con inteligencia artificial es la inspeccion de calidad. El enfoque que se le da con este tipo de herramientas es mejorar la forma manual con la que se revisan los productos. La forma tradicional de inspeccion esta relacionada con varios factores que limitan su eficiencia y dan paso a la produccion de material incorrecto. Las herramientas con IA ofrecen diferentes ventajas en este mbito, como la revision del 100% de la produccion y observaciones mas uniformes y con mayor precision. Por ejemplo, en la investigacion hecha por Chen, et al. [83] desarrollaron un sistema de deteccion de defectos, mediante una inspeccion ptica automtica. Su funcion consista en descartar el fondo de la imagen, para mejorar la inspeccion del producto; y detectar defectos de la superficie (rayaduras). Cabe destacar que, ademas de la revision de productos, la inspeccion computarizada apoyada de la inteligencia artificial ofrece diversas funcionalidades en la industria de inyeccion. Por ejemplo, Librantz et al. elaboraron un sistema de inspeccion capaz de examinar y evaluar la superficie de los moldes (componente crtico en la inyeccion de plsticos) [89]. Dicho modelo fue programado para automatizar el anlisis de la superficie de pulido, por medio de un laser dispersado en la superficie. Del mismo modo este modelo demostro ser capaz de identificar algunos defectos en la superficie, como los rayones y el sobrepulido, lo que ayudo a disminuir el tiempo y el costo que generalmente se involucra en esta tarea.

Si bien, dentro de los artculos recopilados, se pueden apreciar diversas reas del proceso en donde se aplico la inteligencia artificial; el objetivo general que se ha perseguido con esta tecnologa es conseguir el control de las actividades industriales. Mediante esta aplicacion, se espera aprovechar los recursos, reducir los desperdicios, e incrementar la eficiencia del proceso de inyeccion. Aunque han sido pocos los estudios que se han encontrado en esta rea, los beneficios que se obtienen de ella son destacables. Tal es el caso del sistema desarrollado por Cui y Wang [77], el cual fue diseado para diagnosticar fallas y optimizar parmetros. Dicho sistema fue configurado para trabajar de forma autnoma o para alertar a los operadores de que deban realizar una reparacion manual. Ademas, se le programo la capacidad autoaprendizaje, con la cual poda guardar informacion sobre las reparaciones manuales que se le hacan, para utilizarla en el anlisis de problemas futuros.

Las reas de implementacion de tecnologa con IA han incrementado en los ltimos aos. Los beneficios que se pueden conseguir con su uso han impulsado a las industrias manufactureras a integrarlas en su cadena de valor. Con base en la informacion reportada en Scopus y Compendex, la industria de inyeccion ha tenido buenos resultados al adoptar este tipo de tecnologa en sus procesos, ya que se aprecia un aumento en el nmero de investigaciones relacionadas con la implementacion de IA. El estudio y anlisis de los casos de xito pretende identificar los puntos clave del desarrollo de tecnologa inteligente con el fin de acercar a la industria nacional a la actual industria 4.0.

Capítulo 5. Conclusiones y recomendaciones

Los avances de la industria 4.0 han cambiado la forma en que se han concebido los procesos industriales. La versatilidad de sus herramientas, como la inteligencia artificial, ha facilitado su integración en las diferentes cadenas de valor de las industrias manufactureras. Específicamente, en las industrias de inyección se han realizado investigaciones para poder integrar en sus procesos esta tecnología y conseguir los beneficios que esta conlleva. En México, el papel que tiene la industria de plástico es tal que, tan solo el 5% el PIB manufacturero proviene de esta actividad. Con la llegada de la industria 4.0, el potencial de este tipo de industria puede incrementarse significativamente, al mejorar su rendimiento y con ello, su competitividad. Esto representa un reto para la industria mexicana, ya que actualmente se estima que su nivel de productividad es menor del 80% de su capacidad ideal.

Ante este panorama, la presente tesis tuvo como objetivo elaborar una metodología de implementación que ofrezca elementos necesarios para integrar tecnología inteligente en procesos específicos de la industria de inyección. Del mismo modo, con la formulación de esta metodología se busca motivar a que la industria nacional de inyección desarrolle herramientas que mejoren sus procesos e incrementen su competitividad, ante un entorno mundial en donde los procesos son cada vez más autónomos y eficientes. Con este fin, a lo largo de este trabajo de investigación se revisaron algunos casos en los que se implementó exitosamente este tipo de tecnología en los procesos de inyección. A partir del análisis se determinaron los siguientes elementos como los más significativos para el desarrollo de tecnología inteligente:

1. Retos más relevantes de la industria de inyección de plásticos

A partir del análisis y búsqueda de información realizado, sobre la industria de inyección, se definieron algunas actividades con diversos niveles de riesgo relacionados a la capacidad y calidad productiva; y a la seguridad de las personas relacionadas estas tareas. Se seleccionaron los parámetros y máquina de inyección; y el factor humano relacionado con la manipulación de las máquinas y productos, como los retos más relevantes de la cadena de valor del proceso de inyección de plásticos, debido a su nivel de relevancia reportada en la literatura y por el número de desarrollos tecnológicos que se han hecho con la tecnología inteligente, los cuales facilitaron la consolidación de la metodología de implementación.

Los parámetros y componentes de las máquinas de inyección se han reportado como los principales generadores de defectos de los productos plásticos y, además, su manejo puede relacionarse a riesgos considerables para la salud de los operadores. Por otra parte, al ser una industria que requiere tradicionalmente de la intervención de las personas para desarrollarse, el papel que tienen los operadores en el proceso de inyección es elevado. El siguiente paso consistió en identificar las funciones que se ha dado a las IA con mayor frecuencia para abordar dichos retos.

2. Función industrial de la tecnología con IA

Con la información recopilada se pudo observar que la implementación con IA en la industria de inyección aún no ha sido lo suficientemente explorada, ya que aún no hay tantos documentos disponibles para su revisión. Por este motivo, se recomienda abordar aplicación de predicción de calidad, ya que es una de las áreas que más se han trabajado con IA y, por lo tanto, se podría conseguir más información de referencia. Mediante esta función se puede anticipar el estado del producto y así evitar la producción de piezas defectuosas, incluso hasta con tres inyecciones de anticipación. Al trabajar con esta función, se sugiere considerar la dimensión del producto como objetivo de la predicción, ya que en la mayoría de los estudios se ha asociado esta variable con la calidad del producto.

3. Dispositivos

Dentro de la infraestructura física que más se ha utilizado en la implementación de los modelos inteligentes relacionados con la predicción de calidad (o con cualquier otro reto) el equipo de cómputo es uno de los equipos más importantes. En algunos estudios se han descrito algunas especificaciones de estos dispositivos, de los cuales se puede destacar el uso de procesadores Intel Core i5 e i7; frecuencias de 1.80 a 2.8 Ghz, y memorias RAM desde 3 a 16 GB. Las características de los computadores facilitan, no solo la ejecución de los programas para los modelos de IA, sino también permiten la conexión entre el resto de los dispositivos que se utilicen.

Otros de los dispositivos que se deben incluir en los sistemas de implementación de IA se relacionan con la medición de parámetros y la comunicación entre dispositivos. Concretamente, la presión y temperatura se consideran unas de las variables más determinantes en la inyección. Su estudio se puede realizar en diversos puntos del proceso, sin embargo, la mayoría de las investigaciones se han enfocado en monitorear, por medio de sensores, los cambios de T y P que ocurren en la cavidad del molde. Los sensores piezoeléctricos y los termopares, especialmente de la marca Kistler, han sido los dispositivos más utilizados en el cumplimiento de esta tarea.

Por otra parte, también se sugiere añadir al sistema medidores de flujo, con el fin de conocer la dinámica del refrigerante, durante la etapa de enfriamiento del molde. Asimismo, para facilitar la comunicación entre los diversos equipos (como sensores y el ordenador), se ha observado la utilidad de usar los amplificadores de carga e interfaces de comunicación.

4. Softwares, programas y lenguajes de programación

En este rubro se ofrecieron dos opciones a considerar para desarrollar el modelo de inteligencia artificial: Python y MATLAB. Python es el lenguaje de programación más utilizado en las investigaciones para la creación de sistemas inteligentes, debido a su eficiencia y flexibilidad de uso en diversas plataformas. La codificación de los modelos se hace principalmente con las bibliotecas de programación TensorFlow, Keras y Scikit-Learn, por su compatibilidad con diversos procesadores y su facilidad de uso. Por otra parte, MATLAB es un medio de programación, en donde se pudieron escribir los códigos de los

modelos y ejecutar las diferentes etapas de la implementación. Cabe resaltar que también es posible desarrollar sistemas inteligentes mediante el uso de ambos recursos, no obstante, se recomienda utilizar el medio que sea más cómodo para el usuario.

Los simuladores han demostrado ser una buena herramienta en las diversas etapas del proceso de creación. Pueden ayudar a crear la base de datos que será usada en el entrenamiento y evaluación del modelo; y también a identificar los rangos operativos de diferentes productos. En este sentido, se recomienda utilizar el programa Moldflow por su preferencia en los estudios recopilados.

5. Técnica de inteligencia artificial

De todas las técnicas de IA reportadas en la literatura, para la industria de inyección, se propone trabajar con las redes neuronales artificiales, ya que en la mayoría de los estudios ha demostrado conseguir buenos resultados en la predicción de calidad (y también para el resto de los retos industriales). Particularmente, el tipo de red *multilayer perceptron* ha mostrado adaptarse mejor a las funciones necesarias para la predicción de resultados.

Se ha observado que la estructura de las redes neuronales es diferente entre un estudio y otro. Sin embargo, la mayoría de las RNA reportadas en los artículos compilados estaba conformada por tres o cuatro capas (una de entrada, una de salida y una o dos capas ocultas). En general, los nodos utilizados en la primera capa están relacionados con los parámetros que más influyen en el problema planteado y los de la última se refieren a los objetivos del modelo (por ejemplo, si el sistema busca predecir la dimensión de tres lados de una pieza, se tendrán tres nodos en la capa de salida; si se define el peso del producto como la característica de calidad que se desea anticipar, se considera solo una neurona en la salida).

La determinación de las neuronas de las capas ocultas se puede realizar mediante ensayos de prueba y error, sin embargo, también se observó que se pueden ajustar mediante múltiplos de la cantidad de nodos de la capa de entrada o por medio de métodos como el de Khaw et al. y Haykin. Para el resto de hiperparámetros se recomienda usar: 1) la función de activación sigmoideal (aunque en la capa oculta se puede aplicar también la función ReLu, y en la de salida la función Softmax); 2) optimizador Adam, 3) tasa de aprendizaje de 0.1 cuando se utilizan funciones de activación sigmoideal, y 0.001 cuando se utilizan ReLu; 4) Función de pérdida “entropía cruzada”; y 5) 30 a 100 épocas de entrenamiento, con ReLu; y de 5000 hasta un millón con la función sigmoideal.

6. Principales etapas de implementación

Finalmente, las etapas más importantes de implementación tecnológica son la recopilación, preprocesamiento y análisis de datos, desarrollo de modelo, entrenamiento, prueba y optimización.

- a) La recopilación de datos puede ser complicada debido a la cantidad de recursos que deben comprometerse para el desarrollo de los modelos inteligentes. Sin embargo, el uso de los simuladores ha demostrado facilitar esta tarea, al conseguir información de diferentes etapas del proceso y desde distintas zonas de las máquinas de inyección.

- b) En el preprocesamiento de datos se sugiere utilizar la técnica de normalización tipo min-máx., con el fin de volver uniforme la escala de los datos de entrada y facilitar la convergencia del modelo. En el análisis de datos, normalmente se aplican diseños de experimentos, como el diseño ortogonal de Taguchi, para delimitar los parámetros que más influyen en el proceso. Sin embargo, también se puede utilizar un método de selección, con el algoritmo InfoGain. Al finalizar esta etapa, se debe dividir la base de datos en un grupo destinado para el entrenamiento del modelo (80% de los datos) y otro conjunto para la evaluación (20%).
- c) En el desarrollo del modelo se debe proponer la estructura e hiperparámetros con las que estará formada la red neuronal. Con los resultados del análisis hecho en el paso anterior y los objetivos planteados se puede definir la estructura preliminar de la red. Antes de pasar a la siguiente etapa se recomienda inicializar los parámetros del modelo, con el fin de que pueda lograr una convergencia más rápida durante el entrenamiento.
- d) En el entrenamiento del modelo se utiliza el grupo seccionado en el punto dos y se corre el modelo para que este pueda ajustar los valores de sus parámetros. En esta etapa se recomienda considerar el algoritmo de backpropagation y optimización por descenso de gradiente. Asimismo, para evitar que el sistema sobreajuste durante esta etapa, se pueden utilizar la técnica de abandono (*dropout*) y el método de parada temprana.
- e) Para evaluar los modelos inteligentes se recomienda utilizar las métricas de evaluación: matriz de confusión, nivel de precisión, *recall*, puntuación F1 y curva ROC para tener un primer acercamiento del funcionamiento real del modelo. Así mismo se propone considerar el uso de la técnica de validación cruzada con cinco capas, para tener una visión más detallada de su rendimiento.
- f) Finalmente, para optimizar los hiperparámetros del modelo, se sugiere utilizar la búsqueda en cuadrícula (la cual puede ser utilizada con la técnica de validación cruzada). Estas herramientas han demostrado ser útiles para encontrar la topología e hiperparámetros del modelo que ofrecen el mejor rendimiento.

En este trabajo hemos observado que el desarrollo de tecnología basada en inteligencia artificial puede ofrecer grandes beneficios a la industria, en su nivel de productividad, en el aprovechamiento de recursos y la protección de la salud de sus colaboradores. Además, la inclusión de esta tecnología se aprecia como una ventaja económica, ya que se pueden conseguir procesos con mayor productividad, reducir los desperdicios energéticos y de materia prima, disminuir productos con defectos (y los gastos implícitos por las garantías); a la vez que se mantiene, e incluso se incrementa, la satisfacción de los clientes. La integración de esta tecnología en las industrias nacionales podría contribuir a impulsar su competitividad ante otras organizaciones del mismo sector, incluso a nivel internacional. Se considera que la creación de metodologías de implementación de tecnología con IA es necesaria para promover las últimas investigaciones que se han hecho en torno a este tema, comprender los beneficios que se pueden conseguir con su inclusión; y también para facilitar la comprensión de conceptos y funciones de los distintos elementos que se necesitan para el desarrollo tecnológico.

Como propuesta de investigación futura se podría ajustar esta metodología contemplando las micro, pequeñas y medianas empresas nacionales, debido a los beneficios que se han visto en la literatura, sobre el uso de IA en la industria de inyección de plásticos, y a la flexibilidad que se puede tener en los componentes físicos y digitales necesarios para su funcionamiento (como los sensores, computadores y sus procesadores; o las plataformas de programación).

Se espera que el contenido de este estudio pueda motivar a quien lo desee a adentrarse a la actual era industrial, que pueda adoptar, o incluso se anime a desarrollar, este tipo de tecnología inteligente, con la que se busca que las operaciones ya no solo sean automáticas, sino que lleguen a ser autónomas.

Bibliografía

- [1] Crawford R. y Martin P. (2020). *Plastics Engineering*. (4ª edición). Butterworth-Heinemann.
- [2] Comisión Europea (31 de mayo de 2021). *Economía circular: La Comisión proporciona orientaciones para la aplicación armonizada de las normas sobre plásticos de un solo uso y progresa en el seguimiento de los artes de pesca*. Recuperado el 29 de octubre de 2021 de https://ec.europa.eu/commission/presscorner/detail/es/ip_21_2710
- [3] Forbes staff (9 de octubre de 2020). *Canadá prohibirá plásticos de un solo uso a finales de 2021*. Forbes México. <https://www.forbes.com.mx/mundo-canada-prohibira-plasticos-de-un-solo-uso-a-finales-de-2021/>
- [4] Senado de la República de Chile (18 de agosto de 2021). *¿Sabía que desde febrero de 2022 no se podrán usar bombillas, revolvedores y cubiertos plásticos de un solo uso?* <https://www.senado.cl/ya-es-una-realidad-platos-vasos-bombillas-y-cubiertos-de-plastico-ya>
- [5] PlasticsEurope, Productores de Materias Plásticas (mayo de 2021). *Plásticos – Situación en 2020. Un análisis de los datos sobre producción, demanda y residuos de plásticos en Europa* [Archivo pdf]. Plastics Europe. <https://www.plasticseurope.org/es/resources/publications/4803-plasticos-situacion-en-2020>
- [6] Chávez J. C. (23 de diciembre de 2020). *Industria del plástico en México crece 3% gracias a COVID-19*. Energía hoy. <https://energiaahoy.com/2020/12/23/industria-del-plastico-en-mexico-crecio-3-gracias-a-covid-19/>
- [7] Aguirrezabal Unamunzaga, Ismene. Oficina Económica y Comercial de España en Ciudad de México (2019). *Ficha sector. Plástico en México 2019* [Archivo pdf]. ICEX España Exportación e Inversiones. Recuperado el 12 de septiembre de 2021, de <https://www.icex.es/content/dam/es/icex/oficinas/077/documentos/2019/09/documentos-anexos/DOC2019826983.pdf>
- [8] Revista Vector (2019). *Representa la Industria del plástico más del 3% del PIB Nacional*. Revista Vector. Recuperado el 10 de septiembre de 2021, de <http://www.revistavector.com.mx/2019/03/29/representa-la-industria-del-plastico-mas-del-3-del-pib-nacional/>
- [9] Plastics Technology México (20 de agosto de 2019). *Desarrollos tecnológicos impulsan el crecimiento de la industria del plástico en EE. UU.* Plastics Technology. Recuperado el 27 de octubre de 2021 de <https://www.pt-mexico.com/articulos/desarrollos-tecnologicos-impulsan-el-crecimiento-de-la-industria-del-plastico-en-ee-uu>
- [10] Bryce D. M. (1996). *Plastic Injection Molding... manufacturing process fundamentals. Volume I: Fundamentals of Injection Molding series*. (Vol. 1). Society of Manufacturing Engineers
- [11] Garrido, J. (2019). *Inyección de plásticos*. Ambiente plástico. Recuperado el 17 de enero de 2022, de: <https://www.ambienteplastico.com/inyeccion-de-plasticos/>
- [12] Barrios Pallares, O. (1998). *Implantación del sistema de calidad ISO 9000 para un departamento de inyección de plásticos*. (México: Universidad Nacional Autónoma de México). [Tesis] https://tesiunam.dgb.unam.mx/F/SQY81EYUJINFE9HHYSKHXNM92MR7LM8MIRT8GM1SKLN61IKFS5-10808?func=full-set-set&set_number=001817&set_entry=000003&format=040

- [13] Herrera Guerrero, A. (01 de octubre de 2021). *Moldeo por inyección robusto por simulación*. Plastics Technology México. Recuperado el 18 de enero de 2022, de: <https://www.pt-mexico.com/articulos/moldeo-por-inyeccion-robusto-por-simulacion>.
- [14] Camisón, C., Cruz, S. y González, T. (2006). *Gestión de la calidad: conceptos, enfoques, moldes y sistemas*. Pearson Educación, S. A.
- [15] Gutiérrez Pulido, H. (2010). *Calidad total y productividad*. (3ª ed.). McGraw-Hill.
- [16] Schmidt, R., Möhring, M., Härting, RC., Reichstein, C., Neumaier, P. y Jozinović, P. (2015). Industry 4.0 - Potentials for Creating Smart Products: Empirical Research Results. En: Abramowicz, W. (Ed) *Business Information Systems. BIS 2015*. Lecture Notes in Business Information Processing, vol 208. Springer, Cham. https://doi.org/10.1007/978-3-319-19027-3_2
- [17] Sader, S., Husti, I. y Daroczi, M. (2019). Quality management practices in the era of industry 4.0. *Zeszyty Naukowe Politechniki Częstochowskiej Zarządzanie*, 35: 117-126.
- [18] Lee, J., Davari, H., Singh, J. y Pandhare, V. (2018). Industrial artificial intelligence for industry 4.0-based manufacturing systems. *Manufacturing letters*. 18:20-23.
- [19] Ponce Cruz, P., (2010). *Inteligencia artificial con aplicaciones a la ingeniería*. Alfaomega.
- [20] Jung, H.; Jeon, J.; Choi, D.; Park, J.-Y. (2021) Application of Machine Learning Techniques in Injection Molding Quality Prediction: Implications on Sustainable Manufacturing Industry. *Sustainability*, 13, 4120. <https://doi.org/10.3390/su13084120>
- [21] Ozelik, B., Ozbay, A. y Demirbas, E. (2010). Influence of injection parameters and mold materials on mechanical properties of ABS in plastic injection molding. *International communications in heat and mass transfer*. 37: 1359-1365.
- [22] Kim, G., Choi, J. G., Ku, M., Cho H. y Lim, S. (2021). A Multimodal Deep Learning-Based Fault Detection Model for a Plastic Injection Molding Process. *IEEE Access*, 9, 32455-132467. doi: 10.1109/ACCESS.2021.3115665.
- [23] Instituto Nacional de Estadística y Geografía (25 de junio de 2020). *Comunicado de prensa Núm. 285/20. Estadísticas a propósito del día de las micro, pequeñas y medianas empresas (27 de junio). Datos nacionales*. [Archivo pdf]. INEGI. Recuperado el 16 de enero de 2022, de: <https://www.inegi.org.mx/contenidos/saladeprensa/aproposito/2020/MYPIMES20.pdf>
- [24] Besterfield, D. (2009). *Control de calidad*. (8ª ed.). Pearson Educación de México.
- [25] Organización Internacional de Normalización (2015). *Sistemas de gestión de la calidad — Fundamentos y vocabulario (ISO 9000:2015)*.
- [26] Evans, J. y Lindsay, W. (2015). *Managing for Quality and Performance Excellence*. (9ª ed.). Cengage Learning.
- [27] Brauer, D. y Cesarone, J. (2022). *Total manufacturing assurance: controlling product quality, reliability, and safety*. (2ª ed.). CRC Press.
- [28] Hoyle, D. (2000). *Automotive Quality Systems Handbook*. Butterworth-Heinemann Ltd.
- [29] Kalpakjian, S. y Schmid, S. (2008). *Manufactura, ingeniería y tecnología*. (5ª ed.). Pearson Educación de México.

- [30] Cabezón Gutiérrez, S. (2014). *Control de calidad en la producción industrial*. (España: Universidad de Valladolid, Escuela de ingenierías industriales). [Tesis]. <http://uvadoc.uva.es/handle/10324/13153>
- [31] Sánchez-Galán, J. (1 de marzo de 2020). *Ley de rendimientos decrecientes*. Economipedia. Recuperado el 12 de octubre de 2022, de <https://economipedia.com/definiciones/ley-de-rendimientos-decrecientes.html>
- [32] Groover, M. (2007). *Fundamentos de manufactura moderna*. (3ª ed.). McGraw Hill.
- [33] Evans, J. y Lindsay, W. (2015). *Administración y control de la calidad*. (9ª ed.). Cengage Learning.
- [34] Gillet-Goinard, F. y Seno, B. (2014). *La caja de herramientas. Control de calidad*. Grupo editorial Patria
- [35] Damelio, R. (1999). *Fundamentos de mapeo de procesos*. Panorama Editorial.
- [36] Dastbaz, M. y Cochrane, P. (2019). *Industry 4.0 and engineering for a sustainable future*. Springer.
- [37] Zheng, P., Wang, H., Sang, Z., Zhong, R. Y., Liu, Y., Liu, C., Mubarak, K., Yu, S. y Xu, X. (2018). Smart manufacturing systems for industry 4.0: Conceptual framework, scenarios, and future perspectives. *Frontiers of mechanical engineering*, 13(2),137-150. <https://doi.org/10.1007/s11465-018-0499-5>
- [38] Zeba, G., Dabić, M., Čičak, M., Daim, T. y Yalcin, H. (2021). Technology mining: artificial intelligence in manufacturing. *Technological forecasting & social change*, 171, 1-18. <https://doi.org/10.1016/j.techfore.2021.120971>
- [39] Godina, R. y Matias, J. C. O. (2019). Quality Control in the Context of Industry 4.0. En Reis, J., Pinelas, S., Melão, N. (ed). *Industrial Engineering and Operations Management II. IJCIEOM 2018*. Springer Proceedings in Mathematics & Statistics. 281: 177-187. https://doi.org/10.1007/978-3-030-14973-4_17
- [40] Benítez, R., Escudero, G., Kanaan, S. y Masip Rodó, D. (2014). *Inteligencia artificial avanzada*. UOC.
- [41] Rouhiainen, L. (2018). *Inteligencia artificial: 101 que debes saber hoy sobre nuestro futuro*. Planeta.
- [42] Ibidapo, T. (2022). *From Industry 4.0 to Quality 4.0. An innovative TQM guide for sustainable digital age businesses*. Springer.
- [43] Li, P., Pereira, P. A. y Navas, H. (2021). *Quality Control - Intelligent Manufacturing, Robust Design and Charts*. IntechOpen.
- [44] Harper, C. (1999). *Modern plastics handbook*. McGraw-Hill.
- [45] Stokes, V. K. (2020). *Introduction to Plastics Engineering*. John Wiley & Sons y ASME Press.
- [46] Bryce, D.M. (1997). *Plastic Injection Molding... material selection and product design fundamentals. Volume II: Fundamentals of injection molding series*. (Vol. 2) Society of Manufacturing Engineers.
- [47] Arpio-Zepeda, L. y Urtuzuastegui-Jiménez, R. D. (1988). *Estudio de factibilidad para la implantación de una fábrica de inyección de plásticos*. (México: Universidad Panamericana)

[Tesis].
https://inventio.up.edu.mx/permalink/52UNIPAN_INST/1r1590p/alma990000123040204971

- [48] García-Martínez, M. G. (2005). *Modelo de Calidad para una industria de moldeo por inyección de plásticos*. (México: Universidad Nacional Autónoma de México). [Trabajo de seminario]. https://tesiunam.dgb.unam.mx/F/SSJDDY1SSTL3FFRD3N9AV8473N94LP1VPNPT4AVDAXU3VE1V37-05632?func=full-set-set&set_number=008396&set_entry=000001&format=999
- [49] Jurado Páramo, J., Reveles Arredondo, J. F., Plascencia Mora, H. y Aguilera Gómez, E. (2019). Análisis de un proceso de inyección de plástico por interacción fluido estructural y cambio de estado. *Acta Universitaria*. 29, 1-18.
- [50] B. Ribeiro (2005). Support vector machines for quality monitoring in a plastic injection molding process. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*. 35 (3), 401-410. doi: 10.1109/TSMCC.2004.843228.
- [51] Carro Paz, R. y González Gómez, D. (2012). *Administración de la calidad total*. Nülan. Repositorio Digital de la FCEyS-UNMDP. <http://nulan.mdp.edu.ar/id/eprint/1614>
- [52] Rosato, D., Rosato, D. y Rosato, M. (2000). *Injection molding handbook*. (3a edición). Springer Science+Business Media, LLC.
- [53] Harper, C. (2006). *Handbook of plastic processes*. Wiley-Interscience
- [54] Harper, C. (2002). *Handbook of plastics, elastomers & composites*. (4a edición). McGrawHill.
- [55] Dang, X.-P. (2014). General Frameworks for optimization of plastic injection molding process parameters. *Simulation modelling practice and theory*. 41, 15-27. <https://doi.org/10.1016/j.simpat.2013.11.003>
- [56] Juanes-Márquez, J. J., Martínez Muneta, M. L., Rodríguez Villagrà, M. y García Pérez, J. M. (2012). Simulando la inyección de plásticos. Nuevas formas de aprender los procesos. *DYNA*. 87 (6), 671-678.
- [57] Erzurumlu, T. y Ozcelik, B. (2006). Minimization of warpage and sink index in injection-molded thermoplastic parts using Taguchi optimization method. *Materials & Design*, 27: 853-861. <https://doi.org/10.1016/j.matdes.2005.03.017>
- [58] Farshi, B., Gheshmi, S. y Miandoabchi, E. (2011). Optimization of injection molding process parameters using sequential simplex algorithm. *Materials and Design*, 32: 414-423. <https://doi.org/10.1016/j.matdes.2010.06.043>
- [59] Kurt, M., Kamber, S., Kaynak, Y., Atakok, G. y Girit, O. (2009). Experimental investigation of plastic injection molding: Assessment of the effects of cavity pressure and mold temperature on the quality of the final products. *Materials & design*, 30: 3217-3224. <https://doi.org/10.1016/j.matdes.2009.01.004>
- [60] Zhao, P., Zhou, H., Li, Y. y Li, D. (2010). Process parameters optimization of injection molding using a fast strip analysis as a surrogate model. *The International Journal of Advanced Manufacturing Technology*. 49: 949-959. <https://doi.org/10.1007/s00170-009-2435-7>
- [61] Bociaga, E. (2001). Effect of mould temperature and injection speed on selected properties of polyethylene moldings. *International Polymer Science and Technology*, 28 (6), 96-102. <https://doi.org/10.1177/0307174X0102800621>

- [62] Jansen K., Dijk D. y Husselman, M. (2004). Effect of processing conditions on shrinkage in injection molding. *Polymer Engineering and science*. 38(5):838–846. <https://doi.org/10.1002/pen.10249>
- [63] Liu, S.-J., Lin, C.-H. y Wu, Y.-C. (2001). Minimizing the sinkmarks in injection–molded thermoplastics. *Advances in Polymer Technology*, 20 (3), 202–215. <https://doi.org/10.1002/adv.1016>
- [64] Wang, J., Mao, Q., Jiang, N. y Chen, J. (2022). Effects of injection Molding Parameters on properties of insert-injection molded polypropylene single-polymer composites. *Polymers*. 14 (1):1-15. <https://doi.org/10.3390/polym14010023>
- [65] Pratap, B. Gupta, R. K., Yadav, A. y Nag M. (2020). Plastic injection molding and its process parameters. *AIP Conference Proceedings*, 2273, 1-7. <https://doi.org/10.1063/5.0024291>
- [66] Hudspeth, M. (21 de junio de 2016). *All is Not Sunk: How to deal with sink Marks in an Injection-Molded part*. Engineers Rule. <https://www.engineersrule.com/not-sunk-deal-sink-marks-injection-molded-part/>
- [67] Rapid Direct Blog. (2021). *Defectos de moldeo por inyección generalmente debido a proceso y cómo prevenirlos*. Recuperado el 13 de marzo de 2022, de: <https://www.rapiddirect.com/es/blog/defectos-de-moldeo-por-inyecci%C3%B3n/>
- [68] Plastic & Injection Molding. (s.f.) *How can you prevent injection mold flash? PFA Incorporated*. Recuperado el 15 de marzo de: <https://www.pfa-inc.com/how-can-you-prevent-injection-mold-flash/?lang=es>
- [69] Farooque, R., Asjad, M. y Rizvi, S. (2021). A current state of art applied to injection moulding manufacturing process – A review. *Materials Today: Proceedings*. 43, 441-446. <https://doi.org/10.1016/j.matpr.2020.11.967>
- [70] Kamrani, R. S., Mehrpour, S. R. y Aghamirsalim, M. (2011). High-pressure plastic injection injury of the hand: case report. *Occupational Medicine*. 61 (7) 518-520. <https://doi.org/10.1093/occmed/kqr082>
- [71] Bryce, D. M. (1997). *Plastic Injection Molding... manufacturing startup and management. Volume IV: Fundamentals of injection molding series*. (Vol. 4) Society of Manufacturing Engineers.
- [72] Bazargan-Lari, M., Taghipour, S., Zaretalab, A. y Sharifi, M. (2022). Production scheduling optimization for parallel machines subject to physical distancing due to COVID-19 pandemic. *Operations Management Research*, 15, 503-527. <https://doi.org/10.1007/s12063-021-00233-9>
- [73] Sarac, T., Sipahioglu, A. y Ozer, E. (2021). A two-stage solution approach for plastic injection machines scheduling problem. *Journal of industrial and management optimization*, 17 (3), 1289-1314. <https://doi.org/10.3934/jimo.2020022>
- [74] Yazici, K., Gökler, S. y Boran, S. (2020). An integrated SMED-fuzzy FMEA model for reducing setup time. *Journal of Intelligent Manufacturing*, 32, 1547-1561. <https://doi.org/10.1007/s10845-020-01675-x>
- [75] Zhao, N.- Y., Lian, J.-Y., Wang, P.-F. y Xu, Z.-B. (2022). Recent progress in minimizing the warpage and shrinkage deformation by the optimization of process parameters in plastic injection molding: a review. *The international Journal of Advanced Manufacturing Technology*, 120, 85-101. <https://doi.org/10.1007/s00170-022-08859-0>

- [76] Chen, S.-C., Mathew, J. J., Feng, C.-T. y Hsu, T.-J. (2022). An Innovative Method to Monitor and Control an Injection Molding Process Condition using Artificial Intelligence based Edge Computing System. *2022 8th International Conference on Applied System Innovation (ICASI)*. 41-45. Doi: 10.1109/ICASI55125.2022.9774445
- [77] Cui, Z. y Wang, J. (2011). Distributed Intelligent Control System of the Injection Molding Machine Based on ARM Controller. *2011 IEEE International Conference on Computer Science and Automation Engineering*, 339-342. doi: 10.1109/CSAE.2011.5952483
- [78] Mahmoud, M., Ammar, H., Eissa, M. H. y Hamdy, M. M. (2018). Improved Production Key Performance Indicators (KPI's) Using Intelligent-Manufacturing Execution Systems (I-MES). *The International Conference on Advanced Machine Learning Technologies and Applications (AMLTA2018)*. 723: 437-448. http://dx.doi.org/10.1007/978-3-319-74690-6_43
- [79] Park, H. S., Phuong, D.X. y Kumar, S. (2019). AI based injection molding process for consistent product quality. *Procedia Manufacturing*, 28, 102-106. <https://doi.org/10.1016/j.promfg.2018.12.017>
- [80] Böttjer, T., Ørnskov Rønsch, G., Gomes, C., Ramanujan, D., Iosifidis, A. y Gorm Larsen, P. (2022). Data-Driven Identification of Remaining Useful Life for Plastic Injection Moulds. En: Andersen, AL., Andersen, R., Brunoe, T., Stoettrup, S., Napoleone, A. y Kjeldgaard, S. *Towards Sustainable Customization: Bridging Smart Products and Manufacturing Systems. CARV MCPC 2021. Lecture Notes in Mechanical Engineering*, 431-439 Springer. https://doi.org/10.1007/978-3-030-90700-6_49
- [81] Shelesh-Nezhad, K. y Siores, E. (1997). An intelligent system for plastic injection molding process design. *Journal of materials processing technology*. 63, 458-462. [https://doi.org/10.1016/S0924-0136\(96\)02664-7](https://doi.org/10.1016/S0924-0136(96)02664-7)
- [82] Zhou, H., Zhao, P. y Feng, W. (2007). An Integrated Intelligent System for Injection Molding Process Determination. *Advances in polymer technology*. 26(3), 191-205. Doi: <https://doi.org/10.1002/adv.20097>
- [83] Chen, Y.-F., Yang, F.-S., Su, E. y Ho, C.-C. (2019). Automatic Defect Detection System Based on Deep Convolutional Neural Networks. *2019 International Conference on Engineering, Science, and Industrial Applications (ICESI)*, 1-4. doi: 10.1109/ICESI.2019.8863029.
- [84] Chouchene, A., Carvalho, A., Lima, T. M., Charrua-Santos, F., Osório, G. J. y Barhoumi, W. (2020). Artificial Intelligence for Product Quality Inspection toward Smart Industries: Quality Control of Vehicle Non-Conformities. *2020 9th International Conference on Industrial Technology and Management (ICITM)*. 127-131. 10.1109/ICITM48982.2020.9080396
- [85] Haselmann, M. y Gruber, D. (2019). Pixel-Wise Defect Detection by CNNs without Manually Labeled Training Data. *Applied Artificial Intelligence*. 33(6), 548-566. Doi: <https://doi.org/10.1080/08839514.2019.1583862>
- [86] Muresan, M. P., Cireap, D. G. y Giosan, I. (2020). Automatic Vision Inspection Solution for the Manufacturing Process of Automotive Components Through Plastic Injection Molding. *IEEE, 16th International Conference on Intelligent Computer Communication and Processing (ICCP)*, 423-430. doi: 10.1109/ICCP51029.2020.9266249
- [87] Mei, Y. y Wu, D. (2009). Research on the quantification of defects in injection molded parts based on digital image processing. *2009 International Conference on Machine Learning and Cybernetics*, 1210-1213. doi: 10.1109/ICMLC.2009.5212397.

- [88] Tseng, T. L., Aleti, K. R., Hu, Z. y Kwon, Y. (2016). E-quality control: A support vector machines approach. *Journal of computational design and engineering*, 3 (2), 91-101. <https://doi.org/10.1016/j.jcde.2015.06.010>
- [89] Librantz, A., de Araújo, S. A., Alves, W., Belan, P., Mesquita, R. y Selvatici, A. (2017). Artificial intelligence-based system to improve the inspection of plastic mould surfaces. *Journal of Intelligent manufacturing*. 28:181-190. <https://doi.org/10.1007/s10845-014-0969-5>
- [90] Hsu, T.-C., Tsai, Y.-H. y Chang, D.-M. (2022). The Vision-Based Data Reader in IoT System for Smart Factory. *Applied Sciences*.12(13): 1-17. <https://doi.org/10.3390/app12136586>
- [91] Bensingh, R. J., Machavaram, R., Boopathy, S. R. y Jebaraj, C. (2019). Injection molding process optimization of a bi-aspheric lens using hybrid artificial neural networks (ANNs) and particle swarm optimization (PSO). *Measurement*, 134, 359-374. Doi: <https://doi.org/10.1016/j.measurement.2018.10.066>
- [92] Zhao, P., Dong, Z., Zhang, J., Zhang, Y., Cao, M., Zhu, Z., Zhou, H. y Fu, J. (2020). Optimization of Injection-Molding Process Parameters for Weight Control: Converting Optimization Problem to Classification Problem. *Advances in Polymer Technology*, 1-9. <https://doi.org/10.1155/2020/7654249>
- [93] Tsai, K.-M. y Luo, H.-J. (2017). An inverse model for injection molding of optical lens using artificial neural network coupled with genetic algorithm. *Journal of intelligent manufacturing*, 28(2): 473-487. <https://doi.org/10.1007/s10845-014-0999-z>
- [94] Lau, H. Y., Li, X. y Du, R. (2008). A new method for monitoring and tuning plastic injection molding machines. *Control and intelligent systems*, 36 (2), 129-136.
- [95] Everett, S. y Dubay, R. (2017). A sub-space artificial neural network for mold cooling in injection molding. *Expert systems with applications*. 79, 358-371. <https://doi.org/10.1016/j.eswa.2017.03.013>
- [96] Li, K., Yan, S., Pan, W. y Zhao, G. (2016). Warpage optimization of fiber-reinforced composite injection molding by combining back propagation neural network and genetic algorithm. *The International Journal of Advanced Manufacturing Technology*, 90 (4): 963-970. <https://doi.org/10.1007/s00170-016-9409-3>
- [97] Lockner, Y. y Hopmann, C. (2021). Induced network-based transfer learning in injection molding for process modelling and optimization with artificial neural networks. *The international journal of advanced manufacturing technology*. 112, 3501-3513. <https://doi.org/10.1007/s00170-020-06511-3>
- [98] Raimee, N.A, Fathullah, M., Shayfull, Z., Nasir, S. M. y Hazwan, M. H. M. (2017). Application of Response Surface Methodology (RSM) and Genetic Algorithm in Minimizing Warpage on Side Arm. *3rd Electronic and Green Materials International Conference 2017, AIP Conference Proceedings*, 1885 (1), 1-10. <https://doi.org/10.1063/1.5002255>
- [99] Yin, F. Mao, H. y Hua, L. (2011). A hybrid of back propagation neural network and genetic algorithm for optimization of injection molding process parameters. *Materials -and design*. 32 (6), 3457-3464. <https://doi.org/10.1016/j.matdes.2011.01.058>
- [100] Afzalirad, M. y Shafipour, M. (2015). Design of an efficient genetic algorithm for resource-constrained unrelated parallel machine scheduling problem with machine eligibility restrictions. *Journal of intelligent manufacturing*. 29, 423-437. <https://doi.org/10.1007/s10845-015-1117-6>

- [101] Charest, M., Finn, R. y Dubay, R. (2018). Integration of artificial intelligence in an injection molding process for on-line process parameter adjustment. *2018 Annual IEEE International Systems Conference (SysCon)*, 1-6. doi: 10.1109/SYSCON.2018.8369500
- [102] Ke, K.-C., Huang, M.-S., (2020). Quality prediction for injection molding by using a multilayer perceptron neural network. *Polymers*, 12(8), 1-22. <https://doi.org/10.3390/polym12081812>
- [103] Kim, I., Na, J., Yun, J. P. y Lee, S. (2023). Deep Feature Selection Framework for Quality Prediction in Injection Molding Process. *IEEE Transactions on Industrial Informatics*, 1-10. doi: 10.1109/TII.2023.3268421.
- [104] Polenta, A., Tomassini, S., Falcionelli, N., Contardo, P., Dragoni, A. F. y Sernani, P. (2022). A Comparison of Machine Learning Techniques for the Quality Classification of Molded Products. *Information*, 13(6): 1-17. <https://doi.org/10.3390/info13060272>
- [105] Román, A. J., Qin, S., Zavala, V. M. y Osswald, T. A. (2021). Neural network feature and architecture optimization for injection molding surface defect prediction of model polypropylene. *Polymer Engineering & Science*, 61 (9), 2376-2387. <https://doi.org/10.1002/pen.25765>
- [106] Tercan, H., Deibert, P. y Meisen, T. (2022). Continual learning of neural networks for quality prediction in production using memory aware synapses and weight transfer. *Journal of intelligent manufacturing*, 33, 283-292. <https://doi.org/10.1007/s10845-021-01793-0>
- [107] Chen, J. C., Guo, G. y Wang, W.-N. (2020). Artificial neural network-based online defect detection system with in-mold temperature and pressure sensors for high precision injection molding. *The International Journal of Advanced Manufacturing Technology*, 110, 2023–2033. <https://doi.org/10.1007/s00170-020-06011-4>
- [108] Chen, W.-C., Tai, P.-H., Wang, M.-W., Deng, W.-J. y Chen, C.-T. (2008). A neural network-based approach for dynamic quality prediction in a plastic injection molding process. *Expert Systems with applications*, 35 (3), 843-849. <https://doi.org/10.1016/j.eswa.2007.07.037>
- [109] Demirel, K. C., Şahin, A. y Albey, E. (2020). A web-based decision support system for quality prediction in manufacturing using ensemble of regressor chains. En Hammoudi, S., Quix, C., Bernardino, J. (ed) *Data Management Technologies and Applications. DATA 2019. Communications in Computer and Information Science* (Vol 1255, 96-114). Springer. https://doi.org/10.1007/978-3-030-54595-6_6
- [110] Kim, S., Kim, S. y Ryu, K. R. (2018). Deep Learning Experiments with Skewed Data for Defect Prediction in Plastic Injection Molding. *2018 IEEE/ACS 15th International Conference on Computer Systems and Applications (AICCSA)*, 1-2. doi: 10.1109/AICCSA.2018.8612875.
- [111] Maarif, M. R., Listyanda, R. F., Kang, Y.-S. y Syafrudin, M. (2022). Artificial Neural Network Training Using Structural Learning with Forgetting for Parameter Analysis of Injection Molding Quality Prediction. *Information*, 13(10), 1-19. <https://doi.org/10.3390/info13100488>
- [112] Nagorny, P., Pillet, M., Pairel, E., Le Goff, R., Loureaux, J., Wali, M. y Kiener, P. (2017). Quality prediction in injection molding. *2017 IEEE International Conference on Computational Intelligence and Virtual Environments for Measurement Systems and Applications (CIVEMSA)*, 141-146. doi: 10.1109/CIVEMSA.2017.7995316.
- [113] Ogorodnyk, O., Lyngstad, O.V., Larsen, M., Wang, K. y Martinsen, K. (2019). Application of Machine Learning Methods for Prediction of Parts Quality in Thermoplastics Injection Molding. En: Wang, K., Wang, Y., Strandhagen, J., Yu, T. (ed) *Advanced Manufacturing*

- and Automation VIII. IWAMA 2018. Lecture Notes in Electrical Engineering* (Vol 484, 237-244). Springer. https://doi-org.pbidi.unam.mx:2443/10.1007/978-981-13-2375-1_30
- [114] Uğuroğlu, E. (2021). Near-Real Time Quality Prediction in a Plastic Injection Molding Process Using Apache Spark. *2021 International Symposium on Computer Science and Intelligent Controls (ISCSIC)*, 284-290. doi: 10.1109/ISCSIC54682.2021.00059.
- [115] Silva, B., Sousa, J. y Alenya, G. (2021). Machine Learning Methods for Quality Prediction in Thermoplastics Injection Molding. *2021 International Conference on Electrical, Computer and Energy Technologies (ICECET)*, 1-6. doi: 10.1109/ICECET52533.2021.9698455.
- [116] Shelesh-Nezhad, K. y Siores, E. (1997). An intelligent system for plastic injection molding process design. *Journal of materials processing technology*. 63 (1-3), 58-462. [https://doi.org/10.1016/S0924-0136\(96\)02664-7](https://doi.org/10.1016/S0924-0136(96)02664-7)
- [117] Zhao, P., Zhang, J., Dong, Z., Huang, J., Zhou, H., Fu, J. y Turng, L.-S. (2020). *Intelligent Injection Molding on Sensing, Optimization, and Control*. *Advances in polymer technology*. 2020, 1-22. <https://doi.org/10.1155/2020/7023616>
- [118] Yamashiro, H. y Nonaka, H. (2021). Estimation of processing time using machine learning and real factory data for optimization of parallel machine scheduling problem. *Operations research perspectives*, 8, 1-9. <https://doi.org/10.1016/j.orp.2021.100196>
- [119] IBM. (s.f.). *¿Qué son las redes neuronales?* <https://www.ibm.com/mx-es/topics/neural-networks>
- [120] Data Science Team. (3 de mayo 2020). *Redes neuronales residuales – Lo que necesitas saber (ResNet)*. Data Science. <https://datascience.eu/es/aprendizaje-automatico/una-vision-general-de-resnet-y-sus-variantes/>
- [121] IBM. (s.f.). *¿Qué es AutoML?* <https://www.ibm.com/mx-es/topics/automl>
- [122] Microsoft Ignite. (7 de junio de 2023). *Ajuste de hiperparámetros de un modelo (v2)*. Microsoft. <https://learn.microsoft.com/es-es/azure/machine-learning/how-to-tune-hyperparameters?view=azureml-api-2>
- [123] Kingma, D. P. y Ba, J. (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*. <https://doi.org/10.48550/arXiv.1412.6980>
- [124] Tutoriales de Informática. (29 de junio de 2023). *Librerías de Machine Learning para Python*. Recuperado el 25 mayo de 2023 de <https://tutorialesinformatica.com/programacion/librerias-ia-python/>
- [125] MathWorks. (s.f.). *MATLAB para Deep Learning*. <https://la.mathworks.com/solutions/deep-learning.html>
- [126] NI, Emerson. (s.f.). *¿Qué es LabWindowsTM/CVI?* National Instruments Corp. <https://www.ni.com/es/shop/electronic-test-instrumentation/programming-environments-for-electronic-test-and-instrumentation/what-is-labwindows-cvi.html>
- [127] Project Jupyter. (s.f.). *Jupyter*. <https://jupyter.org/>
- [128] modeFRONTIER. (s.f.). *Modular environment to connect all steps of design process*. <https://engineering.esteco.com/modefrontier/modefrontier-capabilities/#content>
- [129] Ageyeva, T., Horváth, S. y Kovács, J. G. (2019). *In-Mold Sensors for Injection Molding: On the Way to Industry 4.0*. *Sensors*. 19(16) 1-21. <https://doi.org/10.3390/s19163551>

- [130] Lee, J., Davari, H., Singh, J. y Pandhare, V. (2018). Industrial Artificial Intelligence for industry 4.0-based manufacturing systems. *Manufacturing Letters*, 18, 20-23. <https://doi.org/10.1016/j.mfglet.2018.09.002>
- [131] Kvaktun, D., Hoffmann, A. y Schiffers, R. (2022) Analysis of feature extraction algorithms for quality prediction using machine learning in injection molding. *Procedia CIRP*. 112: 590-595. <https://doi.org/10.1016/j.procir.2022.09.059>
- [132] Agrawal, R. (9 de noviembre de 2021). *A Comprehensive Guide on Neural Networks Performance Optimization*. Analytics Vidhya. <https://www.analyticsvidhya.com/blog/2021/09/a-comprehensive-guide-on-neural-networks-performance-optimization/>
- [133] Rodrigo, J. A. (mayo de 2021). *Redes neuronales con Python*. Ciencia de datos. <https://cienciadedatos.net/documentos/py35-redes-neuronales-python>
- [134] IBM. (s.f.). ¿Qué es el sobreajuste? IBM. <https://www.ibm.com/mx-es/topics/overfitting>
- [135] Blog Analytics Vidhya. (s.f.). Text to Sound – Train Your Large Language Models. <https://www.analyticsvidhya.com/blog/2023/09/text-to-sound-train-your-large-language-models/#h-model-training-challenges-and-solutions>
- [136] Pierleoni, P., Belli, A., Sabbatini, L. y Palma, L. (2020). Using plastic injection moulding machine process parameters for predictive maintenance purposes. *2020 International conference on intelligent engineering and management (ICIEM)*, 115-121. doi: 10.1109/ICIEM48762.2020.9160120.
- [137] Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M. y Duchesnay, E. (2011). *Tuning the hyper-parameters of an estimator*. Scikit-learn: Machine Learning in Python. https://scikit-learn.org/stable/modules/grid_search.html
- [138] Keras. (s.f.). *The Tuner classes in KerasTuner*. Keras. https://keras.io/api/keras_tuner/tuners/
- [139] Hitt, M. A., Ireland, R. D. y Hoskisson, R. E. (2015). *Administración estratégica. Competitividad y globalización: conceptos y casos*. (11a. ed.). Cengage Learning.
- [140] Spulber, D. F. (2007). *Global Competitive Strategy*. Cambridge University Press.
- [141] Data México. (s.f.). Fabricación de productos de plástico. Secretaría de Economía. <https://www.economia.gob.mx/datamexico/es/profile/industry/plastics-product-manufacturing?yearSelectorGdp=timeOption0>
- [142] Ortega Leyva, M. N. (22 de diciembre de 2022). Industria del plástico en México cierra 2022 con números positivos. *Plastics Technology México*. <https://www.pt-mexico.com/noticias/post/industria-del-plastico-en-mexico-cierra-2022-con-numeros-positivos>
- [143] Becerril, D. (01 de junio de 2023). Industria del plástico, ¿cómo se encuentra en México? *México Industry*. <https://mexicoindustry.com/noticia/industria-del-plastico-como-se-encuentra-en-mexico>

Anexo

1. Análisis de los artículos relacionados con los retos de la industria de inyección en donde se implementó Inteligencia artificial

Auto-res	Función abordada con IA	Técnica IA utilizada	Composición de la técnica	Software y programas	Dispositivos involucrados	Pasos de implementación y/o programación	Variables objetivo	Datos y forma de entrenamiento / evaluación	Resultados
[76] Chen, S.-C., et al. (2022)	Control de parámetros	Redes neuronales artificiales	<p>Los hiperparámetros determinados para el RNA son: Función de activación - ReLu (en capas ocultas) y lineal (en capa de salida). Optimizador Adam Tasa de aprendizaje - 0.0001 Función de pérdida: error absoluto medio Tamaño de lote=3 y núm. de épocas = 100. Se utilizan métodos de errores cuadráticos medios y absolutos para evaluar el rendimiento del modelo.</p>	Tensor Flow Lite Micro Python 3.7 CAE MOLDEX 3D Notebook jupyter	Sensores análogos de TyP de cavidad del molde Amplificador de señal Interfaz-microcontrolador Arduino Mega (tipo Arduino-Atmega-2560) + ESP32D	<p>El sistema estaba compuesto por dos subsistemas: 1) Sistema de adquisición de datos y monitoreo del proceso. En el primero, el sensor recibía las señales de P y T. Para ello, se instaló un circuito de acondicionamiento de señal, mediante un amplificador. Su señal de respuesta era enviada a la entrada analógica del microcontrolador para la operación computacional. 2) Sistema con IA en ML. Inició clasificando los datos de entrada en características dependientes e independientes. Se calcularon los hiperparámetros que describían mejor el proceso. Se evaluó el error cuadrático medio y varianza del entrenamiento y se ajustó el modelo con 33% de los datos de entrenamiento. El resultado de la validación en (.h5 Keras) se convirtió en formato (tflite) para usarse por Tensor flow Lite y se implementó en el microcontrolador ESP32. Por medio de un simulador CAE se determinó el volumen específico de la pieza del producto y, por lo tanto, las condiciones óptimas del proceso, también mediante el software se evaluó el rendimiento del modelo de IA, con una curva PVT. También se revisó la estabilidad de las condiciones del proceso y la influencia de la configuración de los parámetros, con respecto a la calidad de la pieza. La evaluación del modelo de tres capas ocultas se realizó mediante una prueba de varianza, sesgo y una función de pérdida.</p>	<p>Variable salida: Vol.Específico</p> <p>Variable entrada: variación de T y P_{iny}.</p>	El conjunto de datos contenía 4529 elementos, de los cuales el 80% (3623 datos) se usaron para el entrenamiento del modelo y el resto (906 datos) para la validación del modelo creado.	<p>Se desarrolló un modelo que permite monitorear y pronosticar los resultados del proceso (volumen específico), utilizando información de P y T. Con este modelo se tiene una convergencia rápida, después de pocas épocas corridas. Lo anterior significa que el sistema puede evaluar las condiciones en que opera el proceso de forma adecuada, y que puede hacer una predicción adecuada del volumen específico. El error absoluto medio del modelo inteligente es 0.0046</p>

<p>[77] Cui, Z., (2011)</p>	<p>Control de parámetros</p>	<p>Razonamiento basado en casos</p>	<p>Se uso CBR debido a que el rango de aplicación de las máquinas puede ser diferente. Con CBR se puede configurar los parámetros de procesamiento</p>		<p>El sistema consistió en un computador base y una de servicio Controladores ARM Bus de campo CAN (redes can) Sensores de T</p>	<p>El diseño del sistema estuvo compuesto de: una computadora anfitriona o de control que conectaba todos los controladores ARM dispersos. Dicha PC podía iniciar la red, gestionar la comunicación entre los ARM, monitorear las máquinas, realizar las estadísticas y actualizar los softwares. El ARM controlador era el puente entre la máquina y la PC, además proporcionaba control remoto para la computadora (configuraba y modificaba parámetros; detectaba, colectaba, procesaba y controlaba parámetros). Los controladores se ubicaron para distintos objetos de la máquina de inyección. La red CAN se usó como bus de campo, el cual permitió formar las redes de comunicación entre los equipos. Se implementó CBR para la configuración de los parámetros. Con sus resultados, el operador podía seleccionar los parámetros que proponía o solo alguno de ellos para usarlos en el proceso. El modelo utilizaba la información de producciones pasadas para ofrecer parámetros de nuevas operaciones (los casos nuevos se configuraban manualmente y su información se almacenaba en la base de datos para acumulación de conocimiento). / El sistema realizaba estadísticas del proceso terminado y analizaba los parámetros que se usaron para optimizar su base de información.</p>	<p>El modelo CBR funcionaba con variables de entrada: tipo de plástico, peso y complejidad geométrica del producto. Su salida estaba compuesta por: P_{molde}, capacidad máxima de inyección, T_{operación}, P_{iny.} y de mant.</p>		<p>El sistema permite el control de la máquina de moldeo, además de autoaprendizaje de los casos, diagnóstico de fallas y optimización de parámetros. Sirve como sistema de control en sitio de inyección y permite la gestión remota. También emite alarmas cuando las máquinas no funcionan con normalidad (si algún parámetro es erróneo). Puede actuar de forma autónoma o alertar a operadores para reparación manual (el sistema guarda información de la reparación manual, para usarla en tareas futuras)</p>
-------------------------------------	------------------------------	-------------------------------------	--	--	--	---	---	--	---

<p>[78] Mah- moud, M.L., (2018)</p>	<p>Control de paráme- tros</p>	<p>Fuzzy Logic (Lógica difusa)</p>	<p>Se utilizó por su simpleza y eficiencia en modelar y controlar sistemas no lineales. Con esta técnica se podía controlar la carga de inyección (fuzzy logic controller) y clasificar los parámetros que se detecten con una calidad determinada.</p>			<p>Desarrollo de fuzzy logic Se elaboró un Controlador capaz de ofrecer magnitudes de parámetros que pudieran mejorar la calidad o corregir algún defecto. para ello se modelaron 49 reglas para el controlador de los parámetros de inyección. La entrada era el error de residuo de inyección y la salida las variables para ajuste Se buscó que FL-Clasificador relacionara el error de residuos de inyección (cushion) y el grado de calidad de los productos, a partir de la configuración de 25 reglas de clasificación de calidad. El sistema con fuzzy logic expert, se desarrolló para tomar los tipos y niveles de defectos y transformarlos en los parámetros optimizados.</p>	<p>Variable entrada: error de residuo de inyección y carga de residuo (cushion). Salida: T_{iny}, vel_{iny} y P_{iny}. para controlar el tamaño de la carga de inyección; y la calidad de producto y grado de calidad.</p>	<p>Se modelaron 25 reglas</p>	<p>Sistema MES (Manufacturing Execution system), capaz de controlar la gestión de información del área operativa y administrativa de la industria. El sistema detecta el error de residuo de inyección y, mediante el controlador y clasificador de lógica difusa ofrece parámetros para mantener o mejorar la calidad Evalúa indicadores KPI y en tiempo reducido ofrece opciones de reparo</p>
---	--	--	---	--	--	---	---	-----------------------------------	--

<p>[79] Park, H.S., (2019)</p>	<p>Control de parámetros</p>	<p>-</p>	<p>-</p>	<p>Python Interfaz digital de comunicación</p>	<p>En cavidad de molde se instalaron: dos sensores de temperatura y dos sensores de presión Interfaz de comunicación y controlador</p>	<p>Se registraron datos por medio de los sensores de P y T, y se relacionaron con tipo de producto, ciclos, parámetros y calidades. Los datos se registraron con una identificación del número de ciclo, parámetros usados y la calidad que se consiguieron con ellos. Se almacenaron los datos en una base de datos para su análisis y para la generación de modelos inteligentes. El análisis con modelo IA se hizo para encontrar relaciones entre los parámetros (de la inyectora y los sensores), y la calidad de los productos. Se calculó la diferencia entre los parámetros de inyección y la real, y se generaron parámetros de entrada de la máquina (para proporcionar el aumento o disminución de valores). Se definió un algoritmo que modificaba parámetros, hasta alcanzar las condiciones deseadas.</p>	<p>T y P de cavidad</p>		<p>Sistema de control de parámetros, en tiempo real, para mantener la calidad definida. Algoritmo genera parámetros para compensar desviaciones y así controlar el proceso. Relación de T y P de cavidad del molde, con la calidad del producto.</p>
--	--------------------------------------	----------	----------	--	--	---	-----------------------------	--	--

<p>[80] Böttjer, T., et al. (2022)</p>	<p>Cuidado y Prote- cción compo- nentes de moldes</p>	<p>XGBoost</p>	<p>XGBoost se usó para funciones de clasificación y regresión de datos. Dicho sistema estaba basado en árboles de decisión.</p> <p>Su implementación se complementó con técnicas como Multivariate statistical process control - MSPC (técnicas de control de procesos estadísticos multivariados).</p>			<p>El contenido de la base de datos se usó para cuantificar la antigüedad del molde (según su uso en la producción). Los datos se normalizaron de acuerdo con las tolerancias de cada dimensión, de tal manera que 0 fuese el valor objetivo, +1 el límite de especificación superior y -1 el límite inferior (los valores fuera de rango se consideraban fuera de especificación y son defectivos). También se adicionaron datos de mantenimiento, los cuales se normalizaron, porque tenían formato de texto libre (con él se explicaban causas/problemas del molde): se hizo una clasificación a cada causa de mantenimiento y se clasificó si se relacionaba a una etapa de producción o desgaste en el tiempo de vida del molde.</p> <p>Para conocer y modelar las desviaciones de las dimensiones de los elementos, y de esta forma, conocer la degradación de los moldes, se utilizó MSPC, mediante medidas de calidad reducidas a variables latentes.</p> <p>El modelo se hizo mediante una clasificación de tres tipos de ciclo de vida, para clasificar el nivel de desgaste de molde: rodaje inicial, operación y desgastado (se definen rangos de desgaste para los tres niveles). Se probaron enfoques de mínimos cuadrados parciales, con análisis discriminante y XGBoost, con variables latentes (referentes a las características de construcción).</p>	<p>Los datos de metrología provinieron de la medición de 10 puntos geométricos del producto y cinco características de construcción</p>	<p>La base de datos contenía mediciones históricas de la producción de una misma geometría con 13 moldes distintos. /En total fueron 17203 muestras por punto de medición, (cada muestra hacía referencia a las mediciones realizadas a las cavidades del molde), se adicionaron datos normalizados sobre las causas de mant. hechos al molde. / Los datos del molde se clasificaron en seis etapas del ciclo de vida.</p>	<p>Es un modelo para cuantificar el tipo de vida útil y progresión de la degradación de los moldes de inyección. Clasifica el estado de molde (ejecución inicial, producción o desgastado) a partir de muestras de metrología, con una precisión del 88%.</p>
--	---	----------------	---	--	--	--	---	--	---

<p>[81] Shelesh - Nezhad , K., et al. (1997)</p>	<p>Diseño procesos</p>	<p>Híbrido: Razonamiento basado en reglas (RBC) y en casos (CBR)</p>	<p>CBR se usó para conseguir la magnitud óptima de parámetros, según el material, flujo y la geometría (primera configuración de prueba de parámetros). Con RBS se propusieron acciones correctivas que derivaron en la combinación de parámetros que se debían cambiar durante la optimización y las posibles variaciones.</p>	<p>Moldflow Programador C++</p>		<p>CBR. 1. Se determinó un número adecuado de casos históricos exitosos (biblioteca del sistema), que incluían parámetros de operación óptimos y condiciones iniciales del material: Se definió el espacio del problema, contemplando las restricciones (relacionadas con la $T_{fusión}$, T_{molde}, T_{iny}, $P_{sistema}$, flujo) y los defectos que ocurrían al pasar los límites. Con el simulador se crearon casos con problemas preliminares y mediante acciones iterativas se definió su optimización (cuya solución se encontraba en el espacio definido o rangos de parámetros). 2. Se hizo una clasificación de los casos de referencia, para relacionar las características de nuevos problemas con datos existentes. La búsqueda de soluciones pasadas se hizo con reglas "if/then", para encontrar similitudes entre casos. A partir del uso de soluciones existentes se construyó un nuevo arreglo, que consideraba las diferencias entre el problema pasado y el actual. De este modo se obtuvo $T_{fusión}$, P_{iny}, tiempo iny, dentro de las restricciones del problema planteado. 3. Se implementó un subsistema de análisis de flujo y posprocesador para delimitar el resto de los parámetros ($T_{cilindro}$ y boquilla, $v_{el.iny}$, $P_{hidráulica}$, $t_{plastificación}$, etc.). 4. Se configuró la máquina con los parámetros delimitados. En el caso de que se presentaran defectos se utilizó RBS para ajustar variaciones y optimizar problema.</p>	<p>CBR. Variables de entrada: Tipo de material, Geometría del producto, Patrón de flujo (radial o unidireccional) Variables de salida: parámetros de la máquina</p>		<p>Sistema inteligente e interactivo que ayuda a obtener los parámetros de proceso. Permite reducir tiempo de optimización, arranque y dependencia de expertos para realizar ajustes.</p>
--	----------------------------	--	---	---	--	--	---	--	---

<p>Zhou, H., et al. (2007)</p>	<p>Diseño y optimización de parámetros</p>	<p>Híbrido: Razonamiento basado en casos (RBC) + Fuzzy inference (FI)</p>	<p>RBC para configuración de parámetros iniciales basados en casos pasados. Primero se calcularon los caracteres geométricos del producto, se emparejó y recuperaron los casos similares (por medio de una función de similitud). Se adaptaron los casos para el nuevo problema, mediante estrategias de adaptación. Fuzzy inference. Para su implementación se usó el modo de "reglas múltiples con antecedentes múltiples" y el modelo Mamdani's Fuzzy, en el motor de inferencia difusa (fuzzy inference). Su estructura se compuso de una base de reglas, base de datos y mecanismo de razonamiento.</p>	<p>-TCP/IP -Winsock 16 -Haitai injection machine</p>	<p>Máquina HAITAI 3800A con un controlador EST P10CY</p>	<p>El sistema inteligente (CBR+FI) se integra en el controlador de la máquina de inyección a través de una interfaz de comunicación</p> <p>CBR Se debe hacer una biblioteca de casos, y una función que describa el problema y la solución (se toma como condiciones previas el molde, material y tipo de máquina). Para calcular los caracteres geométricos se debe: 1) Generar elementos finitos triangulares por "triangulación de Delaunay" en las superficies de la pieza. 2) Construir relaciones coincidentes entre los nodos de la malla; 3) calcular el grosor de cada elemento de malla sobre la base de información coincidente; 4) crear gráfico conectado sobre la base topográfica y relaciones de coincidencia; 5) calcular la longitud del flujo mediante algoritmo Dijkstra; 6) calcular V y área superficial de la pieza y calcular espesor de la pieza. 7) Mediante una función de coincidencia se revisan y eligen casos similares de la biblioteca. Se adaptan los casos anteriores mediante una matriz de casos, razonamiento basado en reglas y ajuste de parámetros (según el caso de casos similares y las similitudes que tenga).</p> <p>Para desarrollar el sistema de FI se debe 1) crear procedimientos de "fuzzification" para corregir las variables de entrada y salida en formato del algoritmo. 2) tener una biblioteca con suficientes reglas difusas, 3) desarrollar funciones de pertenencia para todo el conjunto, 4) establecer un esquema de inferencia difusa, eficaz y eficiente, 5) mantener una estrategia de "defuzzification" para obtener un valor de salida adecuado.</p> <p>La integración del modelo en la máquina de inyección se hace con un interfaz de comunicación.</p>	<p>CBR:</p> <p>Entrada: características del material y geometría del producto;</p> <p>Salida: $T_{fusión}$, T_{molde}, vel_{iny}, P_{iny}, $P_{empaquetado}$, $T_{enfriamiento}$.</p>		<p>Sistema inteligente integrado en la máquina de inyección. El sistema es capaz de determinar parámetros iniciales solo considerando el material y la geometría del producto. También es capaz de optimizar los parámetros en línea.</p> <p>La interfaz permite la comunicación de información, reglas y decisiones entre la máquina de inyección y el sistema inteligente.</p>
--------------------------------	--	---	--	--	--	--	---	--	--

<p>[83] Chen, Y.-F., et al. (2019)</p>	<p>Inspección de calidad</p>	<p>Redes neuronales artificiales</p>	<p>El clasificador multiclase se basa en la arquitectura ResNet de 50 capas. En su estructura se adiciona una capa de concatenación. / Este tipo de técnica distingue defectos, y también puede identificar imágenes de fondo no defectuosas.</p> <p>Para las capas de entrada y salida, se usaron los siguientes hiperparámetros: tamaño de lote = 32, tasa de aprendizaje = 0.005, caída de peso = 0.0004, y número máximo de pasos = 5000.</p> <p>Resto de las capas, y actualización de la red, se usa: tamaño de lote=32, tasa aprendizaje=0.0002, disminución de peso=0.0004 y pasos máximos=15000.</p>	<p>Google GitHub TensorFlow</p>	<p>Cámara ccd Lente focal 12mm Barras de iluminación Digital dimmer</p>	<p>Se desarrolló un espacio para la captura y registro de imágenes, en donde se reguló la iluminación para tener mejor reconocimiento de defectos. Se hizo un pretratamiento de imágenes con método de aumento de datos común.</p> <p>El sistema estaba compuesto de dos secciones: 1) Sección de entrenamiento fuera de línea, en donde el mapa de anotaciones de píxeles etiquetaba la región defectuosa y no defectuosa, también se hicieron máscaras de píxeles con las que se obtuvo un mapa de máscaras y la imagen original. Estas sirvieron para entrenar el modelo ResNet V1 50, primero a la capa de entrada y salida. Después se entrenó y actualizó toda la red (con otros parámetros). 2) En la sección de predicción en línea, la imagen se dividió en parches. Cada parche se clasificó según el peso entrenado (a través de una RNA Convolutiva). Con softmax se clasificaron los parches y se generó un mapa de características. /Con cada mapa calculado, se reorganizaron los parches en el tamaño original, mediante el procesamiento de la imagen y se superpusieron a la imagen original, para resaltar los defectos localizados.</p>	<p>La imagen grande se cortó en parches de 64x64, y el clasificador de defectos se usó para predecir los parches.</p>	<p>El conjunto de datos estaba compuesto por imágenes con defectos de la superficie de las piezas. Se usaron imágenes de tamaño 2592 x 1944 píxeles, recortadas en parches de 64x64.</p> <p>Se usó un paso de etiquetado 14 y el fondo se estableció en 34 con el fin de tener balance de datos. Se generaron 10 mil imágenes para cada clase y se dividió en dos para el entrenamiento y la validación.</p> <p>La entrada del clasificador fue 64x64, por eso se utilizó un método normalizador.</p>	<p>Sistema de detección de defectos, mediante inspección óptica automática.</p> <p>El sistema puede reconocer el fondo y el defecto (el tipo y posición) dentro de las imágenes, con 73.46% de precisión de detección de defectos.</p>
--	------------------------------	--------------------------------------	---	---	---	---	---	---	--

<p>[84] Chou- chene, A., et al. (2020)</p>	<p>Inspección de calidad</p>	<p>Redes neuronales artificiales</p>			<p>Sensores visuales</p>	<p>El proceso de implementación general consistió en:</p> <ol style="list-style-type: none"> 1) Adquisición imágenes del producto objetivo. 2) Preprocesamiento de imágenes para eliminar ruido, mejorar contraste, realizar una binarización, para mejorar la calidad de la imagen. 3) Uso de técnica ML para clasificar las imágenes. Se usaron principalmente las RNA y, también en multicapa para procesos de Deep Learning. 4) El resultado de la técnica representó la decisión para rechazar o no el producto. 			<p>Se expone, de forma general, la implementación de un método de inspección de calidad inteligente.</p>
--	------------------------------	--------------------------------------	--	--	--------------------------	---	--	--	--

<p>[85] Haselmann, M., Gruber, D.P. (2019)</p>	<p>Inspección de calidad</p>	<p>Redes neuronales artificiales</p>	<p>Redes neuronales convolucionales, con el fin de segmentar la información proveniente de las imágenes. Para el codificador: se definieron ocho capas convolucionales después de la 2a, 4a y 6a capa. El tamaño de entrada de la red se definió como 64x64 y un tamaño de mapa 8x8 en la 6a capa. En la 7a capa se usó un Kernel 1x1 para reducción de dimensionalidad. Se utilizó ReLU como función de activación para cada capa en el codificador y una normalización de lotes descendentes (BN) El decodificador consistió en dos capas, con funciones de activación lineal sin normalización. Se usó un optimizador ADAM para el entrenamiento, con $\alpha=0.0005$, $\beta_1=0.9$, $\beta_2=0.999$, $\epsilon=10^{-8}$ y un tamaño de lote de 336.</p>			<p>En el preprocesamiento se definieron máscaras que pudieran separar la superficie del producto, de la parte visible del fondo y se crearon imágenes con defectos (se implantaron defectos) para crear base de datos, con los que se entrenó el modelo inteligente.</p> <p>Se implementó un modelo de redes neuronales convolucionales. Éste se dividió en ocho capas como codificador y dos capas que desglosaban la imagen. El entrenamiento se realizó con un optimizador ADAM. los pesos se definieron a partir de una distribución gaussiana truncada.</p> <p>Antes de evaluar el modelo se hizo una revisión del grado de desequilibrio del modelo entrenado (debido al uso de imágenes con defectos implantados). / La validación y evaluación se realizaron con imágenes no tratadas (para la validación se usaron imágenes con defectos inyectados, pero para la evaluación se prefirió el uso de casos reales).</p> <p>La evaluación se basó en estudios de: curva ROC (Característica operativa del receptor), que graficaba la cantidad de casos verdaderos positivos, contra falsos positivos; análisis de precisión, coeficiente de correlación de Matthew e índice de detección correcta de defectos.</p>	<p>Las imágenes con las que se alimentó el procesador fueron de 2448 x 2050 píxeles. En ellos se expuso la superficie del producto, desde distintas direcciones.</p>	<p>Se modificaron las imágenes, mediante el método de Haselmann y Gruber, para cubrir la mayoría de los defectos reales que podían ocurrir en el producto. Su síntesis se hizo mediante</p> <ol style="list-style-type: none"> 1) Generación de "esqueletos" de los defectos binarios. 2) Elaboración de texturas aleatorias sobre la base del esqueleto. 3) la textura del defecto se usó para modificar la imagen sin defectos. <p>Este procedimiento permitió crear imágenes de distintas morfologías y distintos defectos (con diversos contrastes e intensidades) El aumento de imágenes se obtuvo con la rotación, zoom, cizallamiento, etc. del producto, (en datos de 64x64). / Cada ubicación de defecto implantado se ubicó de forma independiente y aleatoria.</p>	<p>El sistema es capaz de detectar defectos a partir de imágenes de superficie, con precisión de píxeles. El entrenamiento del método se hace a partir de imágenes modificadas (defectos implantados en imágenes de superficie sin fallas).</p>
--	------------------------------	--------------------------------------	---	--	--	---	--	---	--

<p>[22] Kim, G., et al. (2021)</p>	<p>Inspección de calidad</p>	<p>Redes neuronales artificiales: MLP- Multilayer perceptron + CNN - Convolutional neural network + GRU</p>	<p>MLP- Tipo de red neuronal, formada por multicapas completamente conectadas y activaciones no lineales. Se prueban 1, 2, 3 y 4 capas con Kernel de tamaño 16, 32, 16 y 8, respectivamente.</p> <p>CNN. Es la clase de RNA más usadas en la visión computarizada, por su capacidad de extraer patrones jerárquicos en el reconocimiento de imágenes y videos. Se prueban 1,2,3 capas convolucionales y una capa totalmente conectada. El tamaño de Kernel que usan es 8, 5, 3 y 16, respectivamente.</p> <p>GRU. se usa para el modelado de secuencias, clasificación de series temporales, modelado de lenguaje y para tratar datos expresados en forma secuencial. El modelo puede encontrar patrones en datos secuenciales. Sus capas son 1, 2 - Gru y 1,2 Totalmente conectada. El tamaño kernel es 256, 128, 32 y 8, respectivamente.</p> <p>Todos los modelos fueron combinados con un método de fusión temprana. Casi todos utilizan una función de activación ReLU, excepto dos de GRU, que utilizan tanh.</p>	<p>Sistema MES Tensorflow y keras</p>	<p>GPU:GTX 1080 Ti Sensores P y T</p>	<p>La investigación tuvo tres pasos: 1. datos multimodales se recopilaron y normalizaron. 2. se emplearon métodos basados en RNA profundas, para la detección de fallas. 3. se implementaron métodos de fusión temprana.</p> <p>Los datos se colectaron por el sistema MES de la máquina de inyección., a través de dos sensores que recopilaban datos tabulares y datos de series de tiempo. / Se estandarizaron las series de tiempo mediante la técnica de rellenado con ceros, para que cada serie presentara una longitud equivalente. Se usaron técnicas de regularización como dropout, normalización batch, normalización por capas y parada anticipada, con el fin de prevenir el sobreajuste del modelo.</p> <p>Para el desarrollo de cada modelo (GRU, CNN, MLP) se utilizó la función de pérdida focal en el entrenamiento de modelos DL.</p> <p>Los hiperparámetros se ajustaron mediante búsqueda aleatoria. Se utilizó un optimizador de Adam con tamaño de lote=128. También se usó una tasa de aprendizaje = 1e-3, y caída de peso = 1e-4.</p> <p>Se hizo un estudio de puntaje F1, precisión, exactitud y recall, se comparó el desempeño de cada modelo individual y después se realizó una fusión temprana de los métodos que presentan mejores resultados en la evaluación.</p> <p>Los tres submodelos se colocaron en paralelo, y cada uno tomó individualmente un tipo de entrada correspondiente a la vez. El entrenamiento se realizó para el modelo completo, en lugar de cada modelo individual, con un esquema de extremo a extremo. //</p>	<p>Parámetros tabulares: tiempo de inyección, llenado, plastificación, tiempo ciclo y de cierre de compuerta; posición cushion, posición del pistón al cambiar de etapa de empaque a plastificación, posición de compuerta abierta; velocidad máx. de inyección, vel. máxima a la que gira el tornillo y velocidad promedio del tornillo; Presión máx. de iny., contrapresión máx., contrapresión promedio; y T del cilindro.</p> <p>Parámetros con datos de series temporales: Temperatura superior e inferior de la corriente</p>	<p>Cada ensayo recopilado de los ciclos de inyección consta de 23 parámetros provenientes de sensores. La base de datos está compuesta por 2000 valores de series de tiempo, cuya clasificación de calidad está delimitada de forma manual (0 si es un producto correcto y 1 si es defectuoso).</p>	<p>Se trata de un modelo de detección de fallos, el cual no usa datos de simulación para validar el modelo, sino datos reales.</p> <p>El modelo fue entrenado para extraer representaciones significativas, clasificar productos fallidos y trabajar con datos multimodales.</p> <p>El modelo basado en redes neuronales profundas con un esquema de aprendizaje multimodal puede extraer características del proceso y clasificar simultáneamente productos defectuosos, además está combinado con un modo de fusión temprana</p>
------------------------------------	------------------------------	--	---	--	--	---	---	---	--

<p>[86] Muresan, M. P., et al. (2020)</p>	<p>Inspección de calidad</p>	<p>Redes neuronales artificiales</p>	<p>Se utiliza una RNC, basada en una arquitectura LeNet-5 con ocho capas. para distinguir y clasificar imágenes de 32x32 de la posición de los bujes.</p> <p>La primera capa es de imagen 32x32x1, la de salida es 28x28x6. Su núcleo es 5x5, con seis mapas y paso de una, esta capa detecta características básicas de la imagen.</p> <p>La segunda capa es Max-pooling de entrada 28x28x6, salida 14x14x6, núcleo con ventana 2x2 y un paso de 2, para reducir el mapa a la mitad, solo seleccionando las características dominantes.</p> <p>La tercera capa tiene entrada 14x14x6, salida 10x10x16, núcleos 5x5 y 16 mapas, con el fin de aprender características complejas, como combinaciones de líneas y formas básicas.</p> <p>La 4a también es capa Max-P y tiene características de la 2a, con una salida 5x5x16. La 5a tiene kernel 5x5 y 400 mapas, para aprender características más complejas del mapa, su salida alimenta a una red de tres capas conectada, para clasificar la en función a las características proporcionadas por capas convolucionales y Max-Pooling.</p> <p>Se utiliza la técnica de regularización por "abandono" para evitar sobreajuste (en capa convolucional nivel uno y tres). Se usa un optimizador Adam, con tasa de aprendizaje 0.0001.</p>		<p>PC con Intel i7 - 7700HQ, 2.80 GHz, 16 GB RAM</p>	<ol style="list-style-type: none"> 1) Preprocesamiento de datos: Se adquirieron fotogramas, se redujo la imagen de entrada en 85% para reducir el tiempo de procesamiento, se eliminó el ruido Gaussiano en la imagen, mediante un filtro Kernel gaussiano 5x5 (dejando sin alterar las partes de la imagen que sirvieran para detectar la superficie del molde). La imagen se transformó a escala de grises (para facilitar el análisis y reducir el tiempo de procesamiento). 2) De la imagen procesada en (1), se aisló el área de interés del molde, mediante una umbralización Gaussiana, con el fin de reducir áreas de la imagen, que fueron innecesarios para el análisis. Se usó un algoritmo de trazado de bordes que ayudó a reconocer la perspectiva de la imagen, corrigiendo errores de segmentación por mala iluminación. 3) Detección de bujes. fue similar a (2). Se delimitaron físicamente las áreas donde se debían colocar los bujes. Se estableció un nivel óptimo de brillo y contraste en la imagen, con el fin que no fuese impedimento para detectar la ubicación de los contornos y posición de los bujes. Para ello, se ajustó con una transformación lineal cada píxel de la imagen y se ajustaron los valores mediante una equalización de histograma adaptativo. 4) Se clasificó la posición de los bujes, mediante un modelo de RNC para clasificar una posición correcta, incorrecta o falta de bujes. Su entrenamiento se hizo mediante un GPU. 5) Se realizó una evaluación de 200 secuencias de escenarios en condiciones de distinta iluminación, cámaras, ángulos y distancias. 6) Se optimizó la detección de los bujes con un algoritmo de umbralización global, para modificar el cuadro delimitador para el análisis de las imágenes, y así mejorar el procesamiento y tiempo de detección. 	<p>Posición correcta en el molde de los bujes: brida ancha hacia el molde de inyección y ubicada en punto central del orificio.</p>	<p>Se usó un conjunto de 1000 imágenes de bujes en diferentes posiciones y con distintos escenarios (nivel de luz).</p> <p>Se aumentaron los datos al inducir ruido en las imágenes de entrenamiento (como desenfoque, transformación de perspectiva, ubicación de imagen y variación de brillo), hasta incrementar a 8000 fotos, las cuales se usaron para entrenar, validar y evaluar.</p>	<p>Para el caso de producción de componentes de automóviles, donde se deben incrustar bujes en el molde, el sistema inteligente detecta y clasifica el posicionamiento de los bujes. También advierte a los operadores en el caso que la ubicación sea incorrecta.</p> <p>El objetivo es reducir el número de productos defectuosos por mala ubicación de los bujes.</p> <p>Se alcanza cerca del 99% de detección de posición de bujes, a diferentes condiciones: luz natural y artificial; vista directa, a 45°, 60° (hacia la izquierda y derecha); varias distancias del molde y varias posiciones de cámara.</p>
---	------------------------------	--------------------------------------	--	--	--	---	---	--	--

<p>[87] Mei, Y., Wu, D.-L. (2009)</p>	<p>Inspección de calidad Optimización de parámetros.</p>	<p>Support vector machine</p>		<p>Matlab CAE</p>		<p>Para cuantificar y reconocer la aparición de líneas de soldadura primero se simula la producción de piezas con diferentes parámetros, con el fin de obtener imágenes de productos con defectos de línea de soldadura. Se hace un tratamiento previo a las imágenes para que se pueda facilitar su procesamiento (se "resalta" la ubicación del defecto). Para procesar imágenes, primero se lee el gráfico de predicción de líneas de soldadura. De las imágenes se interceptan y cuantifican algunas líneas representativas del defecto, se implementa una función para calcular las líneas. Se transforma en escalas de grises la imagen para identificar zonas diferentes al promedio de la región de interés y del fondo. Se usa operación de esqueletización para simplificar las imágenes a un píxel, sin alterar la estructura de la imagen. Se usa función "bwarea" en Matlab, para calcular el número de píxeles y agregar pesos (clasificar) los píxeles entre los que presentan la línea de soldadura y las que no. Se crea modelo SVM y se entrena con los datos simulados y procesados, de los puntos anteriores.</p>	<p>Líneas de soldadura de cara principal $T_{fusión}$ y T_{molde}</p>	<p>Se entrena el modelo SVM con las imágenes generadas por simulador y procesadas en Matlab (con las líneas de soldadura identificadas).</p>	<p>Modelo para cuantificar líneas de soldadura a partir del procesamiento digital de imágenes. Optimización de parámetros con SVM para predecir y reducir líneas de soldadura.</p>
---	--	-------------------------------	--	-----------------------	--	---	---	--	--

<p>[88] Tseng, T.-L., et al. (2016)</p>	<p>Inspección de calidad y clasificador de productos</p>	<p>Support vector machine</p>	<p>Se utiliza para predecir y clasificar piezas buenas de malas.</p> <p>Se prueban cuatro tipos de kernel: lineal, polinomial, RBF (radial basis function) y sigmoide.</p> <p>Los mejores resultados se obtuvieron al trabajar con un Kernel tipo RBF, un valor $\gamma = 2$ y un valor $C = 376$.</p> <p>También se obtuvo buen resultado con kernel lineal y polinomial. Sin embargo, se considera el valor elevado de C, del modelo con RBF, lo hace más atractivo.</p>	<p>Visual Basic 6 Statistica 8.0</p>	<p>2 robots de ensambles, accesibles en la red</p> <p>2 sensores de visión Cognex DVT 540.</p> <p>Cámara con resolución 640 x 480</p> <p>Controlador RCX 40</p>	<p>El modelo de clasificación y monitoreo se realizó con la técnica SVM. Para conocer los parámetros óptimos de C se utilizó un método de validación cruzada, con K-fold ($k=10$). Se revisaron diferentes funciones kernel (con parámetros, definidos por prueba y error) y se evaluó su precisión de entrenamiento, prueba y validación.</p> <p>Para el entrenamiento y evaluación, se adquirieron y clasificaron datos de forma manual y automática (en el primero, la persona midió las dimensiones del objeto y en el segundo las dimensiones las obtuvo la cámara DVT).</p>	<p>Las dimensiones del producto se consideraron para el funcionamiento del sistema y la clasificación de calidad.</p>	<p>El entrenamiento se hizo con 138 valores experimentales. cinco características de entrada (cinco dimensiones diferentes de la pieza) y dos de salida (si cumple o no cumple) y 966 datos totales. Se usaron 2/3 de los datos para entrenar y 1/3 para evaluar el modelo.</p> <p>Se usaron siete tipos de objetos para reproducir los casos, en donde uno de ellos tenía las especificaciones requeridas y los otros no.</p>	<p>Se desarrolló un sistema capaz de controlar, directamente y de forma remota, el proceso de inyección. Con este modelo se predice y verifica la calidad de los productos, mediante el monitoreo de la máquina y de las características físicas (dimensiones) del producto. Del mismo modo es capaz de clasificar y separar los productos no conformes, con robots automatizados.</p>
---	--	-------------------------------	--	--	---	--	---	--	--

<p>[89] Librant z, A., et al. (2017)</p>	<p>Inspección de moldes</p>	<p>Redes neuronales artificiales</p>	<p>La red neural usada es MLP Es usada principalmente para reconocimiento de patrones y clasificador supervisado.</p> <p>Su estructura está compuesta por seis neuronas en la capa de entrada (que reciben las señales del método PCA), 12 en la capa oculta y 4 en la de salida (que representa las diferentes texturas que puede tener el molde). Se usaron dos funciones de transferencia (logística/sigmoidal y lineal), tasa de aprendizaje=0.1 y tasa de impulso=0.9.</p> <p>Se utiliza un filtro Gabor, el para procesamiento de imágenes, clasificación de texturas y detección de estructuras específicas; y PCA para reducir la dimensión del vector de características de entrada.</p>	<p>C++ y librería PROEIKON</p>	<p>Laser He-Ne una cámara y dos motores paso a paso y controlador interconectado a puerto de PC</p>	<p>El fundamento del modelo se basó en la segmentación por análisis de textura, medición de circularidad y evaluación de superficie. Para lograrlo:</p> <ol style="list-style-type: none"> 1. Se recopilaron imágenes en color RGB y se generaron versiones en escala de grises. 2. Se hizo una segmentación de la imagen, por medio del análisis de textura, a través de las Funciones Gabor (donde se trabajó con un banco de 24 kernel y diferentes frecuencias y orientaciones. con PCA se redujeron las dimensiones de vector (a seis elementos); / Se reconstruyó la imagen, se clasificó la textura y detectaron las regiones clave con MLP. Para conocer el núm. de neuronas en la capa oculta se realizaron experimentos, variando este número y se eligió el modelo con el menor error cuadrático medio, MSE. 3. Con las medidas de circularidad obtenidas, se realizó un análisis de circularidad de la región de interés. 4. Se evaluó la superficie del molde. 	<p>Medida de circularidad de las regiones del molde.</p>	<p>Datos obtenidos de cinco muestras de moldes: 1 hecho por Mitutoyo, y cuatro mecanizados. De los moldes uno fue usado como referencia, dos tenían defectos y los otros dos no. Se recopilaron 3420 imágenes, 420 del primer molde y 750 del resto.</p>	<p>Sistema de inspección y evaluación de superficie de molde. Automatiza el análisis de la superficie de pulido por medio de un láser dispersado en la superficie. Mapea, identifica y clasifica defectos en la superficie pulida, como rayones y sobrepulido, lo que disminuye costo y tiempo de inspección.</p>
--	-----------------------------	--------------------------------------	---	--------------------------------	---	---	--	--	---

<p>[90] Hsu, T.-C., et al. (2022)</p>	<p>Monitoreo de parámetros y control de proceso</p>	<p>Redes neuronales artificiales</p>	<p>Se usa ResNet50, la cual es un tipo de red neuronal convolucional con 50 capas de profundidad. Se utiliza para extraer y clasificar características de imagen de regiones de interés.</p> <p>La estructura está compuesta por filtros convolucionales; agrupadores, Max-pooling; técnicas de regularización dropout. También se utilizó una función de activación ReLU (rectified linear units) para capas convolucionales, y Softmax en capa de salida</p> <p>La tasa de aprendizaje se fijó en 0.01 y se utilizó un optimizador de Adam (frecuentemente usado para RNA profundas), y una función de pérdida L2 o del error cuadrático medio. El entrenamiento se realizó durante 100 épocas.</p>	<p>Cloud computing Anylogic cloud</p>	<p>Cámara Pcam 5c Field Programmable Gate Array (FPGA) PLG-image data collection Válvula electromagnética monitor del panel de control /</p>	<p>a) Se obtienen dígitos y se transmiten números extraídos de parámetros PLC a través de un sistema inteligente. Con una cámara se monitorean las pantallas de las máquinas en todo momento y se capturan imágenes de parámetros.</p> <p>b) se hace preprocesamiento para normalizar la iluminación de las imágenes capturadas y evitar distorsiones de color y contraste. Se usa un modelo estadístico basado en histograma, para extraer características de las imágenes de entrenamiento, en condiciones de iluminación estándar. Se ajustan las imágenes de entrada a condiciones de iluminación estándar.</p> <p>c) Se genera un mapa de prominencia para detectar las regiones de interés donde se encuentran los dígitos.</p> <p>d) En el reconocimiento de dígitos de las imágenes, se utiliza un modelo base compacto, ResNet50, con filtros convolucionales separables. En él se implementó Inception network para determinar la posición de dígitos y max-pooling para agrupar regiones de interés de varios niveles y así estandarizar las características de los datos.</p>	<p>El rendimiento de producción depende de: perfil de temperatura en la máquina (6 etapas del proceso) y tiempo de procesamiento. También se consideran como variables de configuración P, velocidad y medición.</p>	<p>Las fotos de paneles de control se toman de ocho inyectoras diferentes, provenientes de dos industrias de inyección.</p> <p>La obtención de datos se realizó con un formato de transmisión de video de 30 cuadros por segundo.</p> <p>En la base de datos de imágenes no se tuvo limitación de configuraciones de iluminación. El conjunto de datos contiene imágenes de 54,688 dígitos, los cuales fueron normalizados a 28x28 para el proceso de formación.</p>	<p>Sistema basado en un lector de datos, capaz de monitorear las condiciones de las inyectoras en tiempo real, con el fin de mejorar su productividad y desempeño. Se consiguió una precisión de reconocimiento de dígitos de 97.56%</p> <p>El Lector de datos por visión (VDR) en tiempo real monitorea la pantalla del PLC constantemente para obtener los datos de producción. Si los datos no están en el rango normal, el sistema ajustará los parámetros correspondientes a través de dispositivos, en lugar de usar la forma manual.</p>
---	---	--------------------------------------	---	--	--	---	--	--	---

<p>[91] Ben-singh, R. J., et al. (2019)</p>	<p>Optimización de parámetros</p>	<p>Híbrido: Redes neuronales artificiales + particle swarm optimization (PSO)</p>	<p>Se utilizó BP RNA compuesta por (7-13-6). La función de activación de la capa oculta fue lineal, y tangencial en la capa de salida. La regla de aprendizaje fue Levenberg-Marquardt (LM) back propagation. PSO se utiliza para optimizar los parámetros obtenidos del RNA. En el algoritmo se considera swarm(enjambre) = 50 partículas, iteraciones =100, $c1=c2=1.5$, factor de inercia con disminución 1 a 0.3, en cada iteración desde el principio hasta el final (para las 100 iteraciones).</p>	<p>Moldflow MATLAB 2010</p>	<p>Talysurf – PGI 120 de Taylor-Hobson Make.</p>	<p>Se definieron los parámetros que se usaron para mapear el proceso de inyección con RNA. Los rangos se definieron, considerando una deformación y contracción mínima (se utiliza simulador) Se realiza un DOE, por medio de un diseño de arreglo ortogonal Taguchi. En donde se diseñaron 44 conjuntos de variables de entrada para realizar experimentos. Se diseñó el modelo RNA se entrenó y evaluó con las muestras de la base de datos. La evaluación se realizó a través del coeficiente de determinación R2, RMSE y desviación porcentual relativa (RPD). En el sistema híbrido PSO + RNA, se utilizó el algoritmo PSO "mejorado" para optimizar los parámetros del modelo anterior. //</p>	<p>Variables de entradas: $t_{llenado}$, $P_{llenado}$, $t_{mantenimiento}$, $P_{mantenimiento}$, $T_{fusión}$, T_{molde}, $t_{enfriamiento}$. Variable salida: Calidad del producto, basada en: radio de la curvatura, ondulación y rugosidad de la superficie.</p>	<p>Los datos para el entrenamiento constaban de 44 conjuntos de experimentos (obtenidos con el DOE) De la base de datos 40 conjuntos se usaron para entrenamiento y 4 para prueba.</p>	<p>El sistema propuesto permite obtener los parámetros óptimos para el proceso. Predice las dimensiones del producto con menos del 1% de desviación (entre la predicción y las dimensiones reales). Al comparar con otros modelos se observa que puede llegar a una convergencia en menos iteraciones.</p>
---	-----------------------------------	---	--	-----------------------------	--	--	---	--	--

<p>[92] Zhao, P., et al. (2020)</p>	<p>Optimización de calidad</p>	<p>Híbrido: Support vector Machine + Particle swarm optimization (PSO)</p>	<p>SVC es un método de SVM, donde se construye un hiperplano de margen máximo, que también se conoce como límite de clasificación, para separar las muestras positivas y negativas. Al método SVC se agrega el algoritmo de optimización PSO para ajustar los hiperparámetros y minimizar el error de resultados. En PSO se construye una función de aptitud que permite converger rápidamente. Los hiperparámetros del modelo: $C=5451.3$ y, para definir Kernel, se utiliza la función Kernel Gaussiano, cuyo $\gamma=5.74$</p>		<p>Balanza FA2004, de Shanghai Sunny Hengping Scientific Instrument Co.</p>	<p>Se realizan pruebas con distintos parámetros y se registran las condiciones empleadas y los pesos obtenidos en los productos (etiquetados como exceso (+1) o deficiencia (-1) de especificación). Como SVC es un modelo supervisado, el conjunto de datos debe etiquetarse. Al modelo SVM se le agrega PSO para encontrar sus hiperparámetros óptimos. Para ello: 1) se eligen los parámetros del modelo y se establecen rangos iniciales (los cuales deben cubrir todos los parámetros factibles). 2) Se realizan experimentos bajo cada parámetro del proceso y evalúan los resultados, comparando el peso del producto con el peso estándar. 3) Se etiquetan las muestras y prepara el conjunto de datos para el SVC. Se selecciona la función Kernel adecuada y entrena el SVC con los datos elegidos. 4) Se ajustan los hiperparámetros con PSO. 5) Se evalúa la posición del hiperplano que ofrece el modelo SVC (correspondientes a las mejores combinaciones de parámetros). Se inyectan 30 productos con parámetros provenientes del modelo y se comparan con el objetivo.</p>	<p>Parámetro entrada: T_{iny} y $P_{empaquet}$; Parámetro salida: peso del producto</p>	<p>Se hacen 24 experimentos con diferentes parámetros del proceso. Se registraron todos los datos y se mide el peso del producto (sin considerar corredores y punto de inyección). / La evaluación se realizó con datos provenientes de la fabricación de 30 productos, con los parámetros obtenidos del modelo SVC.</p>	<p>Sistema de clasificación de calidad sobre el peso del producto. (ya que el parámetro puede ser mayor o menor que el objetivo). Se tiene un porcentaje de error promedio de 0.0212%. Además, requieren pocos ejemplos (lo que disminuye el costo y el tiempo involucrado). / Generar procesos de parámetro para una inyección óptima.</p>
<p>[93] Tsai, K.-M., Luo, H.-J. (2017)</p>	<p>Optimización de parámetros</p>	<p>Híbrido: Redes neuronales artificiales + algoritmo genético</p>	<p>BPNN se utilizó como modelo de predicción de las condiciones superficiales del producto. Se usó un modelo de tres capas (una capa oculta con seis neuronas); función de activación sigmoide logarítmica positiva, para la capa oculta y de salida. 2000 épocas para entrenamiento, tasa de aprendizaje 0.01. El entrenamiento se realizó con un algoritmo Levenberg-Marquardt, y una función de aprendizaje de descenso de gradiente. AG se usó para optimizar los parámetros. Se usó una codificación binaria en cadenas de 0 y 1, con una población inicial generada aleatoriamente. El tamaño de población fue 30, con probabilidad de operadores de mutación=0.7, y de cruce=0.05; y longitud de cadena=5.</p>	<p>MATLAB</p>	<p>Form Talysurf – PGI 840 de Taylor-Hobson Make.</p>	<p>1. Se realizó un experimento Taguchi para determinar la combinación de parámetros óptima. (Arreglo ortogonal $L_{18}(2^1 \times 3^7)$). / Se realizó un análisis ANOVA para conocer los factores que tienen más influencia en el proceso. Se seleccionaron cuatro factores de control para realizar un DOE factorial 3^4 y así obtener datos para el proceso de aprendizaje y prueba. 2. Se desarrolló un modelo RNA con BP. Para conocer el núm. de neuronas ocultas se implementaron diferentes pruebas de modelos RNA, después se comparó el coeficiente R^2 de las capas ocultas 3 El modelo RNA se combinó con AG para identificar el mejor conjunto de parámetros. Primero se codificaron los parámetros en formato binario, y se definió la función de aptitud (una de ellas es el modelo RNA entrenado), el mecanismo de selección, cruce y mutación. 4. Finalmente, se usó el coeficiente R^2 para determinar la precisión del modelo.</p>	<p>Para experimento Taguchi se consideraron $T_{fusión}$, vel_{iny}, P_{iny}, posición de cambio entre llenado/empaque, $P_{empaquet}$, T_{molde}, $t_{enfriamiento}$. Para el modelo RNA y AG se usaron como parámetros de entrada: T_{molde}, $t_{enfriamiento}$, $P_{empaquet}$, $t_{empaquet}$.</p>	<p>Se capturó la información de 81 ejecuciones experimentales y se dividieron 60 conjuntos para el entrenamiento y 21 para pruebas. El entrenamiento de RNA-BP usó el algoritmo Levenberg-Marquardt</p>	<p>Sistema (ARN + AG) capaz de identificar parámetros óptimos del proceso, de acuerdo con la demanda de calidad de los lentes. Se encontró que la T del molde es el factor más influyente en el proceso de inyección.</p>

<p>[94] Lau, H.Y., et al. (2008)</p>	<p>Optimización de parámetros y predicción de calidad</p>	<p>Híbrido: Redes neuronales artificiales + Support vector machine (SVM) + Virtual search method (VSM)</p>	<p>Se utiliza el derivado de RNA: Radial basis function neural network, para monitorear la calidad del proceso. Su entrenamiento es similar a una regresión lineal (por lo tanto, es más fácil de realizar, en comparación de otros tipos de RNA). La determinación de las neuronas en capa oculta se hace por prueba y error. Para el peso de las neuronas de salida se usa regla delta y otros enfoques estadísticos. / El SVM con VSM se usó para ajustar y optimizar los parámetros.</p>		<p>Sensor de P_{boquilla} Kistler (modelo 4083a) Sensor de $P_{\text{hidráulica}}$ "Kistler", modelo RAG25A200B V1H). Grabadora Hioki, modelo Hicorder Computadora</p>	<p>Se realizaron experimentos basados en el principio del diseño de experimentos (considerando dos niveles para cuatro factores), para determinar los factores más determinantes (P_{iny} y T_{boquilla}). Para conocer y predecir el peso de pieza, se sugiere averiguar la P_{boquilla}. Con este fin se formuló un método de dos etapas: En el primero se usó un modelo RBF-RNA con los factores de entrada: $P_{\text{hidráulica}}$ (y su retraso) y la posición del tornillo; y la salida es $P_{\text{estimada de boquilla}}$. 2) el resultado del punto anterior se usó en otro modelo RBF-RNA, cuya salida fue el peso. (también se hizo prueba con un solo modelo RBF-RNA, con la entrada de la primera etapa y el peso como salida). En la optimización de los parámetros se desarrolló un modelo SVR para predecir el peso del producto, con los ajustes de producción real y el peso objetivo de la pieza a producir. / Se elaboró un modelo VSM, que utilizaba la información del peso predicho y el real, para proporcionar parámetros con los que se podía mejorar el proceso, después de completar el actual ciclo de inyección (las iteraciones las finaliza hasta que el peso actual y el predicho están en el rango de especificación). /El entrenamiento de SVR se hace con los mismos datos usados en RBF-RNA. SVM funciona con la base entrenada SVR.</p>	<p>DOE y SVR. Entrada: T_{boquilla}, P_{iny}, $v_{\text{el iny}}$, $P_{\text{mantenimiento}}$ Salida: peso del producto RNA. Entrada: Posición tornillo, tiempo de apertura de molde. Salida: Peso del producto y P_{boquilla}</p>	<p>RBFNN y modelo SVR. Se probaron dos casos: en el primero se recolectaron 60 muestras de datos, de producciones con tiempo ciclo 23s; de ellas 30 se utilizaron para entrenar el modelo y el resto se usó para probar su desempeño. (se compara la predicción de peso con el peso real del producto). En el segundo caso se recopilamos 30 muestras de datos, de las cuales 15 se utilizaron para entrenamiento y el resto para evaluación.</p>	<p>Se desarrolló un sistema de monitoreo y ajuste de parámetros, basados en la calidad del producto (asumida con el peso de la pieza). RBFNN resultó ser útil para predecir calidad, según los datos de operación. En el primer caso se obtuvo un error de predicción de 0.2% y en el 2do de 1.3% Con SVR se requirieron menos experimentos para su entrenamiento y evaluación, y su combinación con VSM permitió conseguir el peso objetivo, con pocas iteraciones.</p>
--	---	---	--	--	---	---	---	---	---

<p>[95] Everett , S.E., Dubay, R. (2017)</p>	<p>Optimización parámetros</p>	<p>Redes neuronales artificiales</p>	<p>Se consideró esta técnica por su capacidad de capturar y manipular no linealidades del sistema. Se utilizó el tipo de red Multicapa recursiva (MLR), para aprender y adaptarse a la dinámica térmica no lineal del proceso de moldeo cíclico. Además, se trabajó con un modelo de cascada para aumentar la precisión de predicción (la predicción A es entrada para predicción de B y ambas se utilizan como entrada para predicción de C).</p>	<p>Software LabWindows CVI</p>	<p>Sensores transductores de P sensor normal para $Q_{\text{refrigerante}}$ Termopares Válvula de control de flujo Tarjeta DAQ (PC-6123)</p>	<p>a) Se equipó máquina con sensores para alimentar los modelos inteligentes. Se midieron parámetros considerando ciclos de inyección, para conocer la relación de los parámetros y el producto. (p. ejemplo, se revisó la relación entre T_{cavidad}, el flujo refrigerante, capacidad térmica del polímero, geometría producto, etc.) Se hizo estudio de correlación con coeficientes de Pearson para dar una primera idea de cómo se relacionaban los parámetros. b) Se desarrolló un modelo de dos capas para predecir el perfil de T_{cavidad}. Se utilizó un modelo ANN en cascada y con redes interconectadas para aprender cómo cambiaban los parámetros entre un ciclo y predecir los parámetros que definen la dinámica del proceso y las condiciones para el ciclo futuro. Se le dictaron reglas para que supiera cuál era el objetivo y, de esta forma, redujera las predicciones erróneas. En La capa de perfil, se usó un enfoque State Space Model (SSM), para conocer y modelar la dinámica de la inyección y modelar así el estado de enfriamiento del molde en tiempo real (además de predecir el perfil de temperaturas del molde). Se compararon los datos predichos y el observado en la máquina). c) se entrenó el algoritmo de forma iterativa, en donde se ajustaron los pesos del modelo, hasta que la diferencia entre las salidas del sistema y las predichas fueron mínimas. d) Se ajustó el modelo por medio del estudio de la correlación de parámetros y se validó el modelo para predecir ciclos de producción futura, a partir de información de ciclos anteriores.</p>	<p>T_{iny}, t_{ciclo}, flujo refrigerante y $T_{\text{refrigerante}}$ / La salida del sistema es el perfil de T_{cavidad}.</p>	<p>Se utilizaron datos experimentales reales, colectados de ciclos productivos. Se recopilaron datos con el sistema DAQ, sobre Temperatura de refrigeración y del molde, flujo de refrigerante, cada 0.05s.</p>	<p>Se produjo un sistema de identificación y modelado para optimizar el sistema de enfriamiento del proceso de inyección. Con el modelo se identificó y ajustó en línea los parámetros que se relacionaban con el sistema de enfriamiento del molde (el análisis se realizó entre ciclo y ciclo)</p>
--	------------------------------------	--	--	--	---	--	---	---	---

<p>[96] Li, K., et al. (2016)</p>	<p>Optimización parámetros</p>	<p>Híbrido: Redes neuronales artificiales + algoritmo genético</p>	<p>Se utilizó BP RNA para "mapear" las relaciones no lineales entre los parámetros de diseño y la deformación del producto. Se trabajó con un modelo de cuatro capas y dos capas ocultas, con neuronas 6-10-1. Se utilizó una función de transferencia "logsig" sigmoidal (entre capa de entrada y oculta), y "Purelin" (entre la oculta y de salida). (se agregó back propagation para establecer un modelo relacional entre los parámetros y la calidad del producto). AG se integró en el modelo para optimizar parámetros y conseguir la menor deformación del producto. Se utilizó un tamaño de población de 20, tasa de cruce 0.4, de mutación 0.2 y núm. de generaciones 100.</p>	<p>Moldflow</p>		<p>Se utilizó un DOE "arreglo ortogonal Taguchi" para analizar la influencia de parámetros en el proceso. Se llevaron a cabo 25 pruebas. / Después de encontrar el nivel de influencia de cada factor, se desarrolló el modelo RNA con BP. La delimitación del número neuronas: en la capa de entrada se basó en los parámetros influyentes del proceso; en las capas ocultas se determinó por ensayos; y en la de salida se determinó por el número de funciones objetivo. / Después de elegir los hiperparámetros se entrenó y probó el modelo. El entrenamiento se hizo mediante función "traingd", con datos de entrada y salida. Sobre la base del modelo RNA se implementó AG. Para ello, se determinó una función de aptitud (en donde se eligen el valor de aptitud, tamaño de población, la tasa de mutación y número de iteraciones o generaciones.</p>	<p>Para análisis Taguchi: Contenido de fibra, t_{my}, $T_{fusión}$, T_{molde}, $P_{retención}$, y aspecto de la fibra.</p>	<p>En el diseño de experimentos se realizaron 25 corridas, donde se obtuvieron datos de parámetros del proceso y especificaciones de la fibra de vidrio. / Se crearon 125 conjuntos de datos y se dividieron en 100 para la etapa de entrenamiento y 25 para pruebas del modelo RNA. La función de entrenamiento es "Traingd".</p>	<p>Sistema que permitió encontrar los mejores parámetros para evitar la deformación en productos que contienen fibra para reforzar productos. (se encontró que las especificaciones de la fibra influyen más que los parámetros de inyección). El modelo RNA pudo mapear la relación no lineal entre la deformación de la pieza y los parámetros. El método de análisis de rango se utilizó para estudiar la influencia de los parámetros de diseño en la deformación de la pieza en el molde por inyección</p>
-----------------------------------	--------------------------------	--	---	-----------------	--	--	--	--	--

<p>[97] Lockner, Y., Hopmann, C. (2021)</p>	<p>Optimización parámetros</p>	<p>Redes neuronales artificiales, con Aprendizaje por transferencia</p>	<p>La arquitectura del modelo e hiperparámetros fueron: tres capas, seis neuronas en la capa de entrada, Función de activación de la capa entrada y oculta: Elu; siete neuronas en la capa oculta, una neurona en la capa de salida, función de activación lineal de la capa de salida y 2000 ciclos (épocas) de entrenamiento. El aprendizaje por transferencia se utilizó porque requiere menos esfuerzo de entrenamiento (menos tiempo y datos), además tiene una rápida adaptación.</p>	<p>Autodesk inventor professional 2018 Cadmould 3D-F Python</p>		<p>Se diseñaron los productos con los que se hizo el modelo/ Se simularon los procesos de inyección para los 60 productos diseñados, con el fin de generar datos de entrenamiento, prueba y validación. Para ello, se aplicó un DOE - diseño compuesto central con 77 configuraciones para cada producto (total de 4620 simulaciones), esto también sirvió para identificar el comportamiento del proceso y conocer la influencia de distintos parámetros en la calidad. El modelo de transferencia se hizo definiendo distintas restricciones: todos los datos se generaron variando los mismos parámetros y el parámetro de calidad fue el mismo para todos los productos (peso de la pieza). El modelo de RNA se definió para todos los experimentos, los hiperparámetros se obtuvieron por experimentos realizados con búsquedas aleatorias, hasta la convergencia del modelo. Se usó una detención temprana para evitar sobreajuste durante el entrenamiento, con el fin de no prolongar esta actividad. Se realizó un primer entrenamiento general para determinar parámetros / Para crear un modelo con transferencia inducida se hizo una fase de pretratamiento en donde se transfirió una capa de entrada entrenada, una oculta no entrenada y otra de salida; se transfirió una capa de entrada y oculta, entrenada, y otra de salida sin entrenar; y una transferencia de las capas de entrada, oculta y salida, entrenada. / Se evaluaron los modelos mediante el grado de determinación R².</p>	<p>En DOE se trabajó con: Q_{iny}, T_{fusión}, T_{molde}, P_{mantenimiento}, t_{mantenimiento} y t_{enfriamiento}. El peso de la pieza se consideró para el análisis de calidad Para la transferencia de aprendizaje se consideró: Q_{iny}, T_{fus}, T_{cauidad}, P_{mantenimiento}, t_{mant.}, t_{enfriam}.</p>	<p>Se realizaron experimentos para comparar el aprendizaje transferido y un entrenamiento convencional. .</p>	<p>El sistema probó con éxito la transferencia de aprendizaje para un modelo de ARN, para disminuir las pruebas necesarias para entrenar el modelo. El éxito de la transferencia de aprendizaje fue mayor si hay similitudes entre productos, además redujo los datos necesarios para entrenar nuevos modelos. la transferencia de un modelo y un reentrenamiento superó todos los enfoques.</p>
---	--------------------------------	---	---	---	--	--	---	---	--

<p>[98] Raimee , N. A. et al. (2017)</p>	<p>Optimiza- ción paráme- tros</p>	<p>Híbrido: Algoritmo Genético + RSM</p>	<p>RSM es una técnica estadística para determinar relación entre parámetros y la calidad del producto.</p> <p>AG se usó para optimizar modelo matemático RSM, con población 80, generación 100, factor 5, rango de mutación 0.01, tasa de cruce 0.8, tamaño de cromosoma 83, en código básico de AG.</p>	<p>Moldflow CATIA software AMI NX 7.5 Software Design Expert 7.0 MATLAB 2009</p>		<ol style="list-style-type: none"> 1. Al tratarse de un producto nuevo, se diseñó y exportó la información (esquema, moldes, cavidades, enfriamiento, etc.) a Moldflow para simular el proceso de inyección y así conocer los parámetros involucrados (con restricciones recomendadas por otro software) 2. Se seleccionaron los parámetros que más influyen en el proceso. Por medio de simulaciones se delimitó su rango de operación. 3. DOE: Se realizó un diseño central compuesto con 48 ejecuciones, para identificar la curvatura del proceso y así conocer la relación entre las variables de entrada y salida. 4. Con RSM se definió un modelo de regresión que relacionó los parámetros, con el valor de deformación. 5. El Algoritmo genético se usó para optimizar el modelo RSM y encontrar los parámetros óptimos que minimizarían la deformación del producto. 	<p>Para DOE y RSM se consideró T_{molde}, $T_{fusión}$, $P_{empaques}$, $t_{empaques}$ y t_{efriam}</p>	<p>Se hicieron 48 corridas de experimentos para realizar el DOE</p>	<p>Sistema que permitió encontrar parámetros necesarios para minimizar el defecto de deformidad en producto. Reducción de la deformación en 28%</p>
--	--	--	--	---	--	---	--	---	---

<p>[99] Yin, F., et al. (2011)</p>	<p>Optimización parámetros</p>	<p>Híbrido: Redes neuronales artificiales + Algoritmo genético</p>	<p>Sistema híbrido que buscó aprovechar las características de cada técnica. BP RNA se usó para encontrar la relación entre los parámetros reales y los objetivos de optimización. Estructura de cuatro capas, 5-9-9-2. Con el algoritmo genético se optimizaron los valores que se obtuvieron de la otra técnica. Con tamaño de población=100, 05 en tasa de cruce, tasa de mutación con 0.1 y tamaño de generación 60.</p>	<p>Moldflow</p>	<p>HP personal workstation</p>	<p>Inicialmente se establecieron funciones objetivo. /Se estableció modelo el modelo de IA: 5-9-9-2 BP Neural N, para predecir deformación durante la inyección y la fuerza de sujeción durante inyección. / Se entrenó el modelo con los resultados del simulador / Se evaluó el aprendizaje, para calcular la precisión y nivel de confiabilidad del sistema. / Se ajustó el sistema con algoritmo genético para optimizar los parámetros obtenidos con BP NN.</p>	<p>Factores de diseño: T_{molde}, T_{fundición}, P_{empaquetado}, T_{empaquetado}, T_{enfriamiento}</p>	<p>En moldflow, se simularon 16 muestras por método de experimento ortogonal y 44 de forma aleatoria, para entrenar el modelo híbrido. Para evaluar el modelo se usaron seis grupos de parámetros del proceso no utilizados en el entrenamiento, para conocer la precisión y confiabilidad del sistema.</p>	<p>Sistema de optimización de parámetros durante inyección. Demostró ser capaz de encontrar la relación entre objetivos de optimización y parámetros.</p>
--	--------------------------------	---	---	-----------------	--------------------------------	--	---	---	---

<p>[100] Afzalirad, M., Shafipour, M. (2015)</p>	<p>Planeación de actividades</p>	<p>Algoritmo genético</p>	<p>Dos tipos de AG, uno clásico y uno con procedimiento heurístico. Esta combinación se usó para optimizar valores.</p>	<p>LINGO 9.0 MATLAB</p>	<p>Computadora con Intel Core i5, 2.27 Ghz y 3 GB de RAM</p>	<ol style="list-style-type: none"> 1. Se delimitaron parámetros, índices, variables de decisión y restricciones para modelar problema. 2. Se creó modelo AG simple con los siguientes pasos: Creación de cromosoma para codificar la solución del problema. Definición de la población inicial con tres cromosomas. Selección de los cromosomas con los que se creará la siguiente generación. Diseño de operador de cruce y de operador de mutación. 3. Se diseñó el AG híbrido, para resolver problemas experimentales. El modelo se desarrolló para utilizar un procedimiento heurístico, mediante un sistema de dos niveles. 4. Se usó DOE para investigar el efecto de los factores en el rendimiento de los algoritmos. Para calibrar parámetros se usó metodología RSM 5. Evaluación de los algoritmos, con problemas de prueba aleatorios. 	<p>Índices: trabajos máquinas, periodos de tiempo para la planeación, recursos. / Parámetros: Tiempo de procesamiento en cada máquina, recursos requeridos, disponibilidad de recursos.</p>	<p>Se probaron varios casos, como ocho trabajos, en 3 máquinas y un recurso adicional.</p>	<p>Sistema de programación de máquinas paralelas con recursos limitados en los que las máquinas no estaban relacionadas.</p>
--	----------------------------------	---------------------------	---	-----------------------------	--	---	---	--	--

<p>[72] Bazar-gan-Lari, M.R., et al. (2022)</p>	<p>Planeación de actividades</p>	<p>Algoritmo genético</p>	<p>NSGA-II es un tipo de algoritmo genético de búsqueda de segunda generación, que permite hallar un número de soluciones no dominadas que convergen en un frente óptimo de Pareto. Para resolver problemas de objetivos múltiples relacionados a problemas de planeación.</p> <p>NRGA también es un algoritmo evolutivo de algoritmo genético para clasificación multiobjetivo no dominada, para resolver problemas de optimización no lineales.</p>	<p>MATLAB R2019b</p>	<p>Intel © Core™ i7-4500U CPU, a 1.80 GHz, en una laptop con 8 GB de RAM</p>	<p>El problema se categorizó como una programación de máquinas paralelas. Se formularon restricciones gobernantes y objetivos de problema. Se recopilaron datos. Con los datos se diseñó el modelo y los problemas de prueba. Se utilizaron algoritmos metaheurísticos, en donde se consideró el distanciamiento físico como una función objetivo para el modelo.</p> <p>Para modelar se definió: el estado de las máquinas: inactivo, ocupado (produciendo piezas con trabajadores) u ocupado (produciendo piezas sin trabajadores). También se definieron los objetivos (maximizar beneficio neto, el índice de seguridad de stock y la distancia física entre empleados). Con ello se establecieron tres algoritmos, junto con algunas restricciones. Ya que el problema consta de variables enteras y no enteras se usó el enfoque de programación MILP para incluir dichos algoritmos objetivos y sus restricciones.</p> <p>Debido al número de variables y restricciones totales (20400 y 118460, respectivamente), se utilizó un método Lp-Metrics del enfoque NSGA-II y NRGa (algoritmos evolutivos)</p> <p>La validación se realizó al probar un espacio con cinco máquinas y 14 productos diferentes, con distintas demanda y cantidad necesaria para cada producto; diversas características del molde y un determinado número de empleados.</p> <p>La optimización de los algoritmos se hizo mediante una técnica estadística RSM</p>	<p>Núm. de partes, Núm. Máquinas.</p> <p>Índices: de periodo, de tipo de pieza, de número de máquina.</p> <p>Parámetros: tiempo de configuración, número de cavidades por molde para producir cierta pieza, tiempo ciclo, demanda de la pieza, beneficio neto de la parte, costo unitario de escasez de la pieza, núm. de empleados para producir pieza en cierta máquina; capacidad de inventario (búfer), distancia entre máquinas, si la máquina puede producir cierta pieza; cantidad de producción para la pieza</p>		<p>Modelo para programación de actividades en la línea de producción, considerando distanciamiento físico entre personas.</p> <p>El modelo tuvo como objetivo maximizar el índice de seguridad de las piezas y de la distancia física de entre operadores; y se abordó como un problema de programación de producción diaria.</p>
---	----------------------------------	---------------------------	---	----------------------	--	---	---	--	---

<p>[101] Charest , M., et al. (2018)</p>	<p>Predicción de calidad</p>	<p>Redes neuronales Artificiales Árboles de decisión (AD), K vecinos más cercanos (KNN), Naive Bayes (NB).</p>	<p>A) tres árboles de decisiones: a) ID3: algoritmo de regresión y clasificación. b) Adaboost (adaptive boosting). c) Random Forest. B) NB divide los datos de entrenamiento en tabla de frecuencias y probabilidades. C) KNN. la instancia se clasifica en función de similitud con un número de instancias vecinas. D) RNA. Todos los clasificadores se probaron usando una validación cruzada de cinco pliegues, 10 veces</p>	<p>Python 2.7</p>	<p>Sensores integrados a la máquina de inyección, registran T, P, posición, flujo Tarjetas National Instruments Interfaz gráfica</p>	<p>1) Recopilación de datos. Los datos se dividieron en diccionarios asociados a piezas inyectadas secuenciales. 2) Preprocesamiento y filtrado de datos. A partir del conjunto de datos se creó una nueva lista con parámetros clave. Se normalizaron los datos y se definió la variable objetivo: 1 cuando es un producto bueno y 0 cuando se trata de un tiro corto. 3) Se desarrollaron técnicas ML y se comparó su desempeño. La evaluación se hizo con una validación cruzada de cinco pliegues, 10 veces, para cada producto.</p>	<p>Variable de entrada: T_{max} cavidad, T_{media} refriger., $T_{yP_{barril}}$ (diferentes zonas); posición tornillo al final del ciclo, vel_{iny}, flujo medio del refrigerante. Variables de salida: P_{max} cavidad</p>	<p>Para construir la base de datos, se produjeron piezas con calidad variable de dos productos diferentes, y con variación de los parámetros de inyección El conjunto de datos estuvo compuesto por los parámetros involucrados en la elaboración de 360 piezas A y 100 piezas B, con 26 conjuntos de parámetros de productos anteriores y actuales, y una variable objetivo.</p>	<p>Sistema para predecir la calidad de la siguiente pieza moldeada, en función de los datos del proceso. El sistema, al detectar una pieza errónea, fue capaz de indicar que los parámetros se debían cambiar. Se encontró que el volumen de plástico inyectado es más determinante en la calidad del producto, y que el modelo RNA clasifica la producción con 87% de precisión.</p>
--	------------------------------	--	--	-------------------	--	--	---	--	--

<p>[102] Ke, K.-C., Huang, M.-S. (2020)</p>	<p>Predicción de calidad</p>	<p>Redes neuronales artificiales</p>	<p>Se utilizó modelo MLP, con hiperparámetros: 1 capa oculta. El número de neuronas en la capa oculta se ajustó por múltiplos del número de nodos en la capa de entrada. Número de nodos de entrada se relacionó con el núm. de índices de calidad y el número de sensores instalados en el molde. Función de pérdida: Entropía cruzada categórica. Optimizador: descenso de gradiente estocástico, tasa de aprendizaje=0.1, funciones de activación sigmoidea para la capa oculta y softmax en la capa de salida, tamaño de lote 10, 5000 épocas, tres nodos en capa de salida (una por cada dimensión) y cuatro en la entrada (por cada índice).</p>	<p>Python 3.6.9 Google colab</p>	<p>2 tipos de sensores de presión del molde de Futaba Corporation. Fueron montados detrás del eyector y seis en el molde. CRYSTA-Apex S700, Mitutoyo 1 módulo de adquisición de dato computadora para modelado.</p>	<p>Para obtener los datos del proceso se varió la velocidad de inyección y la P de mantenimiento. En cada disparo se obtuvo una curva de P del sistema y siete curvas de presión de la cavidad, y con ello se determinaron 11 índices de calidad Con el coeficiente de correlación de Pearson se verificó la relación entre los índices de calidad y la calidad (el resultado se delimitó entre -1 y 1, entre mayor sea el valor, más relacionado estaba con el objetivo). A partir de los resultados se determinó cuáles de ellos serían incluidos en el modelo de predicción. Preprocesamiento: Se normalizaron índices de calidad (parámetros) que se consideraron relacionados a la calidad de la pieza (entre 0 y 1) para usarlos como datos de entrada en el modelo inteligente. Para desarrollar la MLP se propusieron los hiperparámetros y se entrenó el modelo. La evaluación de convergencia del entrenamiento del modelo se hizo con una función de precisión</p>	<p>Índices de calidad: índice P de retención de la primera etapa, índice de P máx., índice de caída de P residual, índice integral de P Variable salida: dimensión producto</p>	<p>De los datos obtenidos de los sensores, se obtuvieron diferentes índices de calidad. La curva de P del sistema se utilizó para determinar dos índices de calidad y con las siete curvas de presión se obtuvo el resto índices En total se realizaron 445 experimentos, con 11 índices de calidad (de los cuales se determinaron los que tenían mayor relación con la calidad del producto). De estos datos 356 casos fueron usados para el entrenamiento y 89 para la prueba del modelo.</p>	<p>Modelo inteligente capaz de realizar predicciones sobre la calidad geometría de los productos. Con una tasa de precisión del 92%.</p>
---	------------------------------	--------------------------------------	--	--------------------------------------	--	---	--	--	--

<p>[103] Kim, I., et al. (2023)</p>	<p>Predicción de calidad</p>	<p>Redes neuro- nales + Comple- mento Layer-wise relevance propaga- tion (LRP)</p>	<p>MLP, se usa como red truncal, para recibir datos estructurados. Compuesto por cinco capas ocultas con 10 dimensiones y función de activación ReLu., 5/10/10/10/10/1</p> <p>Velocidad de aprendizaje =0.001 y tamaño de lote=30; con experimentos de 30 épocas para convergencia.</p> <p>LRP es una técnica aplicable a modelos de redes neuronales y ayuda a la comprensión de red profunda (en este caso MLP). Se agrega LRP para la tarea de regresión de la función de entrada, con las restricciones: función de activación ReLU, verdad fundamental $y_i > 0$ y regla z. (con el fin de aproximar el modelo a un modelo de regresión lineal).</p>	<p>Maps 3D- computer- aided engineering (CAE) software (VMTech, Korea)</p>		<p>Se calcularon las características geométricas de los moldes (cavidad y canales) y se determinaron las propiedades del polímero, como viscosidad, calor específico, etc.</p> <p>El sistema se dividió en tres pasos:</p> <ol style="list-style-type: none"> 1) Se extrajeron las características de la simulación del proceso y se realizó un preprocesamiento de datos. Se utilizó método Taguchi para obtener más información sobre la combinación de parámetros del proceso. En el preprocesamiento se aplicó un método de normalización Min-Max a las características de entrada (para mejorar la velocidad de aprendizaje y rendimiento). Los datos normalizados se dividieron en conjunto de datos de entrenamiento, validación y prueba. 2) Se Desarrolló y entrenó la red profunda, con los datos del paso anterior. Los hiperparámetros se buscaron mediante una búsqueda en cuadrícula (así se obtuvo la velocidad de aprendizaje y tamaño de lote). El rendimiento predictivo se evaluó usando el valor promedio, la desviación estándar de RMSE y error relativo. 3) Se analizó el puntaje de relevancia de la función de la entrada del modelo y se implementó LRP-R. Se revisó el puntaje de relevancia de la función y se maximizó el reconocimiento de patrones no lineales, por medio de RFEC: Mediante esto, se estudió qué características eran importantes y cuáles no, para eliminarlas del modelo. 4) Se seleccionó el conjunto de funciones con mejor rendimiento predictivo, basado en los algoritmos RFECV. Después se hizo un reentrenamiento de características. 	<p>El parámetro de entrada para el simulador es llenado, T fusión, T molde, tempaque, P empaque, área de superficie general.</p> <p>Parámetro salida: peso del producto</p>	<p>El conjunto de datos estuvo basado en productos de diferentes formas geométricas, utilizando diferentes resinas. Se colectaron 100 muestras para cada caso (resina y forma), lo que dio a lugar a: 3600 muestras de varias geometrías, para el primer tipo de resina, y 1900 muestras provenientes de una forma extra de molde.</p>	<p>Sistema para predecir calidad, de varias formas geométricas y tipos de resina. El método interpretó la importancia de las características y mejoró la predicción de calidad en el proceso. (el mismo método pudo hacer predicción y selección de características, sin usar modelo de interpretación separado).</p> <p>En el modelo, conforme trabajaba, la media y desviación estándar del error de predicción disminuyeron, lo que demostró su capacidad de aprendizaje, de predicción y estabilidad de inferencia</p> <p>El funcionamiento del modelo reveló una disminución en el costo computacional y aceleración del proceso de selección de características.</p>
---	----------------------------------	--	---	--	--	---	---	--	--

<p>[104] Polenta, A., et al. (2022)</p>	<p>Predicción de calidad</p>	<p>Árbol de decisiones (AD) KNN Random Forest (RF) gradient-boosted trees (GBT), Support vector machine (SVM), Redes neuronales artificiales (RNA)</p>	<p>Se compararon seis técnicas de ML. KNN conformada por $K = 4$ con una distancia "Manhattan". AD con un criterio de precisión de desdoblamiento, sin pre-poda, con un criterio de división tipo precisión. RF, se usaron árboles "extra", con ganancia mínima=0.01, tamaño mínimo de hoja =2, 151 árboles, profundidad máx.=79 GBT: contracción (taza de aprendizaje = 0.01, 300 árboles y profundidad máxima=41. SVM: con Kernel RBF, $\gamma=0.0010$, y $C=100$. RNA - MLP: función sigmoide de activación para cada neurona, entradas normalizadas entre -1 y 1, tasa de aprendizaje=0.1, impulso=0.6 y 500 épocas.</p>	<p>RapidMiner Studio 9.10 "TIG" Manufacturing Execution System (MES)</p>	<p>Sensores integrados en la máquina de inyección Notebook con Windows 10</p>	<p>Se construyó una base de datos con los parámetros de producción, en ella se clasificaron los datos de acuerdo con cuatro tipos de calidad, definidos en el proceso, al tomar en cuenta una característica cuantificable de la pieza (Uniformidad general) Se evaluó la relevancia de cada parámetro con un análisis de confianza y método ANOVA, con el fin de delimitar los parámetros con los que se alimentarían las técnicas ML Se establecieron seis técnicas ML para construir modelo y se comparó su precisión en la predicción de calidad. Para conocer los hiperparámetros que permitían la mejor precisión de clasificación, se utilizó una estrategia exhaustiva de búsqueda en cuadrícula. La evaluación experimental de los modelos se hizo al dividir aleatoriamente en cinco pliegues con el mismo número de muestras. Las pruebas de precisión se repitieron cinco veces, seleccionando un pliegue diferente en cada iteración como conjunto de prueba y los otros pliegues se usaron como conjunto de entrenamiento. Se comparó la precisión media de las pruebas en los cinco pliegues de todos los clasificadores, para ello se calculó: precisión, recall y puntuación F1, y se construyó una matriz de confusión para saber la relación entre falsos positivos, falsos negativos, etc. También se utilizó una prueba Friedman para revisar si había diferencia estadística entre los resultados de los modelos ML.</p>	<p>Se contemplaron 13 parámetros de entrada: $T_{fundición}$, T_{moldeo}, $T_{llenado}$, $T_{plastificación}$, T_{ciclo}, Fuerza de cierre, fuerza de sujeción, valor de torque máximo y promedio, $P_{contrapresión\ máx.}$, $P_{iny\ máx.}$, posición tornillo al final expulsión producto, Vol. inyección.</p>	<p>La base de datos contó con 1451 ciclos de producción divididos en cuatro clases de calidad: desperdicio (370), aceptable (406), óptima (310) e ineficiente (360).</p>	<p>Se probaron técnicas ML para predecir calidad, basados en los parámetros de inyección, usando datos reales. La predicción se hizo para cuatro tipos de clases de calidad (a diferencia de la forma tradicional de dos clases). La técnica Random forest y GBT presentaron los mejores resultados para clasificar y predecir calidad.</p>
---	------------------------------	--	--	--	---	--	--	--	--

<p>[105] Román , A. J., et al. (2021)</p>	<p>Predicción de calidad</p>	<p>Redes neuronales artificiales</p>	<p>La estructura RNA con BP incluyó: cinco neuronas en la capa de entrada, dos capas ocultas, nodos ocultos (32-256), y una capa de salida con una neurona; sin método de normalización. Para inicializar los pesos del modelo se utilizó el inicializador uniforme Glorot (de la biblioteca keras) al extraer muestras de una distribución uniforme aleatoria dentro de un límite.</p>	<p>MATLAB Proteus Tensorflow</p>	<p>DSC 214 Polyma, de Netzsch Reómetro AR 2000EX de TA</p>	<p>RNA - Se caracterizaron los materiales que fueron modelados y se realizaron pruebas de calorimetría y de relajación, para garantizar que se cumplan las condiciones de procesamiento. Se realizó un análisis dimensional "Buckingham Pi" para determinar qué propiedades podían provocar la aparición de defectos superficiales, y reducir las variables de entrada del modelo.</p> <p>Los métodos SVM y LR (regresión logística) se utilizaron para cuantificar la relación entre los parámetros y el defecto estudiado (esos pesos ayudaron a determinar la estructura de RNA, al incluir los nodos con mayor peso).</p> <p>Una vez que los nodos de entrada fueron seleccionados, se creó una arquitectura RNA preliminar, a la que se entrenó, validó y evaluó con valores reales.</p> <p>La optimización Bayesiana se usó para determinar la mejor estructura RNA y prevenir iteraciones aleatorias (el modelo propone nuevos hiperparámetros, basado en el rendimiento del sistema).</p> <p>Para probar el rendimiento de la arquitectura el modelo se entrenó nuevamente con todas las muestras de entrenamiento y validación. Los datos de prueba reservados se usaron para calcular la precisión de predicción.</p>	<p>Variables de entrada: contenido de elastómero, de comonomero y de agente de procesamiento, viscosidad, vel iny, tamaño de placas, índice de fluidez, tiempo relajación, T_{tolva}, T_{baril} en zona 1, 2-4, $P_{mantenimiento}$, $P_{contrapresión}$, $t_{enfriamiento}$, rotación de tornillo.</p>	<p>Se utilizaron 257 conjuntos de datos para los procesos de entrenamiento, validación y prueba. 213 datos se destinaron al entrenamiento y validación y 24 en pruebas.</p> <p>El conjunto de entrenamiento y validación se usaron para el ajuste de hiperparámetros.</p>	<p>El sistema permitió la predicción de defectos en el proceso de inyección, considerando los parámetros de producción y propiedades viscoelásticas (además de método de optimización de la técnica ML).</p>
---	------------------------------	--------------------------------------	---	--	---	---	--	---	--

<p>[106] Tercan, H., et al. (2022)</p>	<p>Predicción de calidad</p>	<p>Redes neuronales artificiales en Deep Learning</p>	<p>Se utilizó un enfoque MAS y un tipo neurona: perceptrón multicapa (MLP), de dos capas, 20 neuronas por capa y función de activación ReLU (6/20/20/1)</p> <p>El entrenamiento se realizó mediante optimizador Adam, con lote de 16 unidades y tasa de aprendizaje 0.001, y 50 épocas</p> <p>DL se contempló para fomentar aprendizaje continuo y sin olvido de casos anteriores</p>	<p>Cadmould 3D-F Pytorch</p>	<p>Sensores de P y T</p>	<p>Se definieron los objetos en los que estaría enfocado el método: 16 "bloques" de plástico de diferentes tamaños. / Se simuló proceso para producir cada pieza, variando parámetros mediante un DOE diseño compuesto central de 77 ejemplos, en donde se revisaron los variables del proceso y la calidad que producen.</p> <p>Se definieron hiperparámetros y se entrenó la RNA para predecir la calidad de una pieza, relacionada con seis parámetros de la máquina y el nivel de deformación del producto. Con ello se obtuvo el mejor modelo y lo hiperparámetros con mejor rendimiento.</p> <p>Se implementó un método de entrenamiento MAS de red neuronal (sinapsis con reconocimiento de la memoria) con el fin de entrenar la red neuronal a través de tareas secuenciales, aprovechando el conocimiento adquirido, en donde se transfiere el aprendizaje similar de una neurona y se afina con datos de la nueva tarea.</p> <p>Se evaluó el rendimiento del modelo definido con el error cuadrado medio.</p>	<p>Entrada del modelo: P_{mantenimiento}, t_{mantenimiento}, T_{molde}, t_{enfriamiento}, T_{fusión}, Q_{material}</p> <p>Variable de salida: Calidad del producto (visto según el nivel de deformación del producto)</p>	<p>El entrenamiento se hizo con un tamaño de conjunto de validación del 20% del conjunto de entrenamiento (60 experimentos).</p> <p>Se entrenó primero con una tarea (producción de un producto) y se incrementó de forma consecutiva el entrenamiento de los otros 15 productos (se utilizó el último modelo entrenado para procesar un nuevo problema)</p>	<p>Método de aprendizaje continuo capaz de predecir la calidad del producto.</p> <p>La memoria del modelo se incrementó al usar transferencia de pesos de red, previamente entrenados para el análisis de nuevas tareas. Se usó para aprender nuevos productos, con el uso de redes ya entrenadas y entrenar pesos no usados, sin olvidar los casos iniciales.</p> <p>Se obtuvo un error MSE = 0.037 para el mejor desempeño del modelo.</p>
--	------------------------------	---	---	----------------------------------	--------------------------	--	---	--	--

<p>[107] Chen, J.C., et al. (2020)</p>	<p>Predicción de calidad</p>	<p>Redes neuronales artificiales</p>	<p>Se utilizó un RNA con back-propagation, función de activación sigmoidea y tasa de aprendizaje 0.01. Su estructura estuvo compuesta por dos capas y red 5-3-3-1.</p>		<p>Sensores RJG eDART</p>	<p>Se realizó un DOE, experimentos factoriales completos de tres factores y tres niveles, para revisar muestras en diferentes condiciones de moldeo. También se validó el efecto que tienen los parámetros en el proceso (mediante análisis ANOVA) para seleccionar los que tienen más relevancia</p> <p>Se extrajeron datos de los sensores disponibles y se definieron las variables de entrada, con procedimientos de análisis de regresión estadística (selección directa y por pasos y eliminación hacia atrás), con ello se determinó modelo MLR y ARN.</p> <p>En la ARN se revisaron diferentes combinaciones de hiperparámetros y se utilizó escala min-max y normalización de puntuación Z para normalizar datos antes de entrenar al modelo (se realizaron 48 experimentos de modelado. Se evaluaron los modelos con validación cruzada (CV), coeficiente R2 y la métrica de precisión y comparan. Para realizar CV se usó el caso LOOCV del procedimiento k-Fold, con pliegues 3, 6 y 9. Se hizo una prueba de exactitud de predicción para saber si se tenían falsos positivos o falsos negativos.</p>	<p>Para DOE: T_{cilindro}, contrapresión y P_{retención}</p> <p>Parámetros para creación de MLR y RNA: T_{promedio molde}, Temperatura promedio del agua de la bayoneta, Presión de mantenimiento promedio, área bajo la curva de P de iny, área bajo la curva de P de sensor de cavidad.</p>	<p>El diámetro del disco inyectado se midió después de enfriarse por 24 h. Se recopilaron 54 conjuntos de datos en las condiciones de la máquina para el entrenamiento y otros 54 para la evaluación del modelo (a diferentes condiciones de iny).</p>	<p>Se trató de un sistema para predecir calidad en tiempo real, por medio de un modelo basado en RNA. A partir de valores y rangos de operación de los parámetros, se entrenó el modelo para identificar los productos defectuosos.</p>
--	------------------------------	--------------------------------------	--	--	---------------------------	--	---	--	---

<p>[108] Chen, W.-C., (2008)</p>	<p>Predicción de calidad</p>	<p>Redes neuronales artificiales</p>	<p>El sistema se basó en un modelo mapa autoorganizado (SOM) y una red neuronal BP-RNA</p> <p>SOM se basó en aprendizaje competitivo no supervisado (el cual modifica iterativamente los pesos sinápticos).</p> <p>RNA La entrada del modelo estaba compuesta por nueve neuronas, tres de ellas estaban compuestas por algoritmos SOM y el resto por parámetros directos. La estructura del modelo fue: 9-8-1, con 30000 generaciones, tasa de aprendizaje 0.7, 25000 épocas e impulso =0.8. Se usó método de descenso más pronunciado (steepest-descent) para encontrar cambios de peso y minimizar función de energía de error (RMSE). También se usó función de activación sigmoidea hiperbólica.</p>			<p>Antes de aplicarse SOM + BR-RN se implementó una función de normalización (que modificó los valores de entrada y salida en rango de 0.1 y 0.9), después se aplicó un método de descenso más pronunciado, para encontrar los pesos entre un nodo y otro, y minimizar la función de error.</p> <p>El núm. de neuronas en capa oculta se obtuvo con el método de Khaw y Haykin. La tasa de aprendizaje y el núm. de generación y el impulso se determinaron al encontrar el rango de convergencia de los factores, y al hallar el valor de la misma distancia en cinco niveles. Se realizaron cinco réplicas para determinar el peso predicho por el modelo. Se usó un método de diseño de parámetros Taguchi para mejorar el rendimiento de la red neuronal. / Para conocer el desempeño del modelo se calculó el RMSE.</p>	<p>Parámetros de entrada: curva de posición del tornillo entre una iny. y otra, curva de velocidad de inyección y curva de presión; los otros seis son: $t_{iny.}$, posición interruptor VP, $P_{empaquet.$, $vel_{inyección}$, $t_{empaquet.}$, carrera inyección.</p> <p>Variable de salida: peso del producto</p> <p>En el método Taguchi se utilizaron como factores de control: número de neuronas ocultas, tasa de aprendizaje, impulso y número de épocas.</p>	<p>Los datos de entrenamiento y prueba consistieron en 120 y 40 muestras, respectivamente. La generación de datos se realizó mediante curvas donde el eje horizontal se refería al tiempo y la vertical a la posición del tornillo, vel de iny y presión.</p> <p>Se consideraron tres parámetros de extracción dinámica basados en mapas de autoorganización, con seis parámetros de fabricación para entrenar y probar el BP-RN.</p>	<p>Se trató de un modelo predictor de calidad dinámico, compuesto por un mapa autoorganizado y un modelo de red neuronal de retropropagación.</p> <p>El sistema era capaz de predecir el peso del producto, a partir de 6 parámetros con un error RMSE igual a 0.0017.</p>
--	------------------------------	--------------------------------------	--	--	--	--	---	---	--

<p>[109] Demirel, K. C., (2020)</p>	<p>Predicción de calidad</p>	<p>Random forest</p>	<p>Se utilizó Random forest (RF) regressor como el método de aprendizaje para el ERC.</p> <p>RF mejora la precisión predictiva y evita el ajuste excesivo / El enfoque Ensemble of regressor chains (ERC) es una extensión de Regressor chain (RC) (se basa en encadenar regresores de un solo objetivo secuencialmente en orden aleatorio) /</p>	<p>Python 3.7</p> <p>Open platform communications/Grafana</p>	<p>PLC</p>	<p>Se colectaron datos y se normalizaron las variables objetivo (tres métricas de calidad del producto).</p> <p>Se detectaron los valores atípicos del proceso (ruido proveniente por diversas fuentes), antes de procesarlos en el modelo de predicción. Para ello, los datos fueron separados en grupos mediante un Factor de valores atípicos locales (LOF) para separar modelos con características normales de los inusuales.</p> <p>Se seleccionaron las características para los segmentos de datos, mediante el método Random Forest regressor, primero para los datos normales y después con los inusuales. Se inició con la construcción de gráficas de importancia de características para cada variable objetivo, y mediante el uso del coeficiente de correlación de Pearson, para encontrar las variables que estaban altamente correlacionadas y promediarlas, con el fin de reducir el conjunto de datos.</p> <p>Con los datos reducidos se realizó un análisis numeración, donde se crearon modelos de regresión de objetivo único para cada métrica de los datos normales (que permitan predecir la calidad de las piezas). Después se seleccionó el modelo con mejor rendimiento y se comparó con el modelo ERC. En la comparación se utilizó MAPE como una métrica de rendimiento y se realiza un análisis estadístico de t pareada y ANOVA. Finalmente se realizó una comparación entre el modelo de regresión de objetivo único y el ERC con los datos inusuales.</p>	<p>Variables de entrada fueron 46 parámetros: Presión de iny y boquilla, señal de calentamiento de resistencia, vibración del motor de sujeción, T_{tolva}, etc.).</p> <p>Las variables de salida fueron métricas de calidad: linealidad, planitud y densidad</p>	<p>La base de datos estuvo formada, inicialmente, por 428 filas de cada muestra, cada muestra tenía 46 valores (de diversos parámetros del proceso y características de salida del producto). Con el factor de detección de anomalías se obtuvo una base de datos de 399 casos normales, de los cuales 287 fueron usados para entrenamiento y 72 para pruebas.</p>	<p>Es un sistema de soporte de decisiones, que utilizaba parámetros de proceso para predecir calidad del producto.</p> <p>El sistema era capaz de respaldar decisiones en línea, a través de pantallas de monitoreo de procesos en vivo. Informaba la calidad del producto, problemas sobre la calidad y cambios en la línea de producción. Además, brindaba recomendaciones de parámetros de producción ideales. //</p>
---	------------------------------	----------------------	---	---	------------	---	---	--	--

<p>[110] Kim, S., et al. (2018)</p>	<p>Predicción de calidad</p>	<p>Redes neurona- les artifi- ciales</p>	<p>Se utilizó el tipo de RNA "recurrent neural network", por medio de unidades LSTM (long short-term memory o memoria de corto plazo con larga duración).</p> <p>La capa oculta del modelo estaba compuesta por unidades LSTM conectadas entre sí. (el número de unidades en la capa oculta se determinaron empíricamente para cada modelo).</p> <p>Las salidas de las capas ocultas estaban conectadas con la capa de salida mediante una función sigmoide (como función de activación). La capa final representaba la probabilidad de clase predicha.</p> <p>Se manejó como función de pérdida la entropía cruzada ponderada.</p>		<p>Sensores ya localizados en la máquina de inyección</p>	<p>El análisis se hizo utilizando los datos provenientes de los sensores integrados a las máquinas de inyección, contemplando tres parámetros de inyección.</p> <p>Se construyeron tres modelos individuales de predicción, uno por cada parámetro anterior, mediante "recurrent neural network" con asignación de pesos más altos a los datos que presentan defectos. La salida del modelo se definió como 1 si el valor coincidía con el valor objetivo y 0 si no, con el fin de que el modelo pudiera mandar una señal, cada que cualquier modelo predijera algún defecto.</p> <p>En el entrenamiento, cada modelo recibió como entrada los valores de secuencia de 10 disparos anteriores, incluyendo la inyección actual. Esto permitió predecir los valores para los siguientes tres disparos.</p> <p>La optimización se hizo al probar distintos pesos y unidades LSTM para la capa oculta, en cada modelo de predicción. Se encontró que para el modelo referido a la duración de carga y de llenado se tienen dos unidades LSTM y ocho para el modelo de velocidad de cambio.</p>	<p>Duración de carga, duración de llenado y cambio de velocidad.</p>	<p>Los datos manejados fueron obtenidos de un periodo de 4000 inyecciones consecutivas (cada dato fue identificado y clasificado según el número de disparo).</p> <p>La clasificación de los datos se dividió en: normal, defecto por duración de carga, defecto por duración de llenado y defecto por velocidad de cambio.</p> <p>Cada modelo se entrenó como clasificador binario, mediante un esquema uno contra el resto.</p>	<p>Sistema de detección de defectos en productos mediante control de datos del proceso.</p> <p>El modelo podía trabajar con un promedio alto de eventos pasados y su objetivo era predecir defectos con los datos del proceso, pocas inyecciones antes de su fabricación (por lo menos tres inyecciones futuras).</p> <p>La razón de usar tres clasificadores con el mismo entrenamiento fue que cualquiera de ellos pudiera emitir una alarma cuando predijera un defecto.</p>
---	----------------------------------	--	---	--	---	--	--	---	---

<p>[111] Maarif, M.R., et al. (2022)</p>	<p>Predicción de calidad</p>	<p>Redes neuronales artificiales</p>	<p>Las RNA trabajaron mediante MLP y diferentes funciones de activación.</p> <p>El modelo con menor tasa de error estaba compuesto por nueve neuronas de entrada (por cada parámetro), dos de salida (dos perceptrones con valor de 1 y 0 según si se trataba de inyección corta o no), tasa de aprendizaje = 0.1, tasa de olvido = 0.003 y nueve neuronas ocultas.</p> <p>Se implementó el algoritmo de entrenamiento SLF (aprendizaje estructural con olvido), el cual ayudó a revelar las neuronas y conexiones importantes, a diferencia de backpropagation.</p>		<p>Sensores kistler</p>	<p>Se recopilaron datos de la máquina de iny (la unidad ya contaba con una función para transmitir información). Se etiquetaron las características de los productos de forma manual, para cada experimento.</p> <p>Debido a que se manejaban parámetros con distintas magnitudes, se implementó una función de normalización para estandarizar los valores (enfoque de normalización Min-Max) y escalar los datos en rangos de 0 y 1.</p> <p>El modelo de IA fue un MLP. La función de activación se delimitó mediante un proceso de prueba y error. Para conocer el error de la RNA se utilizó la función MSE.</p> <p>El entrenamiento se realizó mediante un enfoque de aprendizaje estructural con olvido (SLF) para calcular, de manera iterativa, los pesos de cada conexión neuronal y así mantener los más representativos</p> <p>La evaluación del modelo se hizo mediante una matriz de confusión, y las métricas: precisión, recall o sensibilidad, especificidad, exactitud y puntaje F1</p> <p>Se creó una función para predecir la calidad, mediante dos reglas de selección, con los cinco atributos que se encontraron más determinantes del proceso. Se evaluaron las funciones de predicción mediante una matriz de confusión.</p>	<p>El modelo RNA 9 parámetros de entrada: $T_{maxmolde}$, t_{ciclo}, P_{max} y min (en la cav.), t para alcanzar presión máx. y min, Presión integral máx y min, P_{total};</p> <p>2 atributos de salida: tipo de inyección (si es corta o no)- lo que representaba la calidad del producto.</p>	<p>Los experimentos para obtener datos se llevaron a cabo en tres configuraciones diferentes de velocidad de inyección, punto de soporte de presión y temperatura de refrigerante.</p> <p>Se hicieron 30 variaciones a los parámetros, lo que derivó en 270 experimentos con diferentes configuraciones de parámetros. De esa información el 66.67% se utilizó para entrenamiento y el resto para evaluar el método.</p>	<p>El modelo RNA + SLF ayudó a determinar los parámetros de proceso influyentes y a tener un entrenamiento más enfocado.</p> <p>Con el uso de SLF para entrenar el modelo, se generó un modelo más simple, a la vez que ayudó a reconocer los parámetros que más influían, sin disminuir el rendimiento de predicción de calidad.</p>
--	------------------------------	--------------------------------------	--	--	-------------------------	--	--	--	---

<p>[112] Nagorny, P., et al. (2017)</p>	<p>Predicción de calidad</p>	<p>Redes neuronales artificiales. Vs Algoritmos de regresión</p>	<p>Algunos algoritmos seleccionados, con sus hiperparámetros, son: -bosque aleatorio con 100 árboles; -KNN, vecinos=2, - algoritmo KDtree, métrica Minkowski con distancia L1; -árbol de decisión, profundidad máx=1, MSE para medir calidad dividida, dos muestras para dividir;</p> <p>La RNC con mejor arquitectura fue C (32, 5, 1)-P-C(64, 5, 1)-P-D-N-FC(3136)-FC(1024), donde C(d, f, s) indicaba una capa convolucional, con d filtros de tamaño fxf, aplicados a la entrada con paso s; D era la capa de abandono, N la capa ReLu no lineal, FC capa altamente conectada con n nodos.</p> <p>También se utilizó una Red neuronal recurrente con Long-Short Term Memory (LSTM) para entrenar un modelo predictivo. Se trabajó con red de una capa con 30 células. En el entrenamiento se usó optimizador Adam y pérdida de error de puntuación media; tasa de aprendizaje 0.001, con 100 mil iteraciones.</p>	<p>Python</p>	<p>Sensores P y T en el molde, y de Piny y posición de tornillo en la máquina de inyección</p> <p>Cámara térmica en línea</p>	<p>Obtención de muestras y recopilación de datos. / Se extrajeron descriptores estadísticos, mediante función CTW (Continuous Wavelets Transform) en datos sin procesar. Para cada imagen se calcularon los parámetros de Haralick. Se seleccionaron los descriptores que influían de mayor forma el proceso y se desarrolló una matriz de correlación de los descriptores elegidos.</p> <p>Se crearon los modelos predictores con algoritmos de regresión y RNA (RNC). Para RNA las imágenes se redujeron a 28x28 píxeles y, como tenían un valor de un píxel, ya se consideraron en escala de grises. Se probaron diversos modelos RNC, con capas altamente conectadas. Los hiperparámetros se optimizaron con CrossValidation. Los pesos se inicializaron usando valores aleatorios normales con parada temprana, para evitar sobreajuste. Se entrenaron los modelos y se evaluó su desempeño con métrica de error cuadrático medio (MSE) y R2, usando descriptores de señales extraídas, descriptores de imágenes termográficas y ambas. /</p>	<p>Se contemplaron variables del proceso e imágenes termográficas</p> <p>Variable salida: dimensión (ancho) de la pieza</p>	<p>Se produjeron 204 cajas con diferentes ajustes de máquina (se eligieron ajustes para maximizar la variación de la capacidad del proceso).</p> <p>El conjunto de datos se dividió en 177 imágenes para el entrenamiento y 27 para la prueba. Las imágenes sin procesar de 156x156 píxeles se redujeron a 28x28, para facilitar la convergencia del modelo.</p> <p>De las imágenes termográficas se extrajeron 26 descriptores de 204 imágenes de piezas inyectadas. De las condiciones del proceso se extrajeron 71 descriptores estadísticos de las señales y picos de CWT.</p>	<p>Se compararon modelos de predicción de calidad (algoritmos de regresión en descriptores extraídos y redes neuronales en imágenes y señales sin procesar).</p> <p>En el análisis de los algoritmos de regresión se obtuvo que las imágenes termográficas contenían más información para la predicción geométrica que las señales de los sensores en el molde. (el uso de señales e imágenes da malos resultados)</p> <p>Aunque los filtros reaccionaron a patrones reales, la generalización no se logró debido al conjunto de datos pequeño para el entrenamiento. Los autores recomiendan aumentar datos y tener una arquitectura más profunda para aumentar generalización).</p> <p>El uso LSTM tuvo mejor rendimiento para datos sin preprocesamiento (no se probó con imágenes). Redes convolucionales mostraron mejor desempeño al trabajar con imágenes.</p>
---	------------------------------	--	---	---------------	---	--	---	--	---

<p>[113] Ogorodnyk, O., et al. (2019)</p>	<p>Predicción de calidad</p>	<p>Redes neuronales artificiales Vs. Árbol de decisiones</p>	<p>MLP utilizó una función de activación sigmoidea. Su estructura estuvo compuesta por tres capas, con 10 neuronas en capa oculta, para el modelo que considera 18 parámetros.</p> <p>El tipo de AD que se usó es J48. Esta técnica incluyó características como manejo de valores faltantes y función de decisión de poda de árboles. Los árboles del método incluyeron seis nodos en su estructura (referente a seis parámetros).</p> <p>Decidieron comparar con ARN por su facilidad de interpretación. Ambas técnicas solo se diseñaron para distinguir entre piezas buenas o malas (no categorizan el tipo de defecto).</p>	<p>ModeFrontier WEKA</p>		<p>1) Recopilación de datos. Se aplicó un método de hipercubo latino como DoE, para obtener datos con alta y baja calidad. El experimento incluyó 32 combinaciones diferentes de parámetros de inyección. Cada combinación se realizó cinco veces en la máquina de inyección y se obtuvieron 160 conjuntos de datos.</p> <p>2) Para construir los modelos a) se hizo un preprocesamiento de datos, donde se corrigieron y evitaban datos incompletos, faltantes o redundantes. b) se seleccionaron las características y variables más significativas, con InformationGain (la cual evaluó e identificó los parámetros que ofrecían más información del proceso): se redujo el número de parámetros a 18.</p> <p>3) Construcción de modelos de predicción: MLP y J48.</p> <p>4) Entrenamiento y evaluación de los modelos. Para verificar la calidad de se cada modelo se utilizó una validación cruzada de 10 pliegues. En la evaluación se utilizó la métrica de precisión y el área bajo la curva ROC (Receiver operating characteristic o característica operativa del receptor).</p>	<p>Para DOE: P_{mantenimiento}, tiempo presión de manten., contrapresión, t_{enfriamiento}, vel._{iny.}, vel._{tornillo}, T_{cilindro}, T_{molde}.</p> <p>Los parámetros para modelo final: t_{máquina}, contador de inyecciones, contador piezas buenas y defectuosas, cushion después P_{mantenimiento}, vel máx tornillo, T cilindro en zona media, núm plastificación, tiempo cambio, T del grupo de calefacción de la zona uno del cilindro, t inyección, tplastificación máx.</p>	<p>Se registraron 41 parámetros de máquinas y procesos, de 160 ejecuciones de las máquinas. El conjunto de datos contenía 101 muestras de piezas defectuosas y 59 buenas En el segundo entrenamiento se eliminaron seis variables y después, con InfoGain, se redujeron todos excepto 18 parámetros.</p>	<p>Se trató de un sistema de predicción de calidad, el cual podía distinguir entre calidad alta y baja a partir de los procesos de la máquina de inyección.</p> <p>El sistema era capaz de notificar al operador de la máquina cuando es necesario hacer un ajuste por la presencia de piezas defectuosas.</p>
---	------------------------------	--	--	-----------------------------------	--	---	---	--	--

<p>[50] Ribeiro , B. (2005)</p>	<p>Predicción de calidad</p>	<p>Support vector machine: C-SVM y v-SVM / RBFNN</p>	<p>VSM, C-SVM - se basa en una clasificación binaria y se usa con métodos multiclase. v-SVM - disminuye la dificultad en seleccionar el menor error. Ambos modelos utilizaron enfoques "uno contra todos", seis clasificadores, función kernel RBF</p> <p>RBFNN se contempló con seis entradas (proveniente de seis parámetros de inyección), seis salidas (defectos delimitados) y 80 capas ocultas.</p>		<p>pc pentium 3 mobile, 1.0 GHz, con windows</p>	<p>Se registraron y almacenaron datos con 26 parámetros de configuración para cada inyección. Con fines de modelado se identificaron seis variables como determinantes del proceso y se delimitaron su rango de operación y sus medidas de tendencias.</p> <p>Para desarrollar las técnicas SVM se eligieron los parámetros de penalización C (que determinaba el nivel de intercambio entre la complejidad de la función de decisión y el número de ejemplos mal clasificados), la función de mapeo y la función Kernel (se buscó una función Kernel que permitiera la incrustación de los patrones de entradas en vectores de características).</p> <p>En C-SVM se obtuvieron los valores mediante ensayos de prueba y error, con una evaluación de la precisión del rendimiento; y una selección de modelo de búsqueda de cuadrícula interactiva.</p> <p>Con el fin de desarrollar clasificadores multiclase, se decidió combinar varios clasificadores.</p>	<p>t_{ciclo}, $t_{inyección}$, $t_{medición}$, T_{barril} (antes de boquilla), cushion y vel_{iny}.</p> <p>6 parámetros de salida: rayas, manchas, marcas de quemadura, rebabas, piezas sin rellenar, deformaciones.</p>	<p>El entrenamiento se realizó con un conjunto de datos de 120 ciclos (con pares de datos de parámetros y tipo de calidad resultante). El conjunto de prueba se constituyó por 80 ciclos de inyección</p>	<p>Se produjo un modelo para monitorear datos durante el proceso y así predecir la calidad del producto, con el fin de tener la capacidad de responder rápidamente ante algún cambio que afecte al producto.</p> <p>Se trató de un sistema de diagnóstico de calidad, y detección y alerta de errores, a partir de los datos obtenidos del monitoreo del proceso.</p> <p>El modelo se pudo conseguir con grupos pequeños de datos.</p>
---	------------------------------	--	---	--	--	---	---	---	--

<p>[114] Uğuroğlu, E. (2021)</p>	<p>Predicción de calidad</p>	<p>Random Forest Regresión logística KNN RNA</p>		<p>EUROMAP 64/ Kafka y Spark Hadoop cluster Elastic-search database notebook jupyter</p>		<p>Se recopilaron datos de producción con PMMA, en ella se registraron los tipos de defectos que fueron percibidos en el proceso. (se normalizó dicho registro para decir que tiene o no un defecto, con 1 y 0 respectivamente). Se realizó un estudio de correlación (con método de submuestreo) para delimitar las variables con mayor influencia (positiva o negativa) en la calidad del producto.</p> <p>Se desarrollaron varios métodos IA y se entrenó con datos balanceados 50% OK y 50%NOK. La Evaluación y comparación de desempeño se realizó mediante estudios de precisión, matriz de confusión, exactitud y curva ROC. En la prueba de evaluación se contempló la "eliminación" de los falsos negativos como inconveniente del modelo, ya que garantiza que el modelo separa defectos (aunque algunos sean OK).</p> <p>Se utilizó Spark streaming con el fin de hacer el análisis y transmisión en tiempo real, en Elasticsearch se almacenó: Jupyter N y el modelo que presentó el mejor desempeño de análisis (transformado mediante la librería "spark machine learning library"). / Se utilizó una plataforma para visualizar los análisis. Los resultados del análisis fueron dirigidos a robots cartesianos que dirigen los productos OK y NOK a delimitados espacios.</p>	<p>Variables determinantes: T_{transferencia} (relación positiva); T_{molde} (correlación negativa)</p>	<p>Se capturaron 14106 datos de ciclos diferentes (obtenido durante cuatro meses). De ellos, los datos para entrenamiento fueron 10484, prueba: 2622 y validación: 1000</p>	<p>Se desarrolló un sistema para monitorear y clasificar, en tiempo real, los productos, según su calidad (ok o nok). Mediante spark transmission se transmitieron los datos recopilados durante el proceso, y se analizaron mediante jupyter N y con el modelo IA dentro de Elasticsearch (base de datos). El sistema podía separar los objetos defectuosos, para su consideración y se recomendó la intervención de un operador para verificar si se tuvo una clasificación errónea de Falso positivo (es decir, si el producto era OK y se catalogó como NOK).</p>
--	------------------------------	--	--	--	--	---	---	---	---

<p>[115] Silva, B., et al. (2021)</p>	<p>Predicción de calidad (y clasificación)</p>	<p>Híbrido: Redes neuronales artificiales + Support vector machine</p>	<p>RNA compuesto por funciones de activación: logistic, la configuración estaba compuesta por 1 capa oculta, 200 neuronas y la función de activación logística con solver lbfgs.</p> <p>SVM: valor de función de costo = 1000, valor gamma de 0.01 y un kernel lineal</p> <p>Se utilizó la Variable latente de proceso gaussiano como técnica Deep L. /</p>	<p>Python</p>		<p>Se recopilaron datos de ciclos de inyección (39827 datos) y etiquetaron productos cuando presentaban dos tipos de defectos (rebaba e incompletos).</p> <p>Se programaron los clasificadores: a) ARN. Se hicieron pruebas variando número de neuronas en capas ocultas, número capas ocultas, solvers y funciones de activación. b) SVM se hizo una cuadrícula de búsqueda para definir los parámetros más adecuados.</p> <p>Se agregó una un método de ventana móvil, para alimentar los vectores con información de ciclos anteriores y posteriores (el mejor desempeño se observó con tres casos previos y tres casos siguientes).</p> <p>Para mejorar la clasificación de casos se diseñó una técnica de método conjunto basado en votación (donde se incluyen los enfoques RNA y SVM en un mismo método, con la solución de ventana móvil de tres casos previos). También se hizo un análisis de los pesos de las etiquetas de los clasificadores para tener una mejor catalogación de los problemas (evitar falsos positivos o negativos). / Se adicionó el modelo de variables latentes del proceso gaussiano para reducir el espacio de representación de cinco a dos dimensiones y mejorar la clasificación de los grupos.</p>	<p>t_{ciclo}, $t_{inyección}$, $t_{clasificación}$, Pmax de inyección y Cushion(cojín)</p>	<p>39827 ciclos de inyección, con 892 no conformidades (499 incompletas y 393 con rebaba). Se entrenó con 80% de datos y se probó el modelo con los datos restantes.</p>	<p>El objetivo del sistema fue clasificar los productos entre OK y NOK según los parámetros que se manejaban (y una clasificación extra entre defectos por incompletos o con rebaba).</p> <p>El sistema era capaz de notificar al operador si era necesario algún ajuste para no producir piezas defectuosas</p>
---	--	--	---	---------------	--	---	---	--	--