



UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO

PROGRAMA DE MAestrÍA Y DOCTORADO EN INGENIERÍA

INGENIERÍA MECÁNICA – DISEÑO MECÁNICO

Aplicación de redes neuronales artificiales para el modelado de defectos en piezas inyectadas a través de parámetros de inyección

MODALIDAD DE GRADUACIÓN: TESIS

QUE PARA OPTAR POR EL GRADO DE:

MAESTRO EN INGENIERÍA

PRESENTA:

Julio César González Sánchez

Tutor Principal:

Dra. Magdalena Trujillo Barragán

Facultad de Ingeniería

Ciudad Universitaria, CD. MX., Junio 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.

If I'm the seed, they've grown me

They who are my army

The wall of arms around me

The Maccabees

Dedicatoria

Esta tesis va dedicada a cada una de las personas que han aportado algo a mi vida; a mi familia, amigos y compañeros que dejaron un pedazo de ellos en mí.

A Jesús, mi esposo, quien me apoyó incondicionalmente para concluir este proyecto, quien me motivó siempre a seguir adelante, a quien nunca terminaré de agradecer por todo lo que me ha dado y todo lo que he crecido a su lado. Debo agradecer todo el tiempo que dedicaste a permitirme realizar este proyecto y por siempre confiar en mí y brindarme la confianza de hacerlo yo mismo. Este es un logro de los dos y un reflejo de todo lo que podemos hacer juntos. Te amo.

A mi mamá Julieta, que me alentó a seguir mis sueños y que siempre creyó en mí para lograrlos, gracias a ti por tus enseñanzas y todo el cariño con el que me criaste.

A mi amigo el Maestro Omar González, por su apoyo durante esta travesía, sus consejos y su compañía.

Al Laboratorio de Procesamiento de Plásticos por abrirme sus puertas y a sus integrantes, las y los futuros ingenieros por su ayuda.

A mis amigos Karina, Ángel, Victoria, Sergio, Nelly, Francisco, Jess, Hugo y Valeria por compartir momentos inolvidables en mi vida.

Agradecimientos

A la Universidad Nacional Autónoma de México, por todo lo que me ha dado, a la Facultad de Ingeniería por formarme como profesional y al Consejo Nacional de Ciencia y Tecnología por la beca nacional que me proporcionó para realizar mis estudios de posgrado.

Al Programa de apoyo y proyectos de investigación e innovación tecnológica (PAPIIT), Clave del proyecto: BG400620, Proyectos de vivienda, refugio temporal, clínica médica de urgencias y de cubiertas para usos múltiples destinados a grupos marginados, migrantes y todo sector social vulnerable a carecer de vivienda, de escasos o nulos recursos económicos en México, por otorgarme una beca para poder concluir esta tesis.

A la Dra. Magdalena Trujillo por darme la confianza de construir este proyecto y por todas las enseñanzas que me ha brindado.

Al M. I. Efraín Ramos Trejo por su ayuda en la medición de las piezas inyectadas.

Resumen

El laboratorio de procesamiento de plásticos de la Facultad de Ingeniería de la Universidad Nacional Autónoma de México, en colaboración con la Facultad de Arquitectura, lleva a cabo un proyecto llamado 'Proyectos de vivienda, refugio temporal, clínica médica de urgencias y de cubiertas para usos múltiples destinados a grupos marginados, migrantes y todo sector social vulnerable a carecer de vivienda, de escasos o nulos recursos económicos en México', dentro del cual se requiere de piezas plásticas para este tipo de construcción, una de esas piezas cuenta con dos deflexiones a lo largo de dos ejes que afectan directamente al ensamble de esta pieza y por ende a la aplicación.

Para poder disminuir las deflexiones se planteó, emplear herramientas destinadas a optimizar procesos, en este caso, el procesamiento de plásticos por inyección. Estas herramientas forman parte de los optimizadores bio-inspirados, de los cuales se probaron tres de ellos: lobos grises, ballenas grises y hormigas león. Para llevar a cabo la optimización, se utilizaron redes neuronales artificiales para modelar y predecir la relación que existe entre las variables del procesamiento de plásticos y el defecto de deflexión en la pieza inyectada; estas redes fueron entrenadas con datos obtenidos de forma virtual y también experimental.

Se encontró que todos los optimizadores disminuían las deflexiones en porcentajes distintos, y quien obtuvo mejores resultados fue el de hormigas león; sin embargo, los otros optimizadores no distaron tanto del desempeño de este último. Por otro lado, las redes neuronales artificiales tuvieron un desempeño mediano al tener variaciones en las predicciones de las deflexiones.

Contenido

Resumen	3
DEFINICIÓN DEL PROBLEMA	1
OBJETIVO PRINCIPAL	1
Objetivos secundarios	2
HIPOTESIS.....	2
Introducción.....	3
MARCO TEÓRICO.....	8
Comportamiento de los materiales en el proceso de inyección de plásticos.	8
Proceso de inyección de plásticos	12
Diseño del molde de inyección de plásticos	15
Técnicas de optimización	18
Diseño de experimentos	34
Redes neuronales artificiales y su capacidad de predicción.	38
METODOLOGÍA	44
RESULTADOS Y DISCUSIÓN.....	51
CONCLUSIONES	88
Trabajos a futuro.....	90
REFERENCIAS.....	91
<i>Anexos</i>	98

DEFINICIÓN DEL PROBLEMA

En la industria de la manufactura de plásticos, el proceso de inyección es uno de los más utilizados. La necesidad de determinar los parámetros del proceso de inyección ha sido, por mucho tiempo, una decisión difícil que ha producido distintas metodologías con este propósito[1].

Un gran número de metodologías y técnicas se encargan de obtener los parámetros de proceso óptimos para lograr una buena calidad superficial en las piezas inyectadas, además de estabilidad dimensional, repetibilidad en el proceso y constancia en las propiedades físicas de la pieza [2].

Por otro lado, existen técnicas que se basan en la simulación del proceso de inyección de plásticos mediante softwares especializados que evitan el gasto de recursos como tiempo o material y que muestran solamente datos de referencia para inyectar la pieza, ya que se toman ciertas simplificaciones [3]. Además, se han desarrollado métodos de optimización que, a partir de datos experimentales, pueden encontrar mínimos o máximos en el proceso [4].

No obstante, en el ámbito de la inyección de plásticos existen pocos registros de evaluaciones de métodos de optimización, recientemente desarrollados, además de la comparación de experimentaciones físicas y simuladas [3].

Para ello, se sugiere el análisis de la deformación en una pieza caso de estudio usando redes neuronales artificiales, para modelarla a través de experimentaciones físicas y virtuales.

OBJETIVO PRINCIPAL

Determinar el optimizador inspirado en la naturaleza que mejor se acople a la disminución de la deflexión de la pieza caso de estudio.

Objetivos secundarios

- Usar redes neuronales artificiales para modelar y predecir la relación que existe entre los parámetros de un proceso de inyección de plásticos y la deflexión en la pieza caso de estudio.
- Generar información experimental para entrenar a la red neuronal artificial, tanto con experimentaciones hechas a pie de máquina como con simulaciones.

HIPÓTESIS

Con el uso de una red neuronal artificial es posible modelar los defectos de proceso de fabricación de una pieza de plástico, si ésta se hibrida con un método de optimización inspirado en la naturaleza, ya sea con optimizador de lobos grises, optimizador de ballenas grises u optimizador de hormigas león, es posible determinar cuál trabaja de mejor manera disminuyendo la deflexión de la pieza caso de estudio.

Introducción

Anteriormente, en la industria de la inyección de plásticos se solían determinar los parámetros de proceso basándose en la experiencia obtenida y en experimentaciones hechas a prueba y error. Sin embargo, a través de los años se encontró que este método no cumplía con los requerimientos y exigencias de piezas más complejas y de materiales especializados, por lo que, con ello, se motivó a la misma industria a desarrollar metodologías con sustento teórico que pudieran determinar los parámetros necesarios para obtener piezas de calidad [1].

Dependiendo de los requerimientos de la pieza, o bien del proceso, se definen distintos tipos de metodologías para la optimización, que se pueden basar en modelados del comportamiento físico del flujo plástico, en análisis estadísticos que destacan la influencia de los parámetros de proceso en las variables de control que se elijan, entre otras. Las metodologías se pueden enfocar en disminuir defectos, encontrar la estabilidad dimensional, o bien en disminuir el tiempo de ciclo [5].

En [5] se clasifican las técnicas de optimización en métodos en línea y métodos fuera de línea, incluyendo en la primera clasificación el método de prueba y error, el modelo libre de optimización e, incluso, el moldeo científico. El modelo libre de optimización se basa en datos experimentales para la disminución de los defectos superficiales mediante el uso de algoritmos e iteraciones para conocer el comportamiento de la respuesta en estudio [6], mientras que el moldeo científico realiza experimentaciones a pie de máquina para determinar los parámetros de proceso con los cuales se obtenga la mejor calidad superficial de la pieza de estudio [7].

Dentro de la clasificación de métodos fuera de línea, se consideran aquellos que se basan en simulaciones para determinar los valores óptimos de las variables de control. Existen subclasificaciones que se definieron en [4], [8]–[10], las cuales son: métodos directos y métodos basados en metamodelos; siendo los primeros aquellos que se basan en algoritmos para cumplir con el objetivo, mientras que los segundos requieren desarrollar un modelo que relacione las variables de diseño con la respuesta elegida,

comúnmente el modelado se realiza mediante polinomios de bajo orden, estos metamodelos tienen la característica de que pueden ser utilizados para solucionar distintos problemas sabiendo definir las variables de diseño y la respuesta estudiada. Algunas de las técnicas basadas en simulación más utilizadas son algoritmos genéticos (AG), optimización basada en gradiente, método de respuesta de superficie (RSM), redes neuronales artificiales (RNA), modelo Kriging, así como híbridos entre éstos.

Los algoritmos genéticos se basan en la teoría de la evolución de Darwin, en donde la población es el número de posibles soluciones que tiene el proceso y, mediante la evaluación de una función objetivo, se determina el individuo más apto en esa generación; posteriormente, a través de procesos de mutación y reproducción, se obtienen generaciones subsecuentes hasta encontrar al individuo que mejor evaluación de la función objetivo obtenga. Esta técnica es parte de los modelos de optimización directa [11], [12].

En el caso de los modelos de optimización basados en metamodelos, un ejemplo es el modelo de respuesta de superficie, el cual, a través de un procesamiento estadístico de datos, es capaz de determinar un polinomio de segundo orden que relaciona las variables de diseño con las variables de respuesta, a partir del cual se obtienen los valores óptimos de las variables de diseño [13].

El método de respuesta de superficie es utilizado por Berti [14] para determinar el conjunto de parámetros con los cuales los radios de una carcasa de motor se encuentran dentro de las tolerancias de ensamble, mientras que Heidari [13] utiliza esta técnica para predecir la deflexión y el encogimiento volumétrico en prótesis plásticas de cadera.

En [9] se enlistan artículos en los cuales se aplican los modelos matemáticos de optimización, así como el diseño de experimentos utilizado, las variables de diseño y las respuestas analizadas, en donde se destaca el uso del método de respuesta de superficie y las redes neuronales artificiales.

Las redes neuronales artificiales emulan el comportamiento de las neuronas del cerebro humano, a través de conexiones entre ellas para poder analizar un conjunto de

datos con el fin de determinar los patrones que siguen, clasificarlos y, con ello, predecir el comportamiento de éstos [8].

A través de experimentaciones hechas mediante el software Moldflow™, utilizando técnicas como las descritas en párrafos anteriores, Dang [4] determinó que para un caso de estudio analizando y tomando en cuenta como función objetivo la deformación de la pieza y el tiempo de cómputo, las técnicas que mejor desempeño tuvieron fueron la hibridación de AG y el método basado en gradiente; con un número de iteraciones de 120 y una deformación predicha de 2.72 [mm], mientras que las RNA tuvieron un número de iteraciones de 60 y una deformación de 2.74 [mm].

En [3], Oliaei aplica las RNA y se compara con el método Taguchi y ANOVA, encontrándose que los resultados obtenidos por ambas técnicas son muy parecidos, disminuyendo la deformación y los rechupes de cucharas hechas de materiales biodegradables en ambos casos.

Con los puntos anteriores se puede argumentar que, aunque la predicción de las RNA no haya sido la mejor, el valor es muy cercano y el número de iteraciones mucho menor en el caso mencionado en [4]. Aunado a ello, se encuentra que las RNA son una técnica muy utilizada para modelar el comportamiento de las variables de respuesta en función de las variables de entrada, debido a que las RNA son capaces de analizar las relaciones no lineales y multivariadas en el proceso de inyección de plásticos, comprobándose al comparar los resultados con los obtenidos por medio de ANOVA [15], [16].

A través de distintas investigaciones, se encontró que para mejorar el desempeño de las RNA era necesario utilizar alguna técnica de optimización directa que comúnmente tuviera como base el comportamiento de algunos grupos de animales. Algunas de las técnicas más recientes, de las que no se tiene registro de haber sido utilizadas en el proceso de inyección, son las técnicas de halcones de Harris, optimizador de lobos grises, algoritmo de optimización de ballenas, optimizador de hormigas león, entre otras descritas en [17].

En [12], Ozcelik, por ejemplo, realizó la hibridación con AG para disminuir la deformación en una pieza de la base de un botón de PC (personal computer), encontrando buenos resultados en la predicción y disminución de la deformación.

Con el fin de alcanzar las dimensiones críticas de unos lentes bi-esféricos, en [18], Bensingh utiliza las redes neuronales artificiales para determinar el modelo que relacione los parámetros de proceso con la respuesta, en este caso las dimensiones de los lentes. En la etapa de optimización ocuparon las técnicas de enjambre de partículas y algoritmos genéticos, haciendo una comparación entre los resultados obtenidos de las dos técnicas, encontrando una mejora en el número de iteraciones en el caso del enjambre de partículas.

Cabe destacar que la técnica de enjambre de partículas (OEP) emula el comportamiento de aves o peces en busca de su alimento, en donde el movimiento de una de estas partículas está en función del movimiento de ella misma, de las demás partículas como colectivo y de factores como la inercia, entre otros [19].

Por otro lado, Iniesta [15] utiliza también las RNA, pero en este caso se hibrida con la técnica de colonia de abejas (ACA) la cual emula el comportamiento de las abejas para conseguir su alimento; se tienen distintos tipos de abejas que realizan la búsqueda de alimento (posible solución al problema máximo o mínimo) y que, mediante un análisis de la fuente de alimento evaluando la función objetivo, se llega al punto requerido. En la investigación se analiza la deformación y se encuentran mejoras con respecto a las predicciones hechas a través de Moldflow; sin embargo, las experimentaciones se realizaron sólo por medio de simulaciones, es decir, sin validar las predicciones de forma real, a pie de máquina.

Como en el caso anterior, muchas investigaciones sólo basan sus resultados en validaciones a través de simulaciones y sólo algunas lo realizan mediante la experimentación a pie de máquina. Wang [16] utiliza las RNA para disminuir las contracciones en una pieza de prueba, donde las comparaciones de los resultados se realizan a partir de los datos obtenidos del software comercial Moldflow y no se comprueba experimentalmente las predicciones obtenidas; por el contrario, Spina [20]

utiliza las RNA en conjunto con OEP para disminuir la deformación en una recubierta de un sistema eléctrico y, en este caso, se realiza la verificación experimental, encontrando una buena efectividad de la predicción realizada y las piezas inyectadas.

Dentro de las técnicas de optimización, los diseños de experimentos juegan un papel importante en la detección de la influencia de los parámetros en la respuesta estudiada y en la forma de abordar el problema dependiendo de la pieza [21], además de la disminución en el número de experimentos a realizar, obteniendo la misma información tal como se describe en [22] algunos de los métodos más utilizados son ANOVA [13], [3], Arreglo ortogonal [23],[24] y simulaciones estocásticas [14].

A continuación, se presenta el capítulo llamado Marco teórico, donde se abordan temas importantes sobre los polímeros, su procesamiento, las técnicas de optimización utilizadas en el proceso de inyección de plásticos, así como el diseño de experimentos y las redes neuronales artificiales como herramienta para modelar procesos. Más adelante, en el capítulo de 'Metodología', se indica el procedimiento a realizar para llegar a los objetivos planteados, posteriormente se realiza un análisis de los resultados y se concluye.

MARCO TEÓRICO

Comportamiento de los materiales en el proceso de inyección de plásticos.

Polímeros

Los polímeros son macromoléculas compuestas por miles de unidades repetidoras llamadas meros, las cuales están unidas mediante un enlace covalente. Para producir un polímero es necesario un monómero, y éstos se pueden clasificar dependiendo del tipo de monómero, de enlace covalente o de su reacción al incremento de energía en forma de calor, por ejemplo: termoplástico, termo fijo y elastómero [25].

Las aplicaciones de los polímeros están en función de sus propiedades, tales como el peso molecular, su morfología, su temperatura de transición y su comportamiento reológico. Estas propiedades se definirán a continuación [26].

Síntesis polimérica

Para que los monómeros puedan producir polímeros se lleva a cabo una reacción, de la cual existen tres tipos: condensación, adición y polimerización. Un ejemplo es la polimerización radical, en la cual se tiene un iniciador que provee de radicales, los cuales atacan el doble enlace de carbono y forman enlaces con el monómero, de tal forma que se crea una cadena que comienza a crecer [27].

Para que una reacción pueda ser llamada de adición se dice que la molécula completa de monómero se debe de transformar en el polímero, mientras que para la reacción de condensación se debe de obtener un bioproducto como resultado de la reacción, agua o alcohol en algunos casos [28]. La síntesis polimérica determinará las propiedades de los materiales a través del control de su morfología y el peso molecular como ejemplos [26].

Peso molecular y morfología

El peso molecular, así como su distribución en los polímeros, es una propiedad que determina parte del comportamiento termo-mecánico del polímero; un ejemplo muy

notorio es el polietileno de alto peso molecular, de ultra alto peso molecular y de baja densidad, los cuales tienen propiedades mecánicas muy distintas que están en función del peso molecular y de la morfología del polímero [29].

Como es sabido, los polímeros contienen cadenas moleculares con una amplia distribución de longitud de cadena, el número de cadenas puede estar distribuido de distintas formas, las cuales dependen de las condiciones de polimerización; a esta distribución se le conoce como distribución de peso molecular. El peso molecular de un polímero está definido entonces como una distribución, la cual puede ser descrita por distintos pesos moleculares promedio (número promedio, peso promedio y zeta promedio), además del índice de polidispersidad, el cual proporciona información importante sobre la distribución del peso molecular y, por ende, de las aplicaciones del polímero estudiado [26].

La morfología de los polímeros es la forma en que las cadenas de éstos se acomodan, ya sea con algún orden (cristalino) o desordenadas (amorfo), ya que las cadenas poliméricas cristalinas siempre están interconectadas por zonas amorfas; los polímeros no pueden llegar a tener un orden absoluto y, con ello, se abre paso al término de polímero semicristalino, tal como se muestra en la *Figura 1* [29].

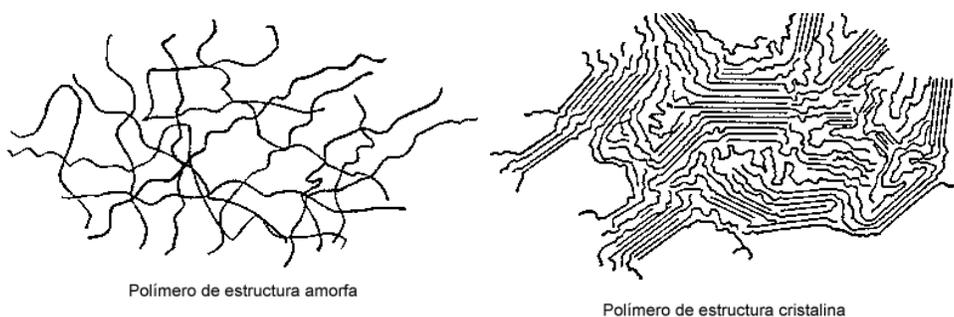


Figura 1 Estructuras poliméricas¹

La mayoría de las propiedades físicas, mecánicas y termodinámicas de los polímeros semicristalinos dependen del grado de cristalinidad y la morfología de las regiones cristalinas. Un mayor grado de cristalinidad es proporcional a una mayor densidad,

¹ Obtenido de <https://www.textoscientificos.com/polimeros/estructura>

rigidez, estabilidad dimensional, resistencia química e inversamente proporcional a la resistencia al impacto, elongación al corte y claridad óptica [25].

Transiciones térmicas en polímeros

Las transiciones térmicas en los polímeros son de suma importancia para determinar las aplicaciones de éstos, ya que a partir de ellas se conoce parte del comportamiento termo-mecánico de los materiales. Por lo general, todos los polímeros tienen al menos una transición, esta es la transición vítrea; en el caso de polímeros semicristalinos también se presenta la transición de cristalización y la de fusión, tal como se muestra en *Figura 2* [25].

La transición vítrea es una transición de segundo orden al no requerir de un aumento o disminución de la entalpía, porque no se necesita romper la red cristalina, está caracterizada por la temperatura de transición vítrea T_g , la cual señala la transición de un estado sólido amorfo a un estado fundido gomoso [29].

Comúnmente los polímeros con una cadena flexible y grupos sustituyentes pequeños tienen una T_g más pequeña que aquellos polímeros que contienen grupos aromáticos o cadenas más rígidas. La temperatura de transición vítrea es importante para determinar el comportamiento de los polímeros a cierta temperatura y, con ello, conocer las aplicaciones en las que podría funcionar este material [26].

Por otro lado, las transiciones de primer orden están definidas como una discontinuidad en la primera derivada de la energía libre de Gibbs, es decir, una discontinuidad en la entalpía, la entropía o el volumen; algunas transiciones comunes son la de cristalización y la de fusión. Estos cambios se pueden apreciar en la *Figura 2* [30].

La temperatura de cristalización T_c es aquella que define el punto en el que, una vez enfriado el material antes fundido, los cristales se forman, mientras que la temperatura de fusión T_m es aquella que indica la temperatura a la cual los cristales comienzan a fundirse; los materiales semicristalinos presentan tanto T_g , como T_c y T_m [26].

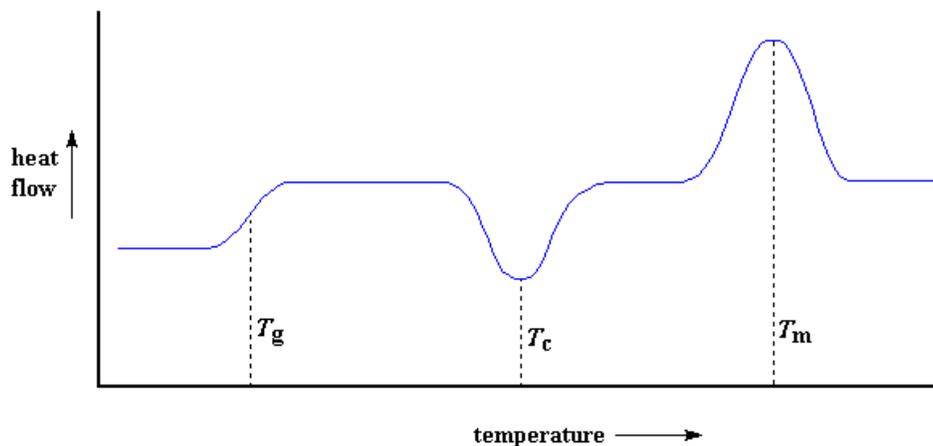


Figura 2 Termograma DSC de las transiciones térmicas en polímeros²

Reología de los polímeros

La reología en los polímeros es la ciencia encargada de caracterizar el comportamiento viscoelástico de los materiales para tener un mejor entendimiento del procesamiento de éstos, es decir, describe la deformación y el flujo de los materiales interrelacionando las fuerzas, la deformación y el tiempo, teniendo como principal propiedad la viscosidad [31], [32].

La viscosidad se puede definir como la resistencia a fluir de cualquier fluido, como se mencionó anteriormente, es una propiedad con dependencia multivariable que ayudará a definir el tipo de fluido que se esté analizando. En el caso de los polímeros fundidos se trata de fluidos no newtonianos, en donde la ley de viscosidad de Newton no es válida, ya que la viscosidad no es constante al producir cambios en la velocidad de corte [1].

Para poder relacionar la viscosidad con distintas variables se desarrollaron modelos como la ley de potencias de Otswald de Waale, el modelo de Maxwell, el de Cross-WLF, entre otros, en donde la viscosidad está en función de constantes que dependen del material [2], [28].

² Obtenido de <https://www.pslc.ws/spanish/dsc.htm>

Proceso de inyección de plásticos

En el año 1872, la máquina de inyección fue patentada por John Hayatt, los sistemas de las primeras máquinas funcionaban con aire comprimido y algunos de ellos eran realizados manualmente como la apertura del molde o la extracción de la pieza, los controles eran válvulas manuales, sin pantallas digitales y no tenían ningún sistema de seguridad [7].

En la actualidad existen sistemas muy avanzados que han permitido que se inyecten piezas complejas, en donde, incluso, se otorgan resultados estadísticos sobre el control del proceso y la calidad de la pieza en tiempo real; el sistema es completamente automatizado y, con el nacimiento de la industria 4.0, se puede controlar incluso desde forma remota [33].



Figura 3 Componentes de la máquina de inyección³

Los componentes de una máquina de inyección se dividen en unidades: unidad de inyección, unidad de cierre, unidad de control y unidad de soporte, las cuales se muestran en la *Figura 3*. En la unidad de inyección se encuentran la tolva (en donde se vierte el material), el cañón (en donde se encuentra el husillo), la camisa y la serie de

³ Imagen obtenida del Laboratorio de Procesamiento de Plásticos UNAM

resistencias, además del sistema hidráulico o eléctrico que se encarga de ejercer la presión necesaria para poder inyectar el material.

Por otro lado, en la unidad de cierre se encuentran el molde, el sistema de cierre y el sistema de expulsión; mientras que la unidad de control es aquella en donde se pueden modificar los parámetros del proceso, además de configuraciones del molde, de la unidad de inyección y de la misma máquina. La bancada o unidad de soporte es aquel soporte que garantiza que no existan vibraciones en la máquina durante su funcionamiento [34].

El proceso de inyección consiste en alimentar el barril con los pellets del material a utilizar, después, mediante la fricción que se produce debido al movimiento rotacional del husillo junto con el calor producido por las resistencias térmicas en la camisa, se logra fundir el material. Mientras el husillo gira, también realiza un movimiento lineal hacia atrás, de esta forma el material permanece al final del husillo, justo detrás de la boquilla, para posteriormente ser inyectado.

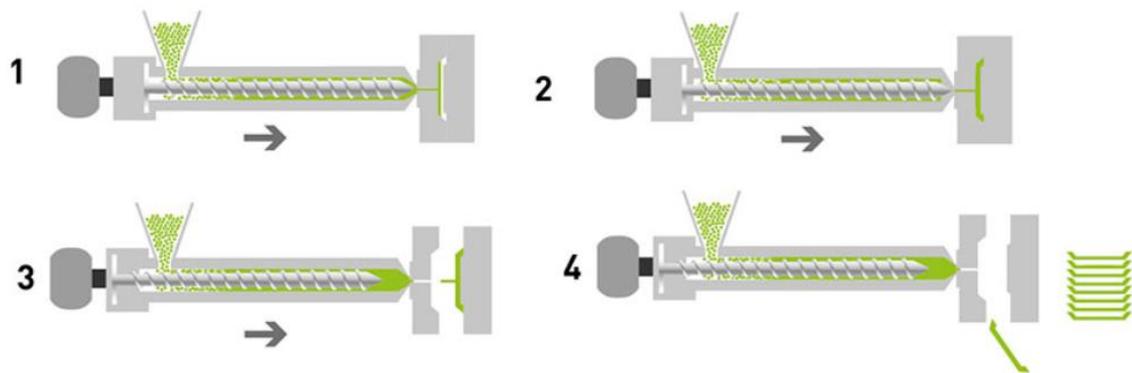


Figura 4 Proceso de inyección de plásticos⁴

Una vez que se inyectó el material gracias al movimiento del husillo hacia delante, el molde recibe al flujo polimérico, éste posee canales internos donde se encuentra un refrigerante comúnmente agua, fluyendo a través de él, que ayuda a mantener su temperatura. Al final, una vez que la pieza es enfriada por debajo de la temperatura de

⁴ Obtenido de [66]

expulsión, está lista para ser expulsada del molde[1]. En la *Figura 4* se muestran las fases del proceso de inyección convencional.

Durante el proceso de inyección existen tres fases de presión dentro del molde (presión plástica): fase de inyección, fase de compresión y fase de remanencia. Se conoce como fase de inyección al momento en que el material es inyectado en el molde la fase de compresión y la fase de remanencia suelen ser confundidas, la primera, es la fase en la cual se aplica la presión de sostenimiento, y la fase de remanencia es la presión que se aplica para que el material no regrese a la boquilla [35].

La máquina de inyección tiene parámetros importantes, los cuales determinan la calidad de la pieza a inyectar y la capacidad de la máquina. Sus definiciones se muestran en los *Anexos* [35].

Diseño del molde de inyección de plásticos

En la inyección de plásticos el diseño y manufactura del molde de inyección es primordial, ya que los moldes son diseñados con el propósito de ahorrar tiempo y dinero en la manufactura de piezas plásticas. El molde es un sistema complejo que debe ser capaz de cumplir con los requerimientos que el proceso de inyección exige, tales como los ciclos de temperatura y esfuerzos demandantes [36].

Las funciones principales del molde de inyección son tres: contener el plástico fundido, transferir el calor y expulsar la pieza una vez enfriada. Por ello, es importante identificar el material con el que se manufacturará, el material plástico que se ocupará en él, el número de cavidades, el tipo de sistema de canales, el tipo de compuertas, el sistema de enfriamiento, entre otros [2].

La composición del molde de inyección es como la que se muestra en la *Figura 5*, cuenta con dos mitades: la mitad llamada de inyección y la mitad llamada de expulsión, cada una con distintos componentes [36].

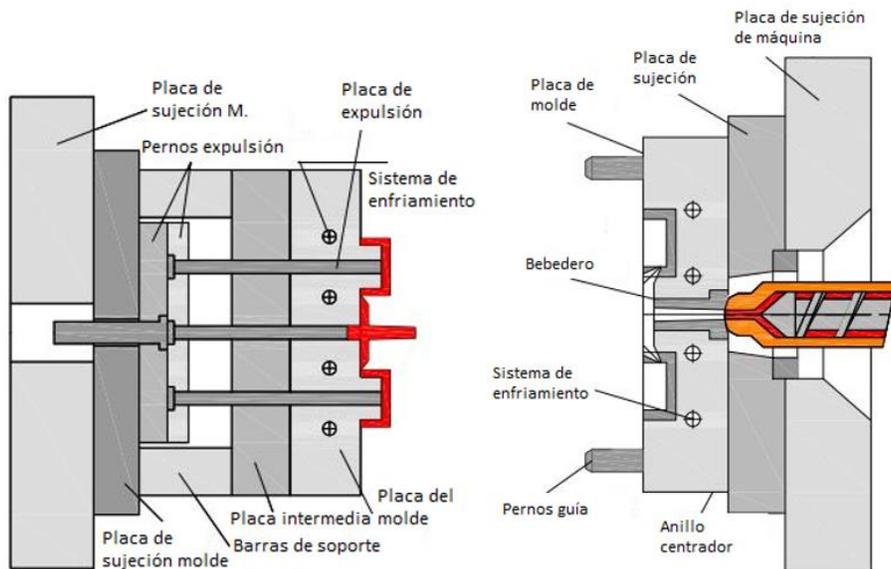


Figura 5 Componentes del molde de inyección de plásticos⁵

⁵ Obtenido de [36]

Diseño para inyección de plásticos

En el diseño de piezas para inyección de plásticos existen ciertas reglas que se deben de tomar en cuenta para evitar cualquier defecto que se pueda presentar, una de ellas es la uniformidad del espesor en la pieza, se prefiere que no existan grandes diferencias en los espesores para evitar las diferencias en temperaturas y, con ello, diferencias en las contracciones que podrían llevar a defectos como vacíos dentro de la pieza; además, para evitar grandes espesores y aumentar la rigidez del núcleo de la pieza, es necesario hacer uso del diseño de costillas y del diseño de esquinas con filetes y chaflanes para evitar problemas en la manufactura del molde, con la concentración de esfuerzos y en la contracción cerca de las esquinas; aunado a ello, para evitar que se dificulte la expulsión de la pieza se debe tomar en cuenta el ángulo de desmoldeo [2].

Análisis de llenado del molde

Este análisis es importante para determinar cómo es que el material plástico fluye a través del sistema de canales y de las cavidades, con ello se asegura que todas las cavidades se llenarán al mismo tiempo y en el mismo porcentaje, además, ayuda a determinar el lugar correcto de las compuertas, el tipo de compuertas, el espesor de las piezas, la localización de los expulsores y de las salidas de aire, entre otros parámetros de diseño [2].

Este proceso se realiza normalmente mediante softwares especializados en el proceso de inyección de plásticos como Moldflow™, tomando en cuenta las temperaturas y presiones de proceso para evitar que no se llene por completo la pieza, o bien para evitar el sobreempaquetamiento que se genera por un exceso de presión de sostenimiento o de tiempo de sostenimiento. Estos análisis están basados en la mecánica de fluidos enfocada en los fluidos no newtonianos, tomando en cuenta ciertos modelos que se presentaron en las secciones anteriores de este trabajo [37].

Afectaciones a la calidad de la pieza por el diseño del molde

El diseño del molde y de la pieza puede afectar directamente la calidad de la pieza. Como principales criterios de calidad se tienen la ausencia de defectos, el cumplimiento en las tolerancias dimensionales de diseño, control del peso y el acabado superficial de la pieza [7].

Los defectos más comunes son las contracciones y las deformaciones, sin embargo, pueden existir vacuolas, ráfagas, infundidos en la pieza, degradación del material, efecto Diesel, tiros cortos, entre otros (*Figura 6*). Estos defectos están relacionados con el comportamiento del material, el diseño de la pieza y los parámetros del proceso [1].



Figura 6 Algunos defectos en inyección de plásticos, rebabas (a), ráfagas (b) y efecto Diesel (c)⁶

Por ejemplo, las contracciones que se producen por el encogimiento volumétrico que sufre el material al pasar de un estado fundido a un estado sólido, son producidas por altas temperaturas de proceso, el tiempo de enfriamiento, la temperatura del molde, por una concentración excesiva de masa, por el tamaño y complejidad de la pieza, el espesor, el tipo de bebedero, entre otros parámetros [37].

Por otro lado, las deformaciones, a diferencia de las contracciones, son los cambios que están fuera del plano, distorsiones o flexiones. Las causas de las deformaciones están directamente relacionadas con las contracciones diferenciales debidas a cambios en el sistema de enfriamiento del molde, es decir, gradientes de temperatura [2].

⁶ Obtenido de [67]

Técnicas de optimización

Durante mucho tiempo, y antes del desarrollo de softwares especializados en la inyección de plásticos, la determinación de los parámetros de proceso se hacía con base en la prueba y el error, más tarde se implementaron métodos para determinar los parámetros de proceso basados no solamente en el conocimiento empírico, sino también analizando el comportamiento del plástico fundido en el proceso de inyección, así como distintas técnicas capaces de cumplir con los requerimientos de las piezas plásticas [38].

Por otro lado, fueron desarrolladas técnicas de optimización general, es decir, no especialmente para optimizar el proceso de inyección de plásticos. Estas técnicas tienen como fundamento las simulaciones de procesos y el uso de algoritmos especializados en encontrar mínimos o máximos globales en un espacio de búsqueda [39].

Moldeo Científico

El moldeo científico se desarrolló hace más de 10 años por los ingenieros John Bozzelli y Rod Groleau. De acuerdo con los comentarios de usuarios del método, se considera la manera más adecuada de optimizar la validación del molde al encontrar los parámetros de inyección en una máquina, otorgándole también repetibilidad y constancia en las propiedades de la pieza inyectada, además disminuye costos y previene averías en la máquina debido a un uso inadecuado [1].

El moldeo científico consiste en 6 pasos, de los cuales se obtienen los parámetros o lineamientos para el proceso de inyección. Cabe destacar que los parámetros y lineamientos que se obtienen dependen de cada material, máquina y/o molde [38]. A continuación, se describen dichos pasos.

1. Curva de viscosidad

El estudio de la curva de viscosidad consiste en encontrar un punto en donde el comportamiento del flujo sea newtoniano, es decir, donde la viscosidad aparente sea constante en un rango de velocidades de inyección; por lo general, este rango se

encuentra a velocidades de inyección altas, ya que a estas velocidades las cadenas poliméricas tienen un mejor ordenamiento y, por ende, un mejor flujo dentro de las cavidades del molde. El parámetro que se obtiene de este paso es la velocidad de inyección [1].

Se grafica la viscosidad aparente contra la velocidad de inyección, para determinar el rango donde la viscosidad aparente se considera constante. En la *Figura 7* se muestra un rango desde 80 hasta 100 [mm/s], con una aparente tendencia en la viscosidad relativamente constante.

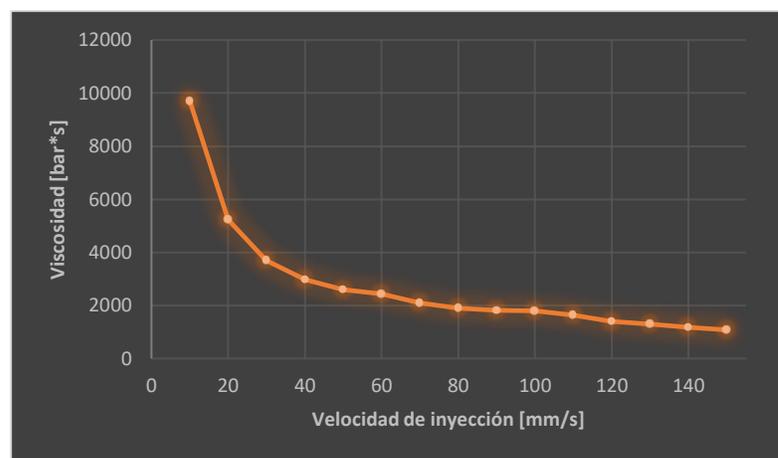


Figura 7 Curva de viscosidad

Los valores seleccionados muchas veces se basan en observar la apariencia de las muestras obtenidas, ya que la selección de la velocidad de inyección estará en función de la aplicación de la pieza, es decir, si tiene una exigencia alta en la calidad superficial, se elegirá la velocidad en donde no exista defecto alguno.

2. *Balanceo de cavidades*

El balanceo de cavidades consiste en realizar una inspección en el molde para determinar que todas las cavidades se llenen al mismo tiempo, esta definición dependerá del tipo de molde y del número de cavidades que contenga. Se verifican las dimensiones de los canales, compuertas, venteos, además de la correcta conexión del sistema de enfriamiento, para descartar o identificar la causa del desbalanceo, en caso de existir; posteriormente, se realizan inyecciones con distintos porcentajes de

volumen de la pieza, y si existe un desbalance mayor al 5% se devuelve al equipo de manufactura del molde para su corrección [40].

3. Caída de presión

El tercer paso del moldeo científico compete a la presión de inyección, es decir, con este paso se obtiene la presión máxima que requiere la pieza para poder ser inyectada, además, se indicará si la máquina es capaz de moldear la pieza. Este paso ayuda también a corroborar las simulaciones hechas previamente.

Una vez obtenida la presión máxima se ajustará en la máquina, y en el caso de que la presión de inyección se altere la máquina lo advertirá y se verificarán las probables causas, como algún cambio en los parámetros de la máquina preestablecidos, ya sea las temperaturas del barril, de la boquilla, del sistema de refrigeración o, incluso, alguna perturbación en el molde.

4. Ventana cosmética de proceso

La ventana cosmética de proceso se refiere al rango de presión de sostenimiento y de temperatura de proceso, en el cual la pieza inyectada no presenta ningún defecto superficial (ráfagas, tiros cortos, rebabas, rechupes, degradación, etc.), este rango se puede observar en la *Figura 8*. Dependiendo de la morfología del material, el proceso que se lleve a cabo será distinto. En el caso de un material semicristalino la temperatura de proceso será la temperatura del molde, debido a que esta temperatura proporciona la energía necesaria para formar cristales. En cambio, en los materiales amorfos no existe la necesidad de esa energía y la temperatura de proceso se convierte en la temperatura de masa fundida, es decir, la temperatura del material al salir de la boquilla del husillo [1].

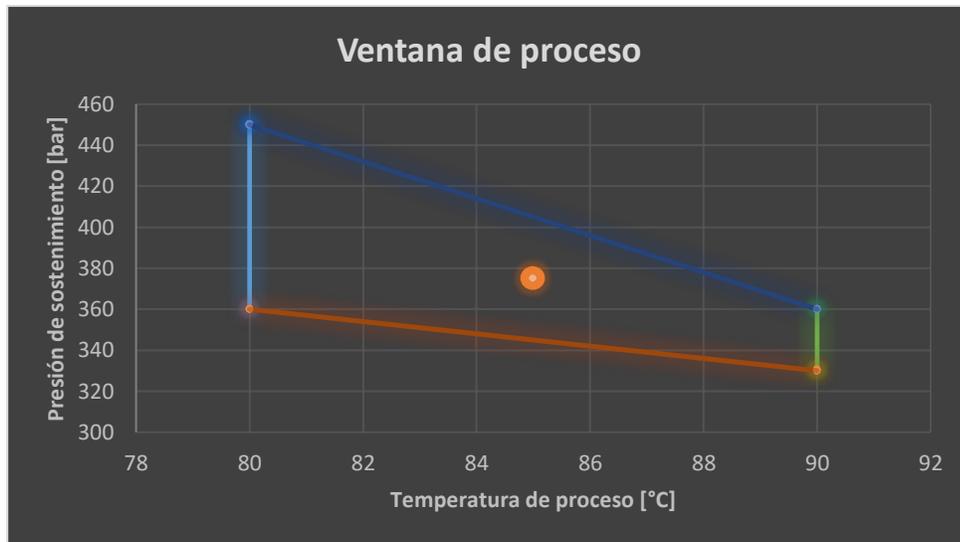


Figura 8 Ventana Cosmética de proceso

5. Sello de compuertas

El sello de compuertas en el moldeo científico es el estudio por medio del cual se encuentra el tiempo en el que la compuerta o punto de inyección de la cavidad ha solidificado y, por ende, impide que el material entre a la misma. Este paso se realiza a través de la medición de la masa con distintos tiempos de sostenimiento, eligiendo el tiempo en el que la masa no varía.

6. Tiempo de enfriamiento

El último paso del moldeo científico, el tiempo de enfriamiento, se refiere a cuánto tiempo se mantendrá la pieza enfriándose a partir del primer contacto con el molde, con el propósito de que las dimensiones críticas no varíen o estén dentro de las tolerancias configuradas para el diseño. Estas dimensiones críticas se seleccionan dependiendo de la aplicación de la pieza, por lo regular en una pieza de ensamble, y se busca que las dimensiones de las partes de la pieza que serán ensambladas estén dentro de la tolerancia del tipo de ajuste seleccionado.

Algoritmos Metaheurísticos

Por otro lado, existen técnicas que han sido desarrolladas para optimizar procesos en general, ya sea para minimizar o para maximizar alguna respuesta. Estas técnicas son llamadas algoritmos metaheurísticos, es decir, aquellos algoritmos que pueden ser aplicados en distintos problemas para encontrar una solución aproximada; estos algoritmos fueron creados para minimizar el costo y tiempo de cómputo sin disminuir la eficiencia al encontrar un objetivo basado en restricciones [41].

Una clasificación de los algoritmos metaheurísticos son aquellos inspirados en la naturaleza, como las subclasificaciones de los algoritmos basados en la evolución, es decir, aquellos que toman los conceptos desarrollados de distintas teorías de la evolución, como los estudiados por Darwin, los algoritmos genéticos; también están los algoritmos orientados en las leyes de la física, como los basados en la teoría de la gravitación universal, por ejemplo el algoritmo de búsqueda local gravitacional (GLSA por sus siglas en inglés); o bien algoritmos que emulan el comportamiento de grupos de animales durante la caza de presas, jerarquía y comportamiento social, como el algoritmo de colonia artificial de abejas (ABC), entre otros que se muestran en la *Figura 9* [42].

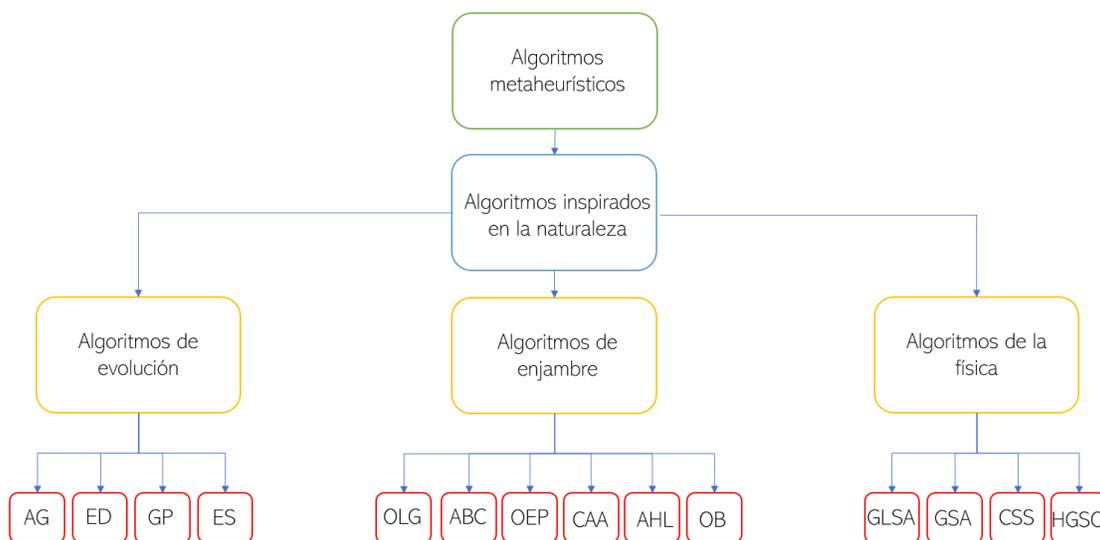


Figura 9 Clasificaciones de los algoritmos metaheurísticos

Algoritmos Genéticos

Los algoritmos genéticos (AG) están basados en los principios de la evolución descritos por Charles Darwin, en donde la población es el número de posibles soluciones de un problema de optimización para buscar el mínimo o el máximo. La población es evaluada aleatoriamente a través de una función objetivo, se eligen a los mejores individuos de esa generación para posteriormente ser reproducidos, tomando en cuenta distintos mecanismos de reproducción, como mutación, recombinación o clonación, hasta encontrar al individuo que más se adapte a la función objetivo con base en los criterios de parada [43].

Para que se puedan aplicar los algoritmos genéticos es primordial definir las restricciones de la población, en este caso los valores máximos o mínimos de los parámetros de proceso que se identifiquen como influyentes en la función objetivo, es decir, la respuesta que se desee analizar [44].

Posteriormente, es necesario codificar cada una de las posibles soluciones o individuos para poder realizar el proceso de reproducción; generalmente la codificación es binaria, se elige un cierto número de posiciones en un vector binario para identificar cada uno de los parámetros seleccionados y analizar la función objetivo [45].

La función objetivo se define como el valor al que se desea llegar con la optimización, en el caso de la inyección de plásticos puede considerarse la deformación o las contracciones como el valor objetivo, donde se busca minimizar ese valor [46].

La selección de individuos se realiza de forma aleatoria, y a esa selección se le llama generación, se evalúa a cada uno de los individuos y se identifican los que hayan tenido mejor valor en la función objetivo. Posteriormente, se realiza el proceso de reproducción para obtener la siguiente generación, en donde existen distintos mecanismos: el primero de ellos es la recombinación, en donde a partir de dos individuos se seleccionan partes de sus vectores para combinarlos; también existe el mecanismo de mutación, donde en cierta posición del vector la componente se cambia, es decir, si era uno ahora será cero, y viceversa; un último mecanismo es la clonación, donde ya sea el padre o la madre se clonan para la siguiente generación [44].

Optimización por enjambre de partículas (OEP)

Este algoritmo también forma parte de los algoritmos inspirados en la naturaleza, en este caso, en el comportamiento de grupos de aves, de peces o de grupos de animales en busca de alimento o para evitar a los depredadores mediante la compartición de información [47].

En el caso de la OEP cada partícula es una posible solución al problema de optimización, el algoritmo consiste en seleccionar aleatoriamente un conjunto de partículas, las cuales tendrán un vector de posición $x(t)$ y un vector de velocidad $v(t)$ [20].

Esta velocidad estará influenciada por la posición en donde mejor valor de la función objetivo haya tenido la partícula (y), además de la influencia del enjambre, que se define como la mejor posición en donde se haya encontrado una partícula del enjambre (y_e). Por otro lado, existe un coeficiente llamado inercia, que tomará en cuenta el movimiento que seguía la partícula (w) y distintos coeficientes que aporta la naturaleza de un proceso estocástico, o bien que restringen el tamaño de paso para la evaluación (r_1, r_2, c_1 y c_2). La velocidad se calculará como se muestra en la ecuación (1) [48].

$$v(t + 1) = w * v(t) + c_1 * r_1(t) * [y(t) - x(t)] + c_2 * r_2(t) * [y_e - x(t)] \quad (1)$$

$$x(t + 1) = x(t) + v(t + 1) \quad (2)$$

La nueva posición se calcula conforme a la ecuación (2). De esta forma es posible encontrar el punto máximo o mínimo requerido para la optimización del proceso.

Algoritmo de colonia de abejas artificiales (CAA)

El algoritmo de colonia de abejas artificiales tiene como base el comportamiento de las abejas mieleras, en el cual existen tres tipos de abejas: las empleadas, las espectadoras y las exploradoras. Las abejas empleadas son aquellas que están en busca de las fuentes de alimento, mientras que las espectadoras esperan la información provista por las empleadas para tomar la decisión de acudir a cierta fuente de alimento. Cuando se toma

la decisión, todas las abejas se convierten en exploradoras para acercarse a la mejor fuente de alimento [15].

Para la optimización se toma en cuenta que las fuentes de alimento son cada una de las posibles soluciones al problema, mientras que el néctar que se encuentra en ellas es la evaluación de la función objetivo y el número de abejas es el tamaño de la población a analizar [8].

Para iniciar el algoritmo es necesario determinar las restricciones en las variables de diseño, se selecciona el número de abejas con las que se trabajará y la función objetivo que se evaluará. Posteriormente se genera una primera iteración con abejas elegidas aleatoriamente, se evalúa cada una de las posiciones de las abejas empleadas mediante la función objetivo, se comparte la información con las abejas espectadoras y se determina cuál es la mejor fuente de alimento, para posteriormente buscar más hasta llegar al objetivo o cuando se cumpla el criterio de parada [49].

Algoritmo de hormigas león (AHL)

Este es un algoritmo que también pertenece a aquellos algoritmos inspirados en la naturaleza, en este caso en el comportamiento de las hormigas león en el momento en que cazan su alimento. Las hormigas león son una especie que, mientras están en estado larvario, para cazar a su alimento generan trampas de forma cónica en el suelo con ayuda de sus mandíbulas, donde las hormigas que no son león caen y, debido a la pendiente pronunciada, les es difícil salir de la trampa; aunado a ello, las hormigas león se encuentran justo en el fondo de las trampas, comienzan a arrojarles arena para impedir que salgan y, hasta que llegan al fondo, son devoradas, tal como se muestra en la *Figura 10* [39].

Para poder elegir el comportamiento de las hormigas león como funcional para desarrollar un algoritmo capaz de encontrar soluciones a problemas con función objetivo, se determinó que es posible encontrar una solución global al problema, debido a que las hormigas león buscan sus presas de una forma aleatoria y sus presas también se mueven de forma aleatoria, evitando estancarse en un óptimo local. Este movimiento

aleatorio se modela con las ecuaciones (3) y (4), donde el vector r es un vector aleatorio y $X(t)$ la posición de las hormigas; esto se puede observar en la Figura 11 [50].

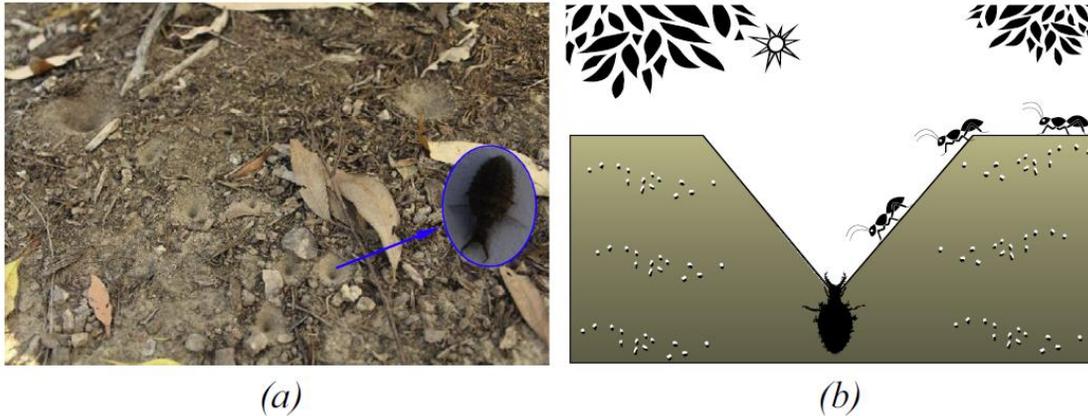


Figura 10 Hormiga león en la superficie (a) hormiga león dentro del cono⁷

$$X(t) = [0, \text{cumsum}(2r(t_1) - 1), \text{cumsum}(2r(t_2) - 1), \dots, \text{cumsum}(2r(t_n) - 1)] \quad (3)$$

$$r(t) = \begin{cases} 1 & \text{if } \text{rand} > 0.5 \\ 0 & \text{if } \text{rand} \leq 0.5 \end{cases} \quad (4)$$

En el algoritmo, tanto las presas como las hormigas león son aquellas posibles soluciones del problema. La hormiga león construye su trampa tomando en cuenta la evaluación de la función objetivo, es decir, entre mejor sea ese valor, más grande y pronunciada será su trampa. Si una presa es atrapada por la hormiga león, se evalúa la función objetivo de la presa y se determina si es mejor al ya tenido por la hormiga león; si es así, la presa se convierte en la hormiga león en la siguiente iteración y cada uno de los valores obtenidos por la función objetivo se guarda en matrices al igual que cada una de las posiciones. De esta forma se aproximan a los mejores valores para obtener la solución [17].

Al iniciar el algoritmo en busca de la solución al problema de optimización, se restringe el espacio de búsqueda, o bien el de las posibles soluciones, para que estén dentro de lo

⁷ Obtenido de [39]

permitido por las variables de diseño, y se selecciona el algoritmo con el cual se otorgará la aleatoriedad al proceso, tanto para el andar de las hormigas como para la construcción de las trampas de las hormigas león [39].

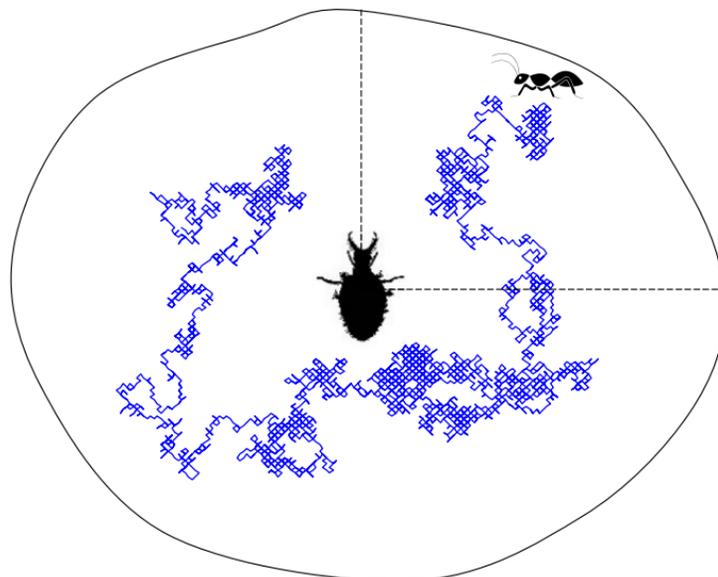


Figura 11 Hormiga moviéndose de forma aleatoria⁸

Optimizador de lobos grises (OLG)

El optimizador de lobos grises es un algoritmo inspirado en la jerarquía social y el comportamiento de los lobos grises al momento de cazar. Los líderes son los lobos alfa, los cuales deben de ser respetados por todos los demás lobos, además de que se encargan de la toma de decisiones sobre la caza, el lugar donde dormir, entre otros; por otro lado, los lobos beta son aquellos considerados los consejeros de los alfa, están por encima de los demás lobos y son los candidatos para convertirse en alfa si el que está muere o se vuelve viejo [51].

El rango más bajo en la jerarquía de los lobos grises es el omega, aquellos lobos que sean omega están destinados a comer por último y a ser subordinados de todos los demás lobos: mientras que los lobos delta son quienes tienen la tarea de ser cuidadores, centinelas, cazadores y exploradores, también están los que alguna vez fueron alfa. Por

⁸ Obtenido de [39]

otra parte, la manera en que los lobos grises cazan es la siguiente: comienzan rastreando a la presa, continúan rodeándola y, posteriormente, es atacada [51].

Para modelar matemáticamente la jerarquía de los lobos grises, así como su proceso de caza, es necesario designar como la mejor solución al lobo α (alfa), la segunda mejor solución al lobo β (beta), la tercera mejor solución a δ (delta) y, por último, todas aquellas que restan serán designadas como lobos ω (omega)[52].

La fase de rodear a la presa es modelada a partir de operaciones con los vectores mostrados en la *Ecuación 8*, del lado izquierdo, donde t indica la iteración actual, \vec{A} y \vec{C} son vectores de coeficientes, \vec{X}_p es el vector de posición de la presa y \vec{X} es el vector de posición del lobo gris. Los vectores \vec{A} y \vec{C} se calculan tal como se muestra en la ecuación (5), del lado derecho, donde \vec{a} decrece linealmente desde dos hasta cero a través del paso de las iteraciones; por otro lado, los vectores \vec{r}_1 y \vec{r}_2 son vectores aleatorios en el rango [0,1]. Este proceso se puede observar en la *Figura 12*, donde se denotan distintas posiciones en dos y en tres dimensiones [51].

$$\begin{aligned} \vec{D} &= |\vec{C} \cdot \vec{X}_p(t) - \vec{X}(t)| & \vec{A} &= 2\vec{a} \cdot \vec{r}_1 - \vec{a} \\ \vec{X}(t+1) &= \vec{X}_p(t) - \vec{A} \cdot \vec{D} & \vec{C} &= 2 \cdot \vec{r}_2 \end{aligned} \tag{5}$$

En el modelado del proceso de caza se asume que tanto el lobo alfa como los lobos beta y delta tienen un mejor conocimiento de la posición de la presa, por ello las posiciones de cada uno de ellos son consideradas como las mejores, haciendo que la posición de los lobos omega se vea obligada a seguirlos. Esto se muestra tanto en las ecuaciones (6) como en la *Figura 14*; también se muestra el cálculo de las posiciones de la siguiente iteración para cada uno de los lobos, donde D_α , D_β y D_δ son las aportaciones de las posiciones de cada uno de los lobos, alfa, beta y gama respectivamente [52].

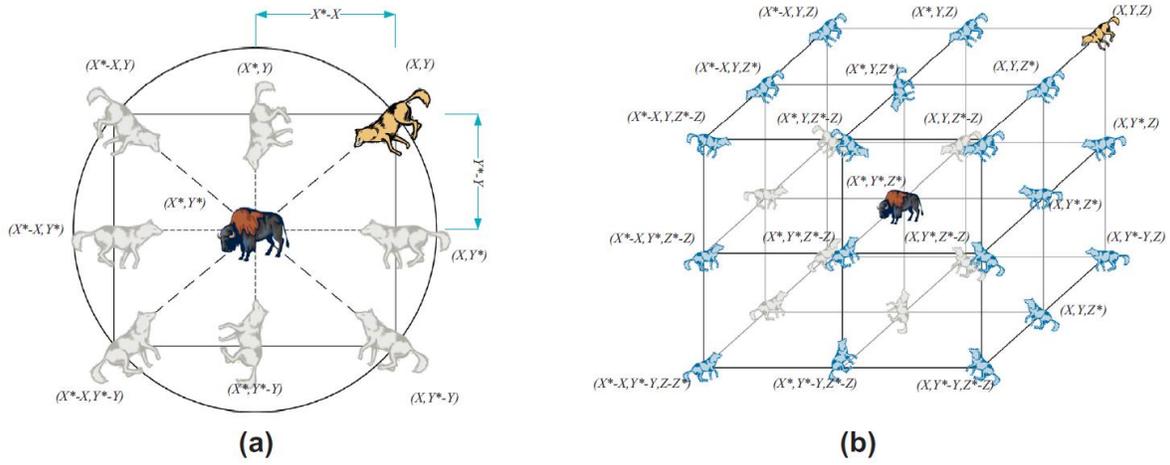


Figura 12 Posibles futuras posiciones de los lobos para rodear a la presa en 2D (a) y 3D (b)⁹

$$\begin{aligned}
 D_\alpha &= |C_1 \times X_\alpha - X(t)|, & X_{i1}(t) &= X_\alpha(t) - A_{i1} \times D_\alpha(t), \\
 D_\beta &= |C_2 \times X_\beta - X(t)|, & X_{i2}(t) &= X_\beta(t) - A_{i2} \times D_\beta(t), \\
 D_\delta &= |C_3 \times X_\delta - X(t)|, & X_{i3}(t) &= X_\delta(t) - A_{i3} \times D_\delta(t)
 \end{aligned} \tag{6}$$

$$X(t+1) = \frac{X_{i1}(t) + X_{i2}(t) + X_{i3}(t)}{3}$$

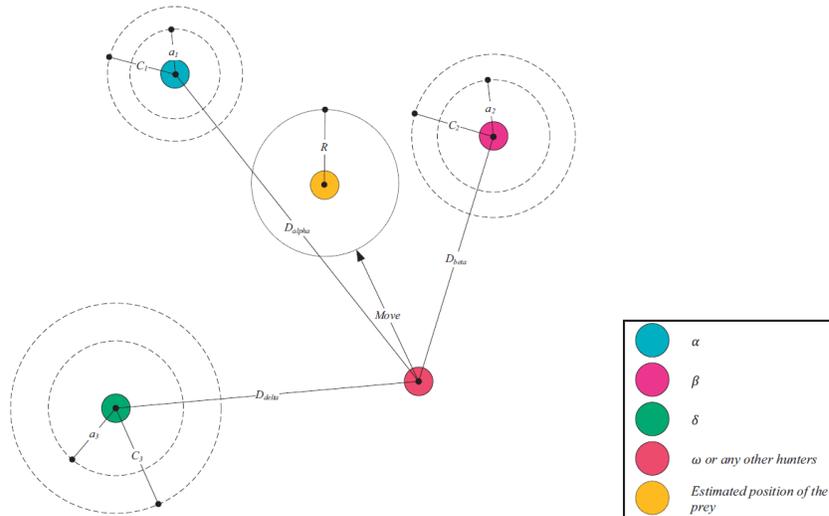


Figura 13 Actualización de posiciones en el OLG¹⁰

⁹ Obtenido de [51]

¹⁰ Obtenido de [51]

El último paso es el ataque de los lobos hacia la presa. Una vez que se realizó el proceso de exploración con valores de $|A| > 1$ se comienza la fase de explotación con valores de $|A| < 1$ con ello, se disminuye la distancia entre los lobos y la presa, tal como se muestra en la *Figura 13 y 14*. Conforme avanzan las iteraciones, las posiciones de los lobos alfa, beta y delta van mejorando al disminuir o aumentar el objetivo planteado.

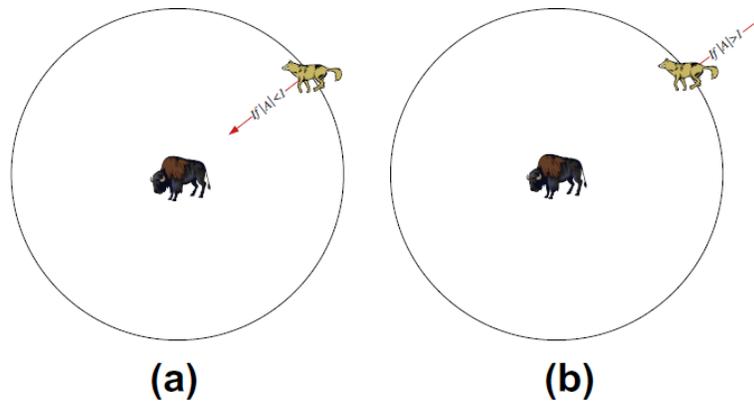


Figura 14 Ataque a la presa vs búsqueda de la presa¹¹

Por otro lado, es necesario mencionar que posteriormente se realizaron mejoras al optimizador. Estas mejoras consisten en compensar algunas deficiencias como la diversidad de la población, el desbalance entre la fase de exploración y la fase de explotación, además de la convergencia prematura del algoritmo. En [52] se menciona la hibridación con el método llamado dimensión de caza basado en aprendizaje, por sus siglas en inglés (DLH), en donde la mayor aportación está en el compartir información entre el vecindario de los lobos.

De esta forma, nace el OLG-M (optimizador de lobos grises mejorado). En este algoritmo surgen algunas modificaciones al algoritmo original, principalmente existen dos opciones para elegir las nuevas posiciones de los lobos, ya que mientras en el primero éstas estaban sólo en función de las posiciones de los lobos α , β y δ , en la versión mejorada las posiciones están en función del vecindario de los lobos y la información que aportan para evitar quedar atrapados en óptimos locales. En un principio se calcula el radio de la vecindad de los lobos, posteriormente se genera una matriz de los vecinos

¹¹ Obtenido de [51]

para que, por medio de la ecuación (7), se genere una posición nueva, por último, se realiza una comparación entre la posición encontrada por el OLG y la encontrada por OLG-M, ecuación (8), y los valores obtenidos por la función objetivo para tomar la mejor y esa ser la nueva posición del lobo.

$$X_{i-DLH,d}(t+1) = X_{i,d}(t) + rand \times (X_{n,d}(t) - X_{r,d}(t)) \quad (7)$$

$$X_i(t+1) = \begin{cases} X_{i-GWO}(t+1), & \text{if } f(X_{i-GWO}) < f(X_{i-DLH}) \\ X_{i-DLH}(t+1) & \text{otherwise} \end{cases} \quad (8)$$

Algoritmo de optimización de ballenas (OB)

El algoritmo de optimización de ballenas tiene su inspiración en la forma en la que las ballenas jorobadas cazan a sus presas, éstas se alimentan generalmente de grupos de kriles o de peces muy pequeños cerca de la superficie del agua. La forma en la que cazan estas ballenas es muy singular, en un principio detectan a la presa y, para poder atraparla, crean una prisión de burbujas en forma circular o en forma del número 9, tal como se muestra en la *Figura 15* [53].

Para el modelado matemático del proceso de caza de las ballenas es necesario aclarar que en una aplicación real no es conocida la posición de la presa, sin embargo, se asume que aquella posición que mejor evaluación de la función objetivo tenga será aquella que esté más cercana a la presa, de esta forma, las demás posiciones serán influenciadas por la mejor o la más cercana a la presa, tal como se muestra en la ecuación (9), donde t indica la iteración actual, $\vec{X}(t)$ la posición del vector, $\vec{X}^*(t)$ la mejor posición hasta el momento, misma que debe ser actualizada en cada iteración sí se encuentra una mejor. Al igual que en OLG existen dos vectores de coeficientes \vec{A} y \vec{C} donde \vec{a} decrece conforme a las iteraciones y \vec{r} es un vector aleatorio en un rango de [0,1] [54].

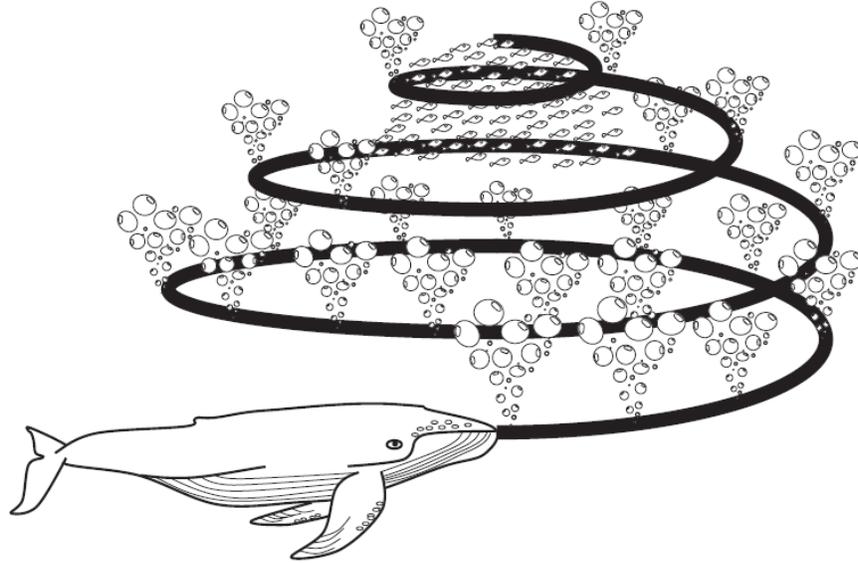


Figura 15 Forma de caza de las ballenas jorobadas¹²

Se muestra en la *Figura 16* que gracias a los vectores A y C es posible actualizar las posiciones en el vecindario de la mejor posición encontrada hasta ese momento, esto se muestra en dos y en tres dimensiones, sin embargo, aplica lo mismo para 'n' número de dimensiones; cabe resaltar que las dimensiones se refieren al número de entradas o parámetros analizados.

$$\begin{aligned} \vec{D} &= |\vec{C} \cdot \vec{X}^*(t) - \vec{X}(t)| & \vec{A} &= 2\vec{a} \cdot \vec{r} - \vec{a} \\ \vec{X}(t+1) &= \vec{X}^*(t) - \vec{A} \cdot \vec{D} & \vec{C} &= 2 \cdot \vec{r} \end{aligned} \quad (9)$$

El modelado de la siguiente fase tiene dos enfoques, ambos están relacionados con la forma en que se atrapará a la presa, por un lado, rodeando a la presa en forma de círculo y, por otro, por medio de una espiral; el primero se realiza a partir del decrecimiento de 'a', ya que este determina el valor de 'A', y al disminuir se acerca más a la presa tal como se muestra en la *Figura 17 (a)*. Por otro lado, el segundo enfoque se define a partir de la creación de la ecuación (10), que resulta en una espiral que toma en cuenta la posición de la ballena y la de la presa; esta espiral puede ser observada en la *Figura 17 (b)*. Donde $\vec{D}' = |\vec{X}^*(t) - \vec{X}(t)|$ es la distancia entre la posición de la presa y la de la

¹² Obtenido de [53]

ballena, b es una constante que define la forma de la espiral logarítmica, l es un número aleatorio en el rango $[-1,1]$ y el $'$ es una operación de multiplicación elemento por elemento.

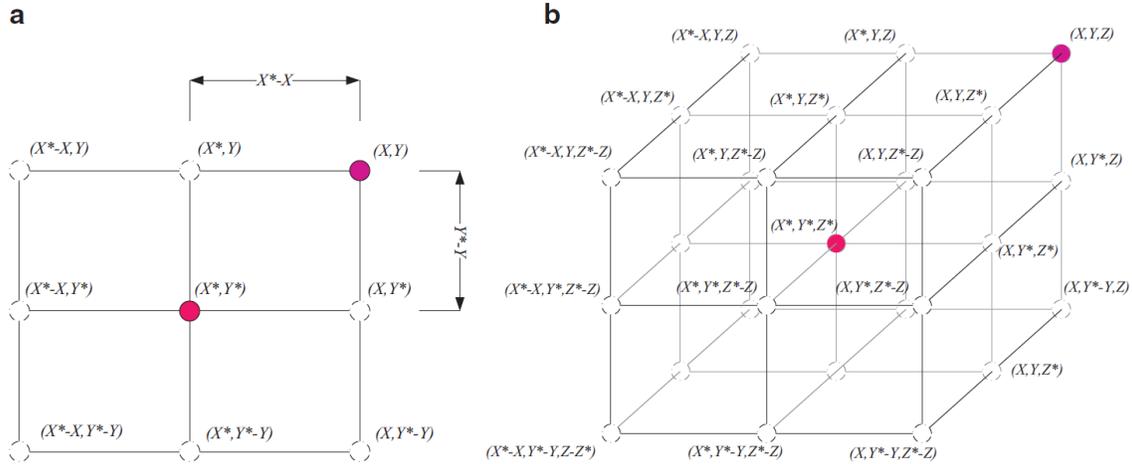


Figura 16 Posibles posiciones de las ballenas en 2D (a) y en 3D (b)¹³

$$\vec{X}(t+1) = \vec{D}' \cdot e^{bl} \cdot \cos(2\pi l) + \vec{X}^*(t) \quad (10)$$

La ballena realiza de forma aleatoria la selección de la forma de caza, esto se modela a través de un número aleatorio p entre 0 y 1, si el número es menor igual a 0.5 se seleccionará la forma de círculo, de lo contrario se seleccionará la forma de espiral.

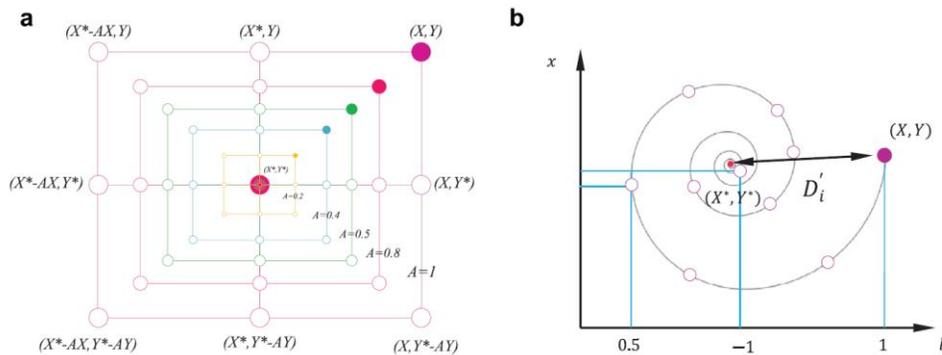


Figura 17 Formas de cazar de las ballenas, en forma de círculo (a) y en forma de espiral (b)¹⁴

¹³ Obtenido de [53]

¹⁴ Obtenido de [53]

Las fases de exploración y explotación son regidas por la selección del valor de referencia del vector \vec{D} y de los valores del vector \vec{A} , por un lado, en la fase de exploración el vector \vec{D} está en función de una posición aleatoria en todo el espacio de búsqueda, lo que evita que la exploración se centre en un sólo lugar; una vez que el número de iteraciones llegó a la mitad del total, el vector \vec{D} ahora está en función de la mejor posición encontrada y la fase cambia a la de explotación para poder encontrar el mejor valor. Por otro lado, los valores del vector \vec{A} repercuten en la búsqueda de posiciones nuevas, ya que al estar fuera del rango de $[-1,1]$ hacen que las posiciones se alejen de las presas encontradas en inicio, mientras que, cuando están dentro del rango, aumentan la atracción de las nuevas posiciones al lugar donde se encuentra la presa.

Diseño de experimentos

La necesidad de la industria por la optimización de productos a través del diseño de experimentos para aumentar la eficiencia, la producción y la calidad del producto, además de minimizar tiempos y costos, ha hecho que siga en aumento la investigación en esta área [55].

El diseño de experimentos es una herramienta que nos permite determinar la influencia de las variables en una respuesta dada (caracterización del proceso), estas variables son conocidas como factores, a través de un diseño de experimentos es posible determinar los valores de los factores que propician que la respuesta llegue a un valor cercano al deseado (optimización del proceso), además de evitar la variabilidad en la respuesta así como minimizar los efectos de variables incontrolables; por otro lado, a través del diseño de experimentos es posible determinar qué variables de diseño son las más importantes para una aplicación, en concreto, mejorar el diseño de algún producto[56].

Para la creación de un diseño de experimentos es necesario tomar en cuenta la identificación y comprensión del problema, los factores y niveles de tratamiento deben estar elegidos y seleccionada la variable de respuesta. Posteriormente, es necesario elegir un diseño de experimentos acorde a las necesidades del problema y los objetivos

planteados, más adelante se realizará la experimentación, un análisis de datos para poder concluir y hacer recomendaciones [56].

Los factores de tratamiento se definen como aquellas variables que son de interés para el experimentador y que afectan considerablemente a la variable de respuesta, la variable de respuesta es aquella variable que será analizada por el experimentador, un ejemplo relacionado con este trabajo son los parámetros del proceso de inyección de plásticos como factores de tratamiento y algún defecto como la variable de respuesta, por otro lado, los niveles de tratamiento son aquellos valores de los factores de tratamiento que serán estudiados [57].

Cabe resaltar que, para el análisis y creación de cualquier diseño de experimentos, es necesario conocer la estadística descriptiva, debido a que ésta es una herramienta de análisis y descripción de un proceso experimental, a través de ella es posible conocer los aspectos generales de un conjunto de datos. [58].

Diseño ortogonal de Taguchi

Uno de los métodos más importantes en la actualidad para mejorar la calidad de un producto es a través de la filosofía de Genichi Taguchi, en la cual se enumeran los siguientes objetivos: *La calidad debe ser diseñada mas no inspeccionada en un producto. La calidad se consigue de una mejor forma minimizando la desviación del objetivo, de tal forma que el producto debe ser diseñado para ser inmune a cualquier factor ambiental incontrolable, y el costo de la calidad debe medirse con base en la desviación estándar y las pérdidas deben medirse en todo el sistema* [59].

Lo anterior se resume en que la calidad debe estar en función de los parámetros del proceso que se está analizando, es decir, con la selección de estos parámetros para obtener la menor variación con respecto a los valores de diseño, analizando la relación señal-ruido; por otra parte, es importante considerar la función de perdida que está relacionada con todas aquellas perdidas que se puedan generar para la sociedad por productos de mala calidad [58], [59].

El método Taguchi comienza definiendo el valor objetivo, este puede ser un máximo o un mínimo, a través de él se determinan los parámetros que afectan a este valor objetivo, así como el rango de variaciones que pudieran tener; con base en el número de parámetros y de sus niveles de variación o niveles de tratamiento, se elegirá el arreglo ortogonal que mejor se adapte a esas necesidades, se realizan las experimentaciones y se analizan los datos para comprobar los objetivos [59].

Para poder determinar los parámetros del proceso que más afectan a la respuesta, es necesario realizar un análisis de datos, éste se hace a través de distintos medios, uno de ellos es la determinación del cociente señal-ruido o SN, mediante el cual se verifica cuáles de los parámetros son con los que más influencia tienen en la respuesta. Además del procedimiento anterior, existe el análisis de varianza, el cual nos proporciona también información sobre los parámetros más influyentes en la respuesta.

A continuación, se presentan las ecuaciones que permiten realizar los análisis de datos tanto con el cociente SN como con el análisis de varianza.

$$SN_i = 10 \log \frac{\bar{y}_i^2}{s_i^2} \quad (11)$$

Donde \bar{y}_i es el promedio y s_i^2 la desviación estándar. Este coeficiente se obtiene para cada experimentación tomando en cuenta el número de repeticiones que se haga; para el caso específico donde el valor respuesta requiera ser minimizado, se utiliza la siguiente expresión:

$$SN_i = -10 \log \left(\sum_{u=1}^{N_i} \frac{y_u^2}{N_i} \right) \quad (12)$$

Posteriormente se calcula el promedio del coeficiente de todas las experimentaciones por niveles de tratamiento, es decir, de cada nivel de tratamiento de cada parámetro, se suma el coeficiente y se divide entre el número de veces que haya aparecido el nivel de tratamiento a lo largo de toda la experimentación, tal como se mostrará en la *Tabla 1* y con las ecuaciones (13). Además, se requiere de calcular el rango del coeficiente en todos los niveles, es decir, restar el menor al mayor y formar la *Tabla 2*; aquel parámetro

que tenga un rango mayor será el que más impacto tenga en la variable de respuesta y así sucesivamente.

Tabla 1 Configuración de resultados de los coeficientes de SN

Número de experimento	P1	P2	P3	P4	SN
1	1	1	1	1	SN1
2	1	2	2	2	SN2
3	1	3	3	3	SN3
4	2	1	2	3	SN4
5	2	2	3	1	SN5
6	2	3	1	2	SN6
7	3	1	3	2	SN7
8	3	2	1	3	SN8
9	3	3	2	1	SN9

$$SN_{P4,1} = \frac{SN_1 + SN_5 + SN_9}{3}$$

$$SN_{P4,2} = \frac{SN_2 + SN_6 + SN_7}{3}$$

$$SN_{P4,3} = \frac{SN_3 + SN_4 + SN_8}{3}$$

(13)

Tabla 2 Tabla de ranking de coeficientes SN para todos los parámetros

Nivel de tratamiento	P1	P2	P3	P4
1	$SN_{P1,1}$	$SN_{P2,1}$	$SN_{P3,1}$	$SN_{P4,1}$
2	$SN_{P1,2}$	$SN_{P2,2}$	$SN_{P3,2}$	$SN_{P4,2}$
3	$SN_{P1,3}$	$SN_{P2,3}$	$SN_{P3,3}$	$SN_{P4,3}$
Δ	RP1	RP2	RP3	RP4
Ranking				

Redes neuronales artificiales y su capacidad de predicción.

Las redes neuronales artificiales se inspiran en los sistemas biológicos, particularmente en el funcionamiento del cerebro humano, son capaces de aprender y generalizar con base en la experiencia; éstas consisten en un conjunto de elementos de proceso conocidos comúnmente como neuronas, las cuales son ordenadas en distintos niveles, esencialmente se tienen tres niveles: entrada, capas ocultas y salida [60].

Las redes neuronales artificiales (RNA) pueden descubrir relaciones interesantes entre las respuestas deseadas y la base de datos obtenida, capaces de aprender de un ambiente complejo; han sido utilizadas para identificar huellas dactilares, reconocimiento de objetos en líneas de producción, además de reconocimiento de patrones e imágenes [61]. Las RNA son una poderosa herramienta para predecir respuestas altamente no lineales, vía función de aproximación, como las obtenidas en el proceso de inyección de plásticos [4].

Las neuronas que forman a las redes son unidades procesadoras que imitan el funcionamiento de las neuronas del cerebro humano, las cuales realizan una tarea simple, tal como la respuesta a una señal; sin embargo, cuando una red de neuronas está conectada se pueden realizar tareas más complejas, tales como hablar y el reconocimiento de imágenes [61].

Las neuronas están formadas por cuatro elementos funcionales conocidos como: receptor, sumador, activador y de salida (*Figura 18*); el receptor se encarga de recibir las señales de entrada, las cuales se atenúan o amplifican dependiendo de la relación que se le haya impuesto por medio de un peso w_i ; el sumador se encarga de realizar la operación designada (suma, multiplicación o algún otro operador), ponderando las entradas de acuerdo a su peso; el elemento activador es aquel que, dependiendo de una función umbral, decide si la neurona emite una señal o no, mientras que el elemento de salida es el encargado de emitir la señal dependiendo de la decisión del elemento anterior [62].

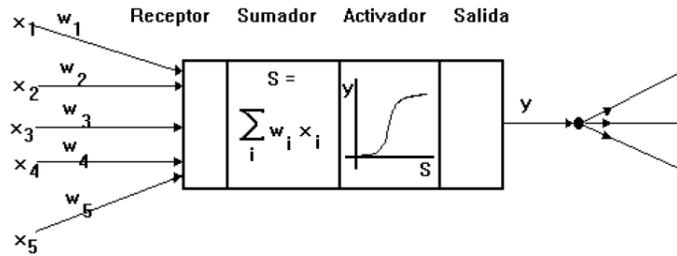


Figura 18 Esquema de neurona artificial¹⁵

Función de activación

La función de activación de la neurona determina la emisión de una señal por parte de la neurona, básicamente se emite una señal si se alcanza el umbral por el que esté definida la función, comúnmente se utilizan la función escalón y la función sigmoidea; sin embargo, se puede llegar a utilizar funciones como modelo rectificado lineal, modelo tangente hiperbólica, el modelo exponencial lineal, entre otros, como el mostrado en *Figura 19* [8].

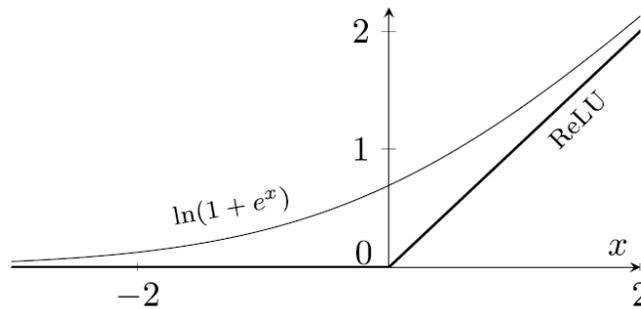


Figura 19 Modelo lineal y modelo suavizado¹⁶

Topología

Además de la organización interna de la neurona, para describir la organización y la forma en que se conectan estas neuronas se utilizan las topologías de redes neuronales. Las neuronas están organizadas por arreglos, mismos que tienen el nombre de capas (*Figura 20*), usualmente se tienen capas de entrada, de salida y ocultas, los números de

¹⁵ Obtenido de [62]

¹⁶ Obtenido de [8]

neuronas en cada una de estas capas es determinado también por la topología de la red [61].

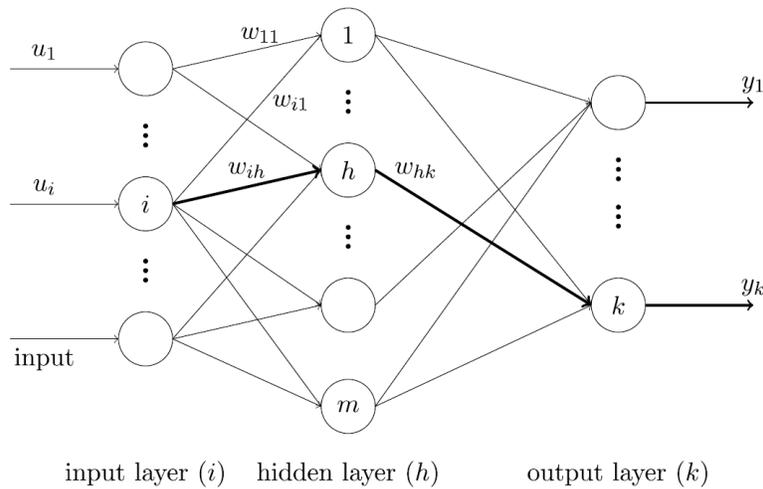


Figura 20 Topología general de ANN ¹⁷

La conexión entre las neuronas se puede dar en un sentido sin bucle y con bucle, en esta última la salida de una neurona puede ser la entrada de otra neurona, ya sea en el mismo nivel o en niveles previos. A estos dos tipos de conexiones se les conoce como red conectada hacia adelante y red conectada hacia atrás [8].

A continuación, se enlistan algunas de las topologías más comunes y se muestran sus esquemas en *Figura 21*:

- Perceptrón de dos capas: es el tipo de topología más simple, tiene una capa de entrada en la que la salida de cada neurona reproduce su propia entrada y una capa de salida. En esta topología cada neurona de la capa de entrada está conectada con las neuronas de la capa de salida. Su ley de aprendizaje es ajustar los pesos de las entradas con el fin de obtener la salida deseable.
- Adeline: esta tipología es análoga al perceptrón, como diferencias se tiene que a las entradas del exterior o de otras neuronas se les agrega otra entrada adicional llamada 'bias', la señal de salida es +1 o -1, ya sea que la señal de salida esté o no por encima del umbral.

¹⁷ Obtenido de [8]

- Red de Hopfield: es una red de una sola capa de neuronas en la que todas las neuronas están conectadas entre sí, la cual se puede llamar como red retroalimentada o recursiva, donde de los pesos pueden ser positivos o negativos [62].

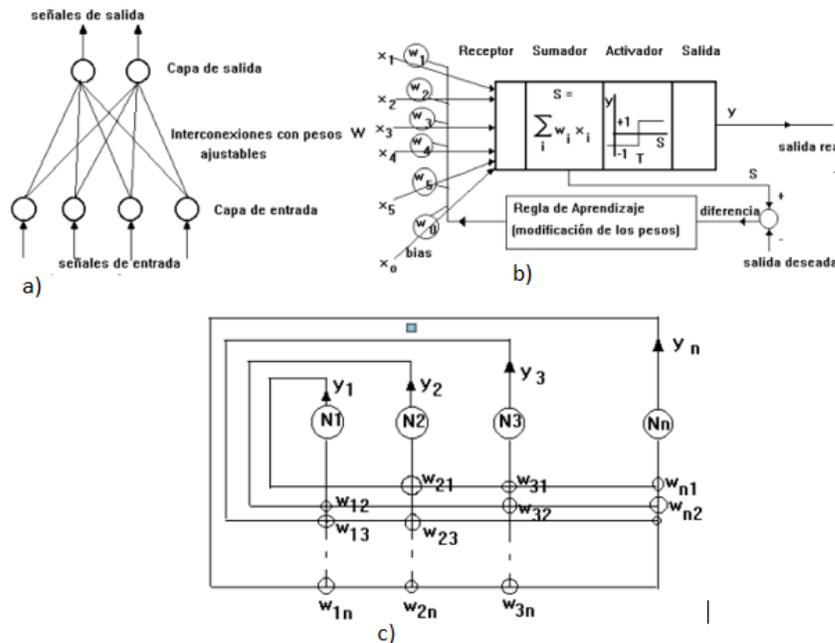


Figura 21 Topologías comunes. a) Perceptrón b) Adeline c) Hopfield¹⁸

Mecanismos de aprendizaje

Los mecanismos de aprendizaje son aquellos que determinarán la forma en que será entrenada la red neuronal artificial, es decir, la forma en que la red comenzará a procesar los datos también llamada regla de aprendizaje. Esencialmente existen dos categorías de mecanismos de aprendizaje, éstas son: aprendizaje supervisado y aprendizaje no supervisado [61].

En el caso del aprendizaje supervisado, se cuenta con un conjunto de datos experimentales los cuales constan de entradas y sus respectivas salidas. Una vez que se obtuvieron estos datos se ingresan a la red neuronal para que aprenda el comportamiento de las variables y comience a determinar los valores de los pesos entre

¹⁸ Obtenido de [62]

las conexiones, para obtener como resultado las respuestas deseadas. Habiendo reducido el error entre las salidas de la red y las salidas de la base de datos, se fijan los pesos y se dice que la red está entrenada. Cabe destacar que para que se puedan obtener predicciones reales la base de datos debió haber sido una muestra representativa del proceso que se está modelando [61].

En cambio, el aprendizaje no supervisado es aquel en que la red neuronal intenta determinar el patrón, las regularidades, correlaciones o categorías entre las entradas y las salidas por sí sola. Dependiendo de la red neuronal y su aplicación, distintos tipos de aprendizaje se deben de seleccionar, además de determinar el criterio de parada, en donde se defina cuál será la forma en que se detendrá el aprendizaje o entrenamiento (por tiempo, por cálculo de error, por número de iteraciones, etc.) [63].

Algunos tipos de aprendizaje supervisado:

- ❖ Aprendizaje por corrección de error: en este tipo de aprendizaje los pesos se cambian en función del error que existe respecto a la salida obtenida y la salida requerida (p.e. la regla de aprendizaje del perceptrón, la regla Delta, y la regla multicapa), dependiendo de la regla utilizada será la forma en que se toma en cuenta el error.
- ❖ Aprendizaje reforzado: en el caso del aprendizaje reforzado, la supervisión se centra sólo en decir si la respuesta obtenida fue correcta o no, manipulando los pesos por medio de probabilidades.
- ❖ Aprendizaje estocástico: en este aprendizaje los pesos son cambiados aleatoriamente hasta encontrar el que mejor se adapte al objetivo deseado.

Ejemplos de aprendizaje no supervisado:

- ❖ Hebbian: es la base de muchas reglas de aprendizaje, en esta regla se asume que, si dos neuronas tienen el mismo estado, ya sea activo o inactivo, el peso de conexión entre éstas aumenta.
- ❖ Aprendizaje competitivo y de banco: esta regla está orientada a la clasificación de la información de entrada, de tal forma que, si se reconoce un patrón que pertenezca a patrones anteriores, se asimila como uno más, en cambio, si el

patrón no se reconoce se cambian los pesos de las conexiones para que sea reconocido como un nuevo patrón [63].

Validación de la red neuronal

Una vez que se han obtenido los pesos de las conexiones entre las neuronas y que se han fijado, se necesita verificar que la red neuronal pueda resolver los problemas para los que fue diseñada y, con ese propósito, se tiene una base de datos distinta a la que se ocupó para entrenar a la red, para validar que las soluciones que determine la red neuronal sean las más apropiadas [63].

METODOLOGÍA

En este capítulo se mostrará la forma en que se trabajó para llegar al objetivo planteado. A continuación, se muestra un esquema de las actividades principales en la *Figura 22*, donde se comienza con la creación de la base de datos tanto para experimentos simulados como para experimentos realizados directamente en la máquina de inyección; se realizará el entrenamiento de la RNA y se elegirán los parámetros de la misma que tengan un mejor desempeño; después se realizará un acoplamiento con los optimizadores a utilizar y se pondrán en marcha para seleccionar los conjuntos de parámetros que disminuyan la deflexión de la pieza caso de estudio; posteriormente se experimentará en la máquina de inyección con esos parámetros y se realizará la medición para verificar la disminución de la deflexión para cada una de las direcciones.

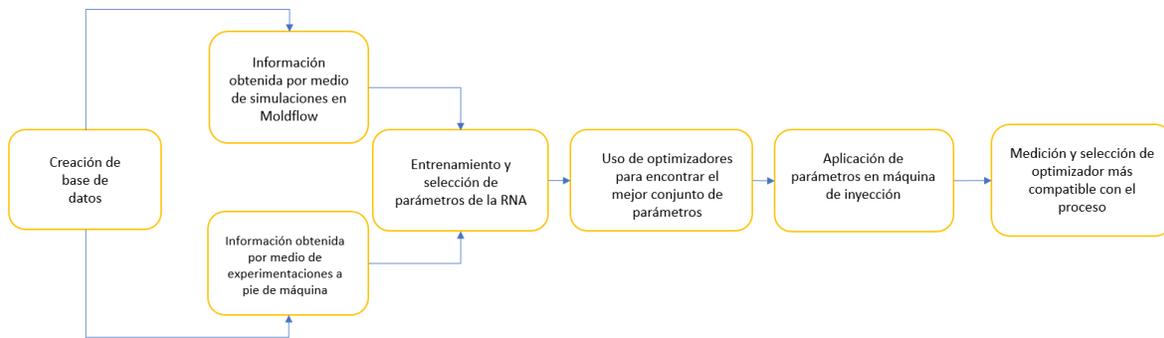


Figura 22 Esquema de actividades

Descripción de la pieza caso de estudio

La pieza caso de estudio, llamada por los diseñadores ‘Oreja’, forma parte de una estructura arquitectónica, la cual se muestra en la *Figura 23*. Ésta tiene como objetivo unir los nodos de la estructura con troncos de bambú; se aprecia en la *Figura 24* que la pieza ‘oreja’ está completada por dos piezas iguales ensambladas. La pieza presenta deflexiones en distintas direcciones, las cuales se muestran en la *Figura 25* en distintas vistas.



Figura 23 Aplicación de la pieza caso de estudio



Figura 24 Pieza caso de estudio 'Oreja'



Figura 25 Deflexiones en la pieza vista frontal y oblicua

Materiales por analizar

Para este trabajo se tomará en cuenta un sólo material, tanto para las simulaciones como para las experimentaciones a pie de máquina. El material es provisto por la marca Celanex perteneciente a Celanese, el número de identificación 5202 (las características principales se muestran en la *Tabla 3* e información más completa se puede encontrar en la hoja técnica que forma parte del *Anexo 1*). Debido a sus propiedades, el material fue elegido como compatible con la aplicación de la pieza, el Celanex 5202 es un poliéster reforzado con 15% de vidrio que mejora el brillo superficial con excelentes propiedades mecánicas, de procesabilidad, y estabilidad de color bajo condiciones de calor y exposición a rayos UV.

Tabla 3 Propiedades más importantes de Celanex 5202

<u>Propiedad</u>	<u>Valor</u>
<i>Densidad</i>	1440 [kg/cm ³]
<i>Coefficiente de fluencia</i>	25 [g/10min]
<i>Módulo de Young</i>	6100 [MPa]
<i>Temperatura de fusión</i>	250 [°C]

Dentro del proceso de inyección de plásticos son necesarios ciertos parámetros que son obtenidos a través del proveedor del material, las temperaturas del cañón, del molde, de secado, así como el tiempo de secado, las cuales se muestran en la *Tabla 4*.

Tabla 4 Condiciones de procesamiento de Celanex 5202

<u>Temperaturas en el cañón</u>	
<i>Zona 1</i>	230-250 [°C]
<i>Zona 2</i>	235-255 [°C]
<i>Zona 1</i>	235-255 [°C]
<i>Zona 1</i>	240-260 [°C]
<i>Boquilla</i>	250-265 [°C]

<u>Condiciones de secado</u>	
<i>Tiempo</i>	4 [h]
<i>Temperatura</i>	120-130 [°C]
<i>Humedad</i>	
<i>máxima</i>	0.02 %
<i>permisible</i>	

Determinación de parámetros influyentes en la deflexión de la pieza

En el proceso de inyección de plásticos existen muchas variables que influyen en los defectos de las piezas, como se mencionó en la introducción de este proyecto, además de que, a través de la investigación realizada, se identificaron algunas de las variables más influyentes en la deflexión, tales como la temperatura del molde (TM), temperatura

de masa fundida (TF), presión de inyección (PI), presión de sostenimiento (PS), tiempo de enfriamiento (TE), tiempo de sostenimiento (TS), así como la velocidad de inyección (VI) y, por consiguiente, el tiempo de inyección (TI) [3], [4], [15], [16], [64].

Debido a que, para cada situación, es decir, para cada molde, material y máquina, las variables que influyen en los defectos son distintas, se requiere determinar la influencia de cada una de las variables; para ello se hace uso de algunas herramientas como el diseño de experimentos. La experimentación de este paso tiene dos vertientes, una de ellas tiene su base en las simulaciones que se hicieron en Moldflow Adviser, mientras que la otra utiliza los datos provistos por experimentaciones hechas a pie de máquina.

Para poder verificar la influencia de las variables, se decidió que se tomarían en cuenta aquellas que pudieran ser controladas a través del software y fueran compatibles con los parámetros que se pueden controlar a pie de máquina, encontrándose que éstas eran: TM, TF, TE, TI, TS, PS.

En este caso, el diseño de experimentos ortogonal L8 fue el elegido para observar lo dicho anteriormente. Tomando en cuenta dos niveles de tratamiento para cada uno de los factores o parámetros de proceso definidos por la ficha técnica del material (TM, TF) o la capacidad de la máquina y el tamaño de la pieza (TI, TE, TS, PS), además, tomando la deflexión como la variable de estudio; estos datos son mostrados en la *Tabla 5*, los cuales fueron obtenidos en su totalidad de forma teórica, es decir, aquellos recopilados por el proveedor.

Tabla 5 Niveles de tratamiento de parámetros del proceso de inyección de plásticos

<u>Parámetro</u>	<u>Nivel 1</u>	<u>Nivel 2</u>
<i>TM [°C]</i>	65	110
<i>TF [°C]</i>	237	271
<i>TI [s]</i>	3	10
<i>TE [s]</i>	42	84
<i>TS [s]</i>	5	10
<i>PS [MPa]</i>	25	50

Creación de base de datos para la red neuronal artificial

Para la creación de la base de datos de la red neuronal que se planeó se realizarán dos tipos de base de datos, la primera de ellas con datos obtenidos a partir de softwares especializados en el proceso de inyección de plásticos, como lo es Moldflow ®; por otro lado, la creación de una base de datos a partir de datos obtenidos a pie de máquina, en la Unidad de Alta Tecnología de la Facultad de Ingeniería, en Juriquilla, Querétaro, imágenes que se muestran en la *Figura 26*.



Figura 26 Máquina de Inyección UAT-FI

El objetivo de realizar distintos tipos de base de datos es evaluar la predicción de la red neuronal, verificar, a partir de datos obtenidos a través de simulaciones o de datos obtenidos con experimentación real, cuál presenta un mejor desempeño.

La base de datos se creará siguiendo un diseño de experimentos que tomará en cuenta las variables influyentes determinadas en el paso anterior de la experimentación, y que será usado para disminuir el número de experimentos sin perder información sobre el comportamiento de las variables y de las respuestas.

Selección de parámetros de la red neuronal artificial

Las redes neuronales artificiales son definidas, entre otras cosas, por su topología, es decir, por el número de neuronas, el número de capas ocultas, la regla de aprendizaje y la función de activación, entre otras. Estas variables requieren ser determinadas para cada proceso estudiado.

Para cumplir con el objetivo planteado en el párrafo anterior, se realizaron diseños de experimentos que determinaran qué niveles de tratamiento fueron los que mejor desempeño mostraban, analizados a partir de evaluadores como el MSE, MAE y el coeficiente de correlación lineal de Pearson (R).

La selección de estos parámetros se realizó completamente en el software Matlab, donde se escribió el código para la red neuronal y se pudieron configurar los parámetros mencionados anteriormente; la selección se determinó usando un diseño de experimentos L16, donde cada uno de los factores cuenta con cuatro niveles de tratamiento. Se seleccionó este diseño debido a que en la investigación se encontró que se experimentaba con al menos 2 neuronas en las capas ocultas para cada neurona de la capa de entrada, al tener 6 neuronas de entrada se decidió realizar el experimento desde 11 hasta 17 neuronas para observar si más neuronas por capa se comportan de mejor manera.

Mientras que, para la regla de aprendizaje y la función de activación, fueron determinadas por aquellas que el software era capaz de utilizar y sabiendo en el caso de la función de activación, que mientras más suave sea la curva que se utiliza mejores resultados se obtendrán; por otro lado, las reglas de aprendizaje utilizadas fueron seleccionadas teniendo en cuenta que son mejoras de otras reglas de aprendizaje, en donde se solucionaron problemas en los cálculos, por ejemplo. En la *Tabla 6* se muestran los factores y los niveles elegidos para este diseño de experimentos.

Tabla 6 Niveles de tratamiento de parámetros de la red neuronal

<u>Parámetro</u>	<u>Nivel 1</u>	<u>Nivel 2</u>	<u>Nivel 3</u>	<u>Nivel 4</u>
<i>Número de neuronas capa oculta 1</i>	11	13	15	17
<i>Número de neuronas capa oculta 2</i>	11	13	15	17
<i>Regla de aprendizaje</i>	trainbfg	trainoss	trainrp	trainr
<i>Función de activación capa 1</i>	logsig	radbas	radbasn	tansig
<i>Función de activación capa 2</i>	logsig	radbas	radbasn	tansig

Técnicas de optimización ocupadas

Para poder seleccionar las técnicas de optimización fue necesario basarse en la información obtenida a partir de la investigación realizada durante el proyecto. Como se menciona en capítulos anteriores, existen una gran variedad de técnicas de optimización, por ejemplo, las que están basadas en el comportamiento de seres vivos al buscar alimento, reproducirse e, incluso, en la evolución de éstos.

Dentro de la investigación realizada se encontró que el trabajo del Dr. Mirjalili [39], [51] sobre el desarrollo de técnicas de optimización basadas en el comportamiento de animales, es de mucha importancia al crear distintos algoritmos capaces de encontrar mínimos o máximos globales en un espacio de posibilidades limitado, mismos que plasmó en códigos de programación en Matlab y que decidió compartirlos con cualquiera que estuviera interesado en su trabajo.

De esta forma, se retomaron los códigos provistos por el Dr. Mirjalili para acoplarlos a la red neuronal que se venía trabajando en Matlab.

RESULTADOS Y DISCUSIÓN

Información obtenida a través de simulaciones

Determinación de parámetros influyentes en la deflexión de la pieza

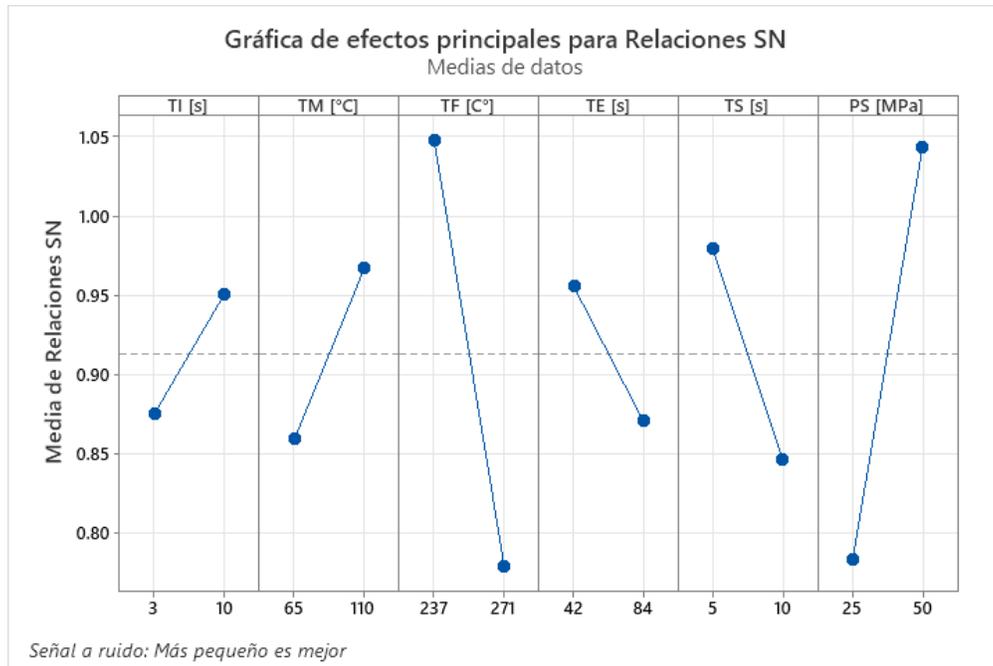
Durante la experimentación hecha a través de las simulaciones, se obtuvieron los resultados de deflexión mostrados en la *Tabla 7*, además del análisis de las respuestas señal-ruido mostrados en la *Tabla 8* junto con sus gráficas mostradas en la *Gráfica 1*.

Tabla 7 Arreglo ortogonal L8 experimentaciones hechas con Moldflow'Dir. Y'

<u>Corridas</u>	<u>TI [s]</u>	<u>TM [°C]</u>	<u>TF [°C]</u>	<u>TE [s]</u>	<u>TS [s]</u>	<u>PS [MPa]</u>	<u>Deflexión [mm]</u>
1	3	65	237	42	5	25	0.902
2	3	65	237	84	10	50	0.890
3	3	110	271	42	5	50	0.884
4	3	110	271	84	10	25	0.942
5	10	65	271	42	10	25	0.928
6	10	65	271	84	5	50	0.904
7	10	110	237	42	10	50	0.870
8	10	110	237	84	5	25	0.884

Tabla 8 Tabla de respuesta para las relaciones S-N

<u>Nivel</u>	<u>TI</u>	<u>TM</u>	<u>TF</u>	<u>TE</u>	<u>TS</u>	<u>PS</u>
	[s]	[°C]	[°C]	[s]	[s]	[MPa]
1	0.8757	0.8597	1.0474	0.9556	0.9798	0.7835
2	0.9511	0.9671	0.7794	0.8712	0.8470	1.0433
<i>Delta</i>	0.0753	0.1075	0.2680	0.0845	0.1328	0.2598
<i>Clasificar</i>	6	4	1	5	3	2



Gráfica 1 Efectos principales para relaciones S-N

Se observa en la *Tabla 8* las relaciones señal-ruido, donde indican que el factor que principal influencia tiene sobre la deflexión es la temperatura de masa fundida junto con la presión de sostenimiento, dejando al tiempo de enfriamiento como uno de los factores que menos impacto tiene sobre la deflexión. Con esta información valdría la pena realizar la base de datos excluyendo al tiempo de enfriamiento, sin embargo, un análisis de señal-ruido no puede tomar en cuenta las interacciones entre factores, por ende, el tiempo de enfriamiento seguirá siendo parte de la base de datos.

Medición de la deflexión de forma virtual y real

Se muestra en la *Figura 27*, encerrados en rojo, los puntos de apoyo que se seleccionaron para determinar la deflexión en la dirección 'X' y 'Y' en la pieza, para que posteriormente sea posible comparar la forma de medición de la información obtenida de las simulaciones y de las experimentaciones hechas a pie de máquina; para la dirección 'X' se tomaron solamente en cuenta los puntos que se encuentran en la mitad de la pieza, es decir en el eje 'Y', mientras que para la dirección 'Y' se tomaron en cuenta los tres puntos. Estos puntos se toman en cuenta debido a que son los que tienen contacto durante el ensamble de la pieza.

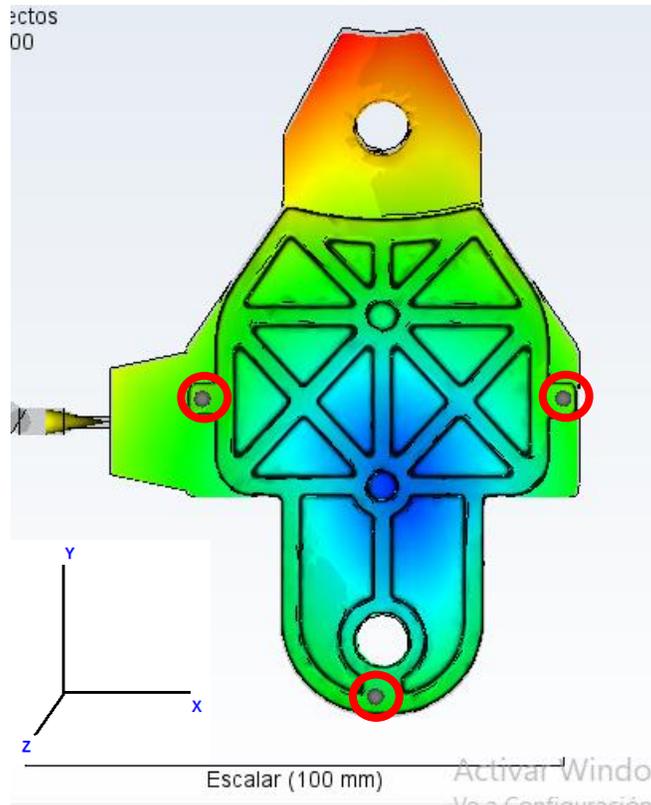


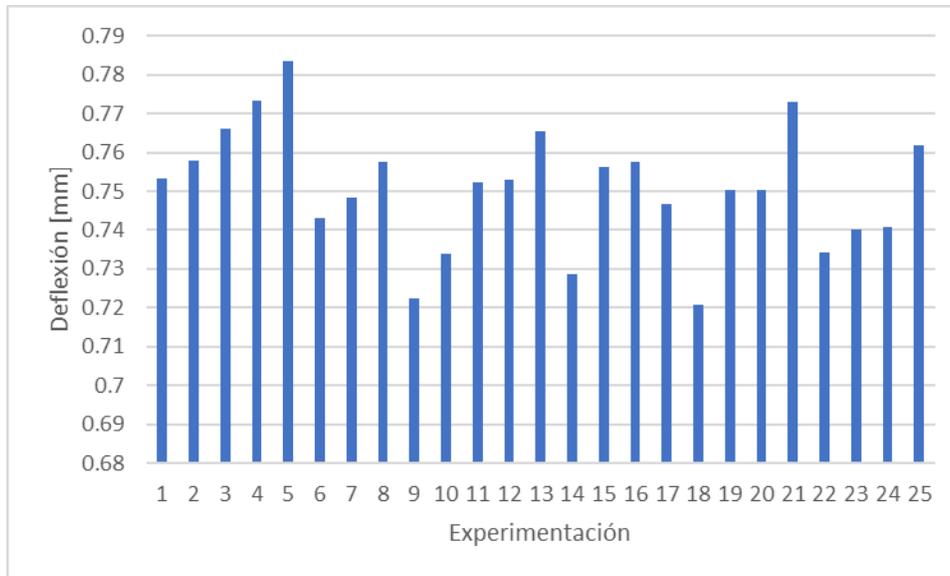
Figura 27 Forma de medición de la deflexión en las simulaciones

Creación de base de datos para la red neuronal artificial

La base de datos fue creada a partir de un diseño de experimentos y en el software Moldflow; en este caso, tomando en cuenta los seis factores que serían utilizados y el catálogo de Taguchi disponible¹⁹, se decidió utilizar el arreglo L25, en donde se cuenta con el mayor número de niveles de tratamiento para el número de factores utilizados, además, se eligió un rango de valores que contemplara solamente los valores internos del rango anteriormente ocupado, es decir, aquellos valores que se encuentran en intervalos cerrados. Los datos obtenidos se muestran en la *Gráfica 2*.

La decisión de utilizar un diseño de experimentos toma en cuenta la disminución del número de experimentos sin perder información, teniendo como referencia distintas investigaciones en donde se ocuparon pocos experimentos [15].

¹⁹ Catálogo obtenido de <https://support.minitab.com/es-mx/minitab/18/help-and-how-to/modeling-statistics/doe/supporting-topics/taguchi-designs/catalogue-of-taguchi-designs/#132-21-49>



Gráfica 2 Base de datos Moldflow

Selección de parámetros de la red neuronal artificial

Una vez creada la base de datos, se comenzó con la experimentación sobre los parámetros de la red neuronal artificial; como se mencionó anteriormente, se realizó un diseño de experimentos L16 (Tabla 9), para determinar la configuración de la red neuronal con mejor desempeño, para ello, se realizaron modificaciones al código de programación de la RNA. En la Figura 28 se muestra el código y se subraya la parte que se modifica a través de cada corrida del experimento.

```

red=feedforwardnet([10,13], 'trainbr');
red.trainParam.epochs=(1000);
red.trainParam.mu=0.1;
red.trainParam.mu_dec=0.1;
red.trainParam.mu_inc=10;
red.layers{1}.transferFcn='logsig';
red.layers{2}.transferFcn='logsig';
configure(red, input, targets);
red.divideParam.trainRatio=90/100;
red.divideParam.valRatio=5/100;
red.divideParam.testRatio=5/100;
[red, tr]=train(red, input, targets);

```

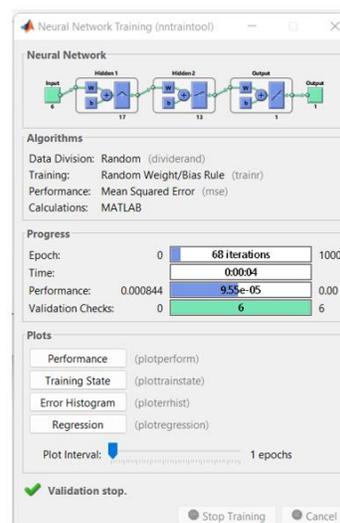


Figura 28 Código de la RNA en Matlab

En la *Figura 28* se muestran distintos renglones del código, así como una pantalla de Matlab donde se realizó un entrenamiento de la RNA. En el primero de ellos se configura una red neuronal del tipo conectada hacia adelante, con dos capas ocultas que son representadas por los números entre corchetes y, después de éstos, el tipo de regla de aprendizaje con la que se entrenará RNA. En el renglón 2, se muestra el número de iteraciones o épocas que se configuran para la RNA, en los renglones 3,4 y 5 se selecciona el factor de aprendizaje para modificar los pesos entre las conexiones, así como su factor de decremento y el factor de incremento respectivamente.

Tabla 9 Arreglo ortogonal L16 para selección de parámetros de RNA

<u>Corridas</u>	<u>NC1</u>	<u>NC2</u>	<u>FAC1</u>	<u>FAC2</u>	<u>RE</u>
1	11	11	logsig	logsig	trainbfg
2	11	13	radbas	radbas	trainoss
3	11	15	radbasn	radbasn	trainrp
4	11	17	tansig	tansig	trainr
5	13	11	radbas	radbasn	trainr
6	13	13	logsig	tansig	trainrp
7	13	15	tansig	logsig	trainoss
8	13	17	radbasn	radbas	trainbfg
9	15	11	radbasn	tansig	trainoss
10	15	13	tansig	radbasn	trainbfg
11	15	15	logsig	radbas	trainr
12	15	17	radbas	logsig	trainrp
13	17	11	tansig	radbas	trainrp
14	17	13	radbasn	logsig	trainr
15	17	15	radbas	tansig	trainbfg
16	17	17	logsig	radbasn	trainoss

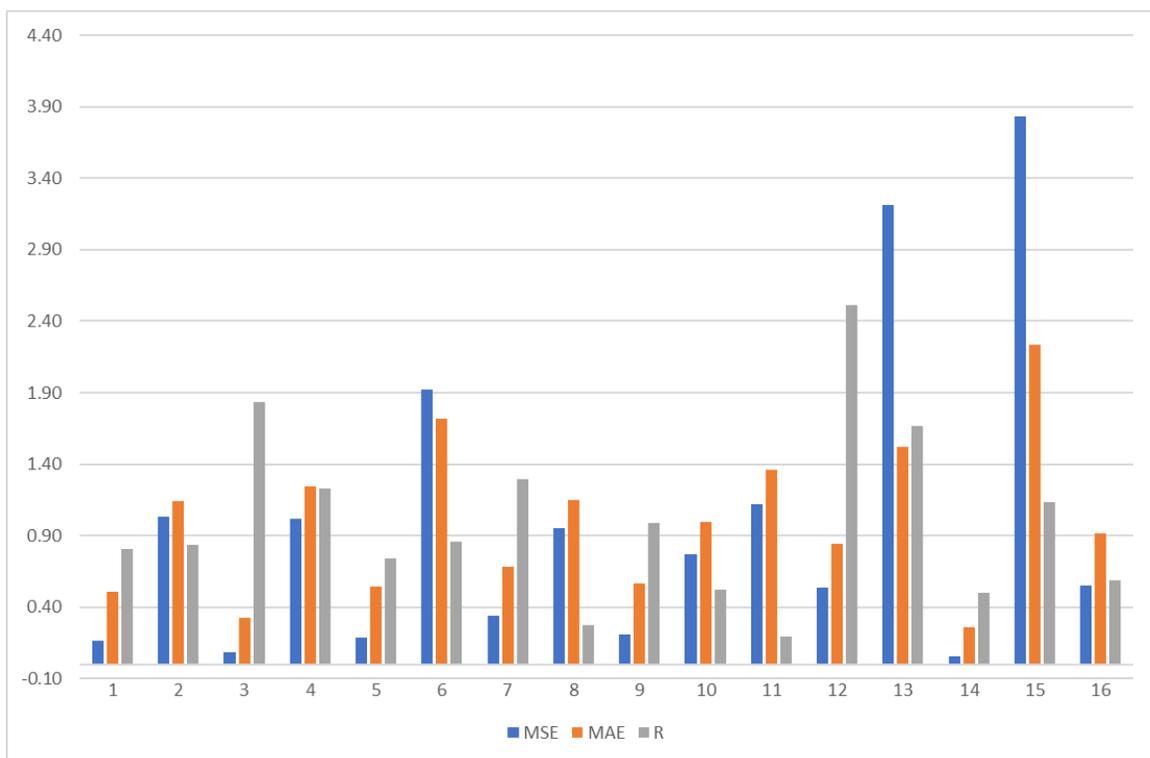
Notas: NC: número de neuronas por capa, FA: función de activación, RE: regla de entrenamiento

En los renglones 6 y 7 se configuran la función de activación o de transferencia de la capa oculta 1 y capa oculta 2. En el renglón 8 se configuran las bases de datos, así como

el nombre de la red; en los renglones 9, 10 y 11 se selecciona el porcentaje de los datos que se ocuparan para entrenar, validar y probar la RNA respectivamente. Por último, en el renglón 12 se entrena a la red neuronal con las configuraciones anteriores.

Posteriormente, se continuó con el diseño de experimentos, explicado anteriormente, utilizando un sólo valor de referencia y 6 repeticiones; calculando los evaluadores, se obtuvieron los datos presentados en la *Gráfica 3*.

Se observa en los datos que existen dos configuraciones que tienen los valores más bajos del MSE y el MAE, es decir, que la respuesta es la más cercana a aquella obtenida a través de Moldflow, como lo son la configuración 3 y la 14, mientras que existe otra configuración que tiene el valor más cercano al 1.0 en el coeficiente de correlación de Pearson; es decir, que es esta configuración en la que el metamodelo que arroja la RNA es más cercano a la simulación, la número 12. Cabe resaltar que, los valores mostrados en la *Gráfica 3* son valores normalizados con respecto al promedio, para una mejor visualización.



Gráfica 3 Desempeño de las configuraciones de RNA

Puesta en marcha de los algoritmos de optimización

Una vez determinados los parámetros influyentes, la base de datos y la configuración de la red neuronal artificial, se requiere poner a prueba los algoritmos de optimización para determinar cuál de ellos presenta un mejor desempeño; esto se observará a partir de la deflexión más pequeña a la que llegue el optimizador. Se muestran los datos en las *Tablas 10, 11 y 12*.

Tabla 10 Conjunto de parámetros obtenidos a partir de distintas configuraciones de la RNA optimizador Lobos Grises

<u>C</u>	<u>TI</u> [s]	<u>TM</u> [°C]	<u>TF</u> [°C]	<u>TE</u> [s]	<u>TS</u> [s]	<u>PS</u> [MPa]	<u>Def. Predicha</u> [mm]
3	10.0	87	271	42.00	5.0	48.84	0.738
3	9.0	110	243	84.00	6.3	50.00	0.734
3	4.1	110	264	42.89	5.1	48.36	0.726
12	3.0	110	240	53.78	9.7	26.57	0.717
12	10.0	110	237	77.92	10.0	43.77	0.680
12	6.2	110	260	61.10	8.4	25.32	0.667
14	9.6	102	240	60.59	10.0	32.43	0.745
14	3.0	110	271	84.00	8.7	50.00	0.739
14	3.0	80	271	49.79	10.0	48.60	0.738

Tabla 11 Conjunto de parámetros obtenidos a partir de distintas configuraciones de la RNA optimizador Ballenas grises

<u>C</u>	<u>TI</u> [s]	<u>TM</u> [°C]	<u>TF</u> [°C]	<u>TE</u> [s]	<u>TS</u> [s]	<u>PS</u> [MPa]	<u>Def. Predicha</u> [mm]
3	9.4	110	271	55.40	7.6	50.00	0.727
3	7.2	110	252	58.40	6.7	50.00	0.738
3	9.2	110	244	84.00	6.2	50.00	0.734
12	7.4	94	251	66.68	9.2	26.48	0.681
12	9.9	100	251	84.00	7.0	50.00	0.697
12	7.4	94	251	66.68	9.2	26.48	0.681
14	9.5	103	239	62.60	10.0	31.80	0.745
14	3.0	110	271	84.00	8.7	50.00	0.739
14	3.2	81	271	49.29	10.0	50.00	0.738

Tabla 12 Conjunto de parámetros obtenidos a partir de distintas configuraciones de la RNA optimizador Hormigas León

C	TI [s]	TM [°C]	TF [°C]	TE [s]	TS [s]	PS [MPa]	Def. Predicha [mm]
3	10.0	87	271	42.00	5.0	48.73	0.738
3	9.0	110	243	84.00	6.3	50.00	0.734
3	4.1	110	264	49.26	5.3	49.88	0.726
12	10.0	110	237	77.91	10.0	43.86	0.680
12	6.2	110	260	60.97	8.4	25.29	0.667
12	10.0	65	237	74.32	6.6	47.85	0.697
14	4.4	77	237	84.00	5.0	25.00	0.745
14	10.0	71	237	84.00	7.3	27.87	0.738
14	3.0	98	237	79.81	10.0	49.75	0.748

Para la puesta a prueba de los algoritmos, es necesario realizar distintas corridas de cada uno sabiendo que al ser procesos aleatorios las respuestas serán distintas en cada uno, por lo que se busca la mejor respuesta. Se seleccionaron tres corridas para cada una de las configuraciones y cada uno de los algoritmos, se hicieron las corridas y se registró la deflexión predicha por la RNA con el conjunto de parámetros elegido por los algoritmos, tal como se muestra en las tablas anteriores.

Se puede observar en la *Tabla 13* que en el promedio de las deformaciones calculadas por la RNA con los conjuntos de parámetros proporcionados por los algoritmos de optimización es menor que aquel calculado con los datos de la base de datos. Este es un resultado con el que se puede decir que los optimizadores están disminuyendo la deflexión por lo menos un 4%.

Por otro lado, evaluando cada uno de los optimizadores por separado, se encuentra que el de hormigas león tuvo en promedio una mejor disminución del 4.23%, además, junto con el optimizador de lobos grises, tuvo una disminución máxima del 11.18% con respecto a la base de datos generada para entrenar a la red neuronal artificial; estos resultados se muestran en la *Tabla 14*.

Tabla 13 Promedios de deformaciones en base de datos y optimizaciones

<i>Deflexión promedio [mm]</i>		
<u>Base de datos</u>	<u>Optimizadores</u>	<u>Disminución</u> %
0.751	0.712	4.14

Tabla 14 Evaluación por separado de cada optimizador

<u>Optimizador</u>	<u>Def. Prom.</u> [mm]	<u>Def mín.</u> [mm]	<u>% Disminución</u> prom	<u>% Disminución</u> máx
<i>Lobos grises</i>	0.720	0.667	4.06	11.18
<i>Ballenas grises</i>	0.720	0.681	4.11	9.34
<i>Hormigas león</i>	0.719	0.667	4.23	11.18

Información obtenida a través de experimentaciones hechas a pie de máquina

En el caso de la experimentación a pie de máquina es necesario que las condiciones de preproceso sean alcanzadas, una de ellas es la medición de humedad y el secado, como se planteó en la *Tabla 4*. La humedad sólo puede llegar a 0.02%, para ello fue necesario el secado del material en un deshumidificador de la marca Motan (*Figura 29 A*) a una temperatura de 130 [°C], por un total de cuatro horas; en cada hora se midió la humedad con el medidor de humedad de la marca y modelo DSH-50-10 (*Figura 29 B*) para verificar que se llegara a la indicada por el proveedor, la cual se muestra en la *Tabla 15*.



Figura 29 Equipos para deshumidificar (A) y para medir la humedad en el polímero (B)

Tabla 15 Humedad a través del tiempo de secado

Horas de secado	% Humedad
1	0.57
2	0.38
3	0.17
4	0.00

Determinación de rangos de parámetros de proceso

Para poder determinar los parámetros que son influyentes dentro del proceso de inyección de plásticos con experimentaciones hechas a pie de máquina, es necesario determinar los rangos de los parámetros que conllevan una buena calidad en la pieza, es decir, los rangos de VI, TM, TF, TS, TE y PS. Estos rangos son provistos por la metodología del moldeo científico, a través de ella se conocen los rangos a partir de los cuales las variaciones naturales del propio proceso no influyen en la calidad de la pieza.

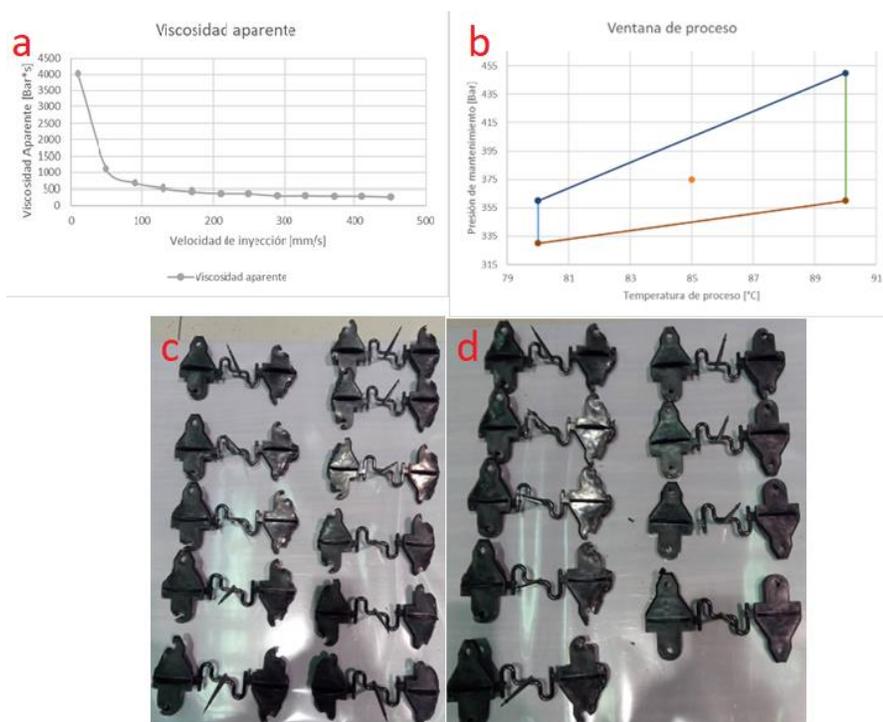


Figura 30 Curva de viscosidad (a) Ventana cosmética de proceso (b) piezas obtenidas por curva de viscosidad (c) y ventana cosmética de proceso (d)

De los pasos del moldeo científico se optó por sólo hacer cuatro de ellos, la curva de viscosidad, la ventana cosmética de proceso, el sello de compuertas y el tiempo de enfriamiento, debido a que éstos proporcionan el rango de variables importantes. En la *Figura 30* se muestran las gráficas de la curva de viscosidad, así como de la ventana cosmética de proceso, además se muestran algunas imágenes de las piezas obtenidas.

En el paso de curva de viscosidad fue posible obtener el rango de velocidades de inyección, los cuales fueron 290-370 [mm/s], ya que en estos se obtuvo menor variación en la viscosidad aparente; por otro lado, la ventana cosmética de proceso fue útil para encontrar los rangos de temperatura de molde en conjunto con la presión de sostenimiento, los cuales son 80-90[°C] y 360-450 [Bar], respectivamente.

Para determinar el rango del tiempo de sostenimiento se realizó el estudio de sello de compuertas; en cambio, para determinar el rango del tiempo de enfriamiento se realizó el paso que lleva por título el mismo nombre (en la *Figura 31* se muestran los gráficos obtenidos, así como piezas inyectadas para realizar estos pasos).

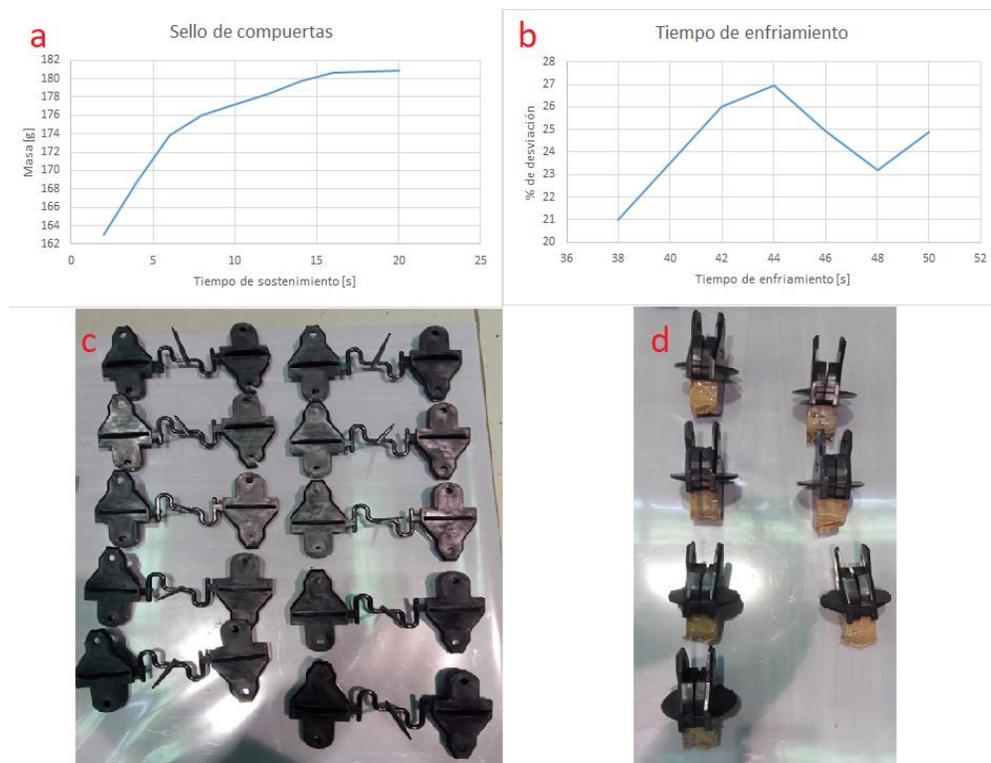


Figura 31 Sello de compuertas (a), tiempo de enfriamiento (b), piezas de sello de compuertas (c) y piezas de tiempo de enfriamiento (d)

En el caso del rango del tiempo de sostenimiento se determinó que la masa de la pieza no cambió desde 16-20[s], mientras que para el tiempo de enfriamiento se observó una variación del 21-26% en los tiempos de enfriamiento de 38-50 [s], por lo que se elegirá ese rango.

Por otro lado, se tuvo que determinar el rango de la temperatura de masa fundida, para lo cual se realizaron pruebas mediante purgas para observar la consistencia del material; sin embargo, debido a que el husillo cuenta con un mezclador en la parte posterior, la temperatura configurada en el controlador de la máquina estaba 25 [°C] por debajo de la medida con el termómetro de bayoneta en el material, por lo que se decidió que la variable que modulara la temperatura de masa fundida fuera el número de revoluciones por minuto. Se realizaron pruebas para determinar la relación entre éstas, y se encontró que con una velocidad de 105 unidades por minuto (UPM) la temperatura era de 253[°C] y a 125 [UPM] 266 [°C], temperaturas que se encuentran dentro del rango que el proveedor sugiere.

Medición de la deflexión

Como se mencionó anteriormente, la deflexión en la pieza caso de estudio está presente en dos direcciones, como primera forma de medición se utilizará el ensamble para el que fue diseñada y se medirá la distancia que se forma en la abertura del conjunto de piezas, tal como se muestra en la *Figura 32*.

Por otro lado, para medir físicamente la deflexión en la otra dirección fue necesario el uso de un brazo de medición de coordenadas marca CAM2 Measure v10.4 (*Figura 33*) y fueron elegidos 5 puntos a través de la pieza, de tal forma que se creara una circunferencia imaginaria, tal como se muestra en la *Figura 34*; esta circunferencia servirá como referencia para determinar el aumento o disminución de la deflexión, si la circunferencia tiende a infinito, se demostrará que la deflexión disminuye y, por el contrario, si la circunferencia tiende a cero, se estará demostrando que la deflexión está aumentando.

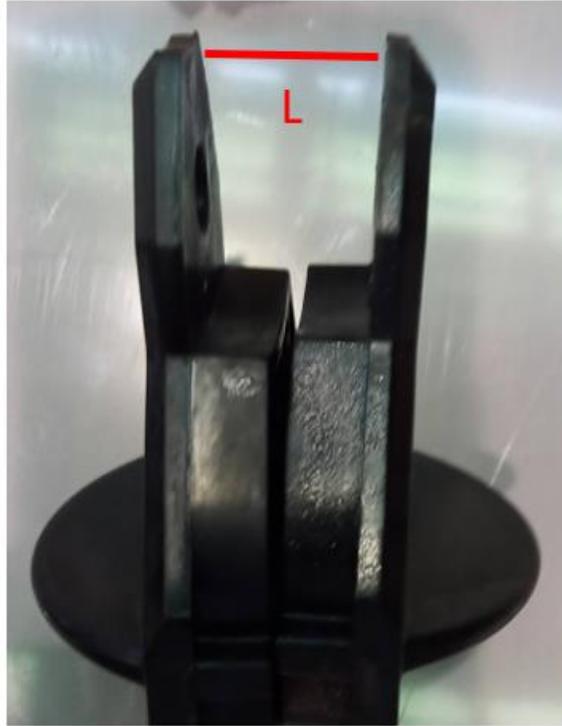


Figura 32 Forma de medición de la deflexión en la dirección 'Y'

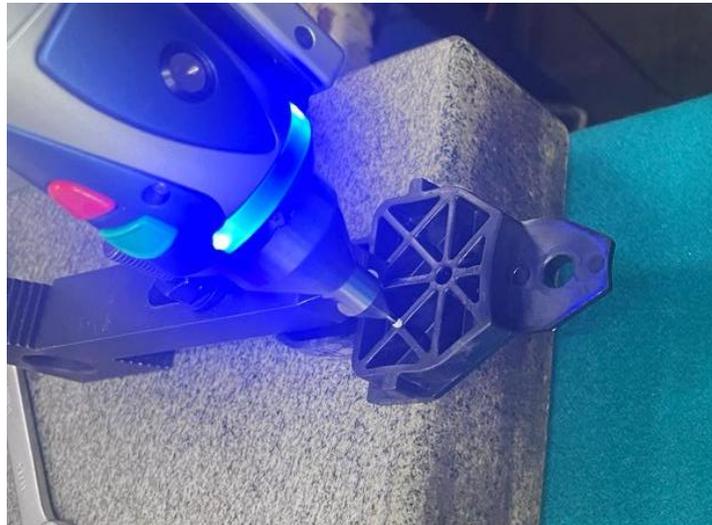


Figura 33 Medición de la deflexión en dirección 'X'

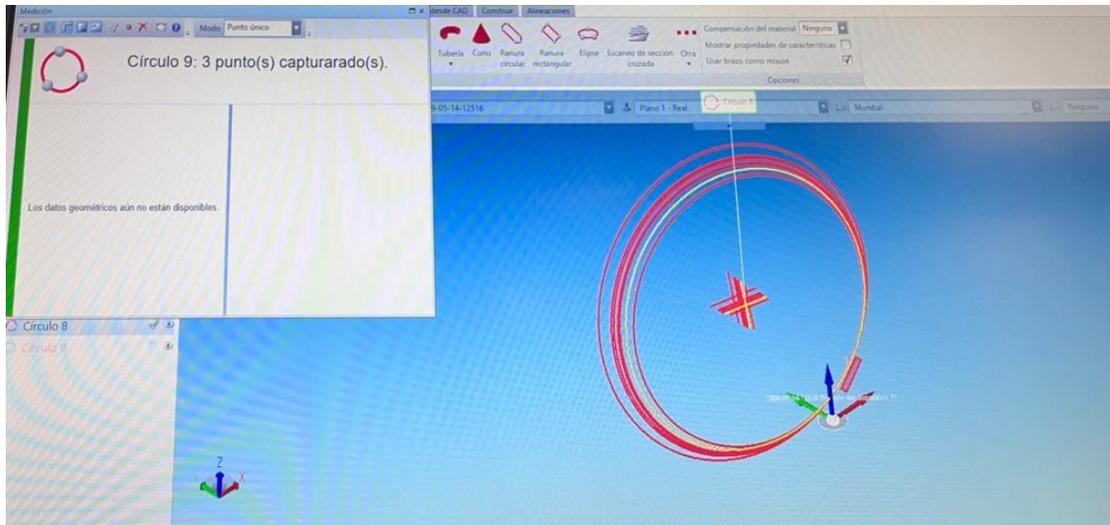


Figura 34 Circunferencia imaginaria medida en pieza

Determinación de la influencia de los parámetros deflexión en dirección 'Y'

Al igual que la determinación de la influencia de los parámetros en el caso de las simulaciones, para la experimentación a pie de máquina se utilizó un diseño de experimentos L8 (Tabla 16) para determinar la influencia de los parámetros. Los análisis se muestran a continuación.

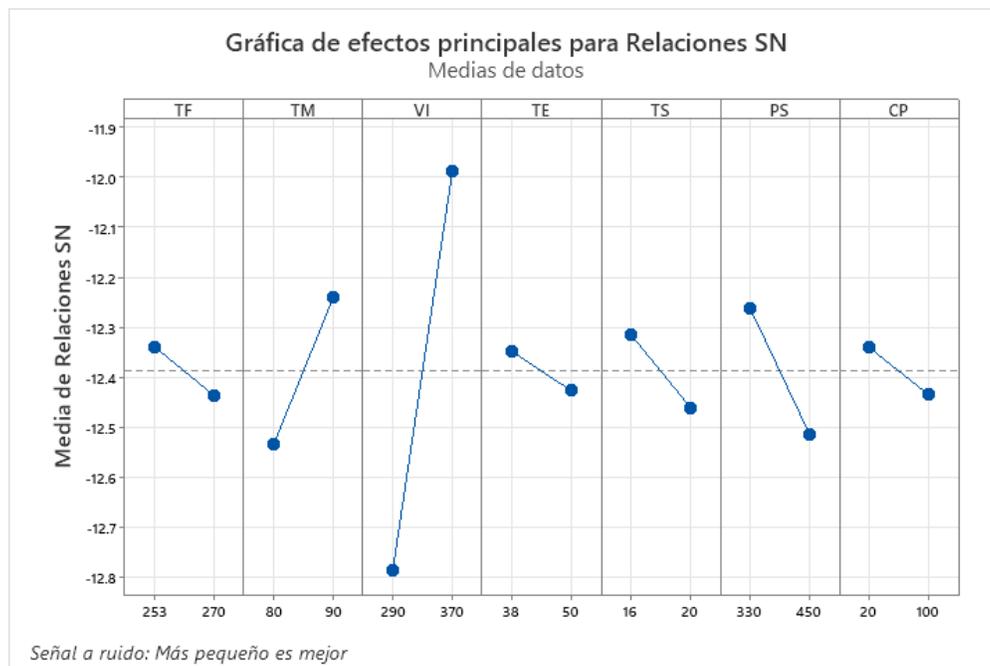
Tabla 16 Arreglo ortogonal L8 experimentaciones hechas a pie de máquina 'Dir. Y'

Corrida	Valores de niveles por corrida							Deflexión
	TF	TM	VI	TE	TS	PS	CP	
	[°C]	[°C]	[mm/s]	[s]	[s]	[MPa]	[Bar]	[mm]
1	253	80	290	38	16	330	20	4.330
2	253	80	290	50	20	450	100	4.472
3	253	90	370	38	16	450	100	3.974
4	253	90	370	50	20	330	20	3.772
5	270	80	370	38	20	330	100	3.974
6	270	80	370	50	16	450	20	4.140
7	270	90	290	38	20	450	20	4.286
8	270	90	290	50	16	330	100	4.322

Se determinó mediante las relaciones S-N que el factor que mayor impacto tiene en la deflexión medida en la pieza es la velocidad de inyección, seguido de la presión de sostenimiento y de la temperatura del molde, tal como se muestra en la *Tabla 17* y *Gráfica 4*, demostrándose de la misma forma que el tiempo de enfriamiento por sí solo tampoco tiene una alta repercusión en la respuesta analizada.

Tabla 17 Respuesta para relaciones de S-N

<u>Nivel</u>	<u>TF</u> [°C]	<u>TM</u> [°C]	<u>VI</u> [mm/s]	<u>TE</u> [s]	<u>TS</u> [s]	<u>PS</u> [MPa]	<u>CP</u> [Bar]
1	-12.34	-12.53	-12.79	-12.35	-12.31	-12.26	-12.34
2	-12.44	-12.24	-11.99	-12.43	-12.46	-12.51	-12.43
<i>Delta</i>	0.10	0.29	0.80	0.08	0.15	0.25	0.09
<i>Clasificar</i>	5	2	1	7	4	3	6



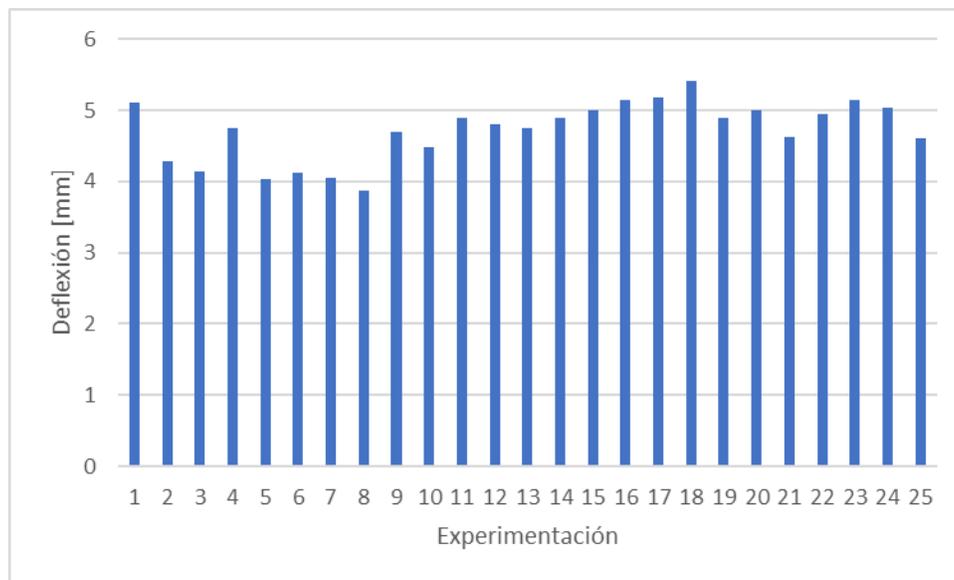
Gráfica 4 Efectos principales para relaciones S-N

Una vez hechas las experimentaciones para determinar las variables más influyentes, se decidió que debido a que la contrapresión es uno de los valores que junto con tiempo de enfriamiento no provocan grandes cambios en la deflexión de la pieza, se seleccionará el menor valor para disminuir el tiempo de ciclo por debajo de los 60 [s].



Figura 35 Piezas obtenidas para la base de datos

Por lo anterior, la base de datos se realizó tomando en cuenta los parámetros TF, TM, VI, TS, TE y PS. La base de datos se presenta en la *Gráfica 5*. En la *Figura 35* se muestran algunas de las piezas obtenidas para la base de datos.

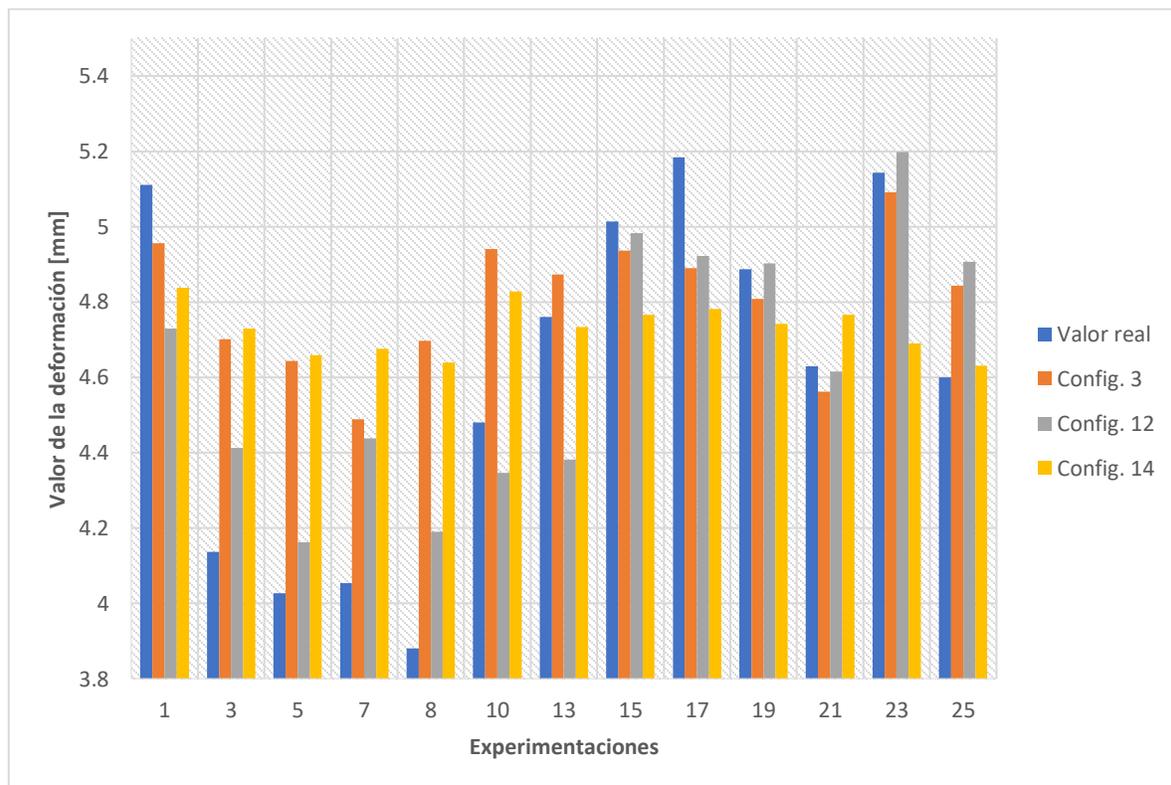


Gráfica 5 Base de datos experimentaciones hechas a pie de máquina

Optimización de la deflexión en dirección 'Y'

Con la base de datos hecha, fue posible comenzar con la disminución de la deflexión a través de los optimizadores elegidos, para ello, también se seleccionaron las configuraciones de la red neuronal artificial con mejores desempeños, es decir, la configuración 3, 13 y 14.

Para observar el desempeño de la red neuronal artificial se realizó la *Gráfica 6*, que muestra las distintas configuraciones que se utilizaron y el valor real medido, visualizando un buen desempeño de parte de las 3 configuraciones; sin embargo, también se observa que en algunas experimentaciones todas las configuraciones distaron del valor real.

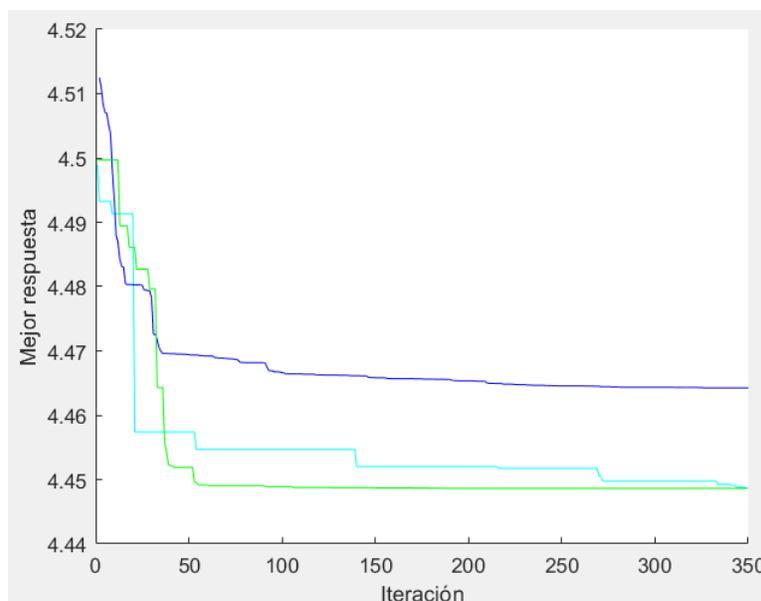


Gráfica 6 Desempeño de las configuraciones de la RNA

Se realizaron 350 iteraciones por cada uno de los optimizadores (Lobos, Ballenas y Hormigas) ya que, en experimentaciones hechas anteriormente, se observó que a partir de este número de iteraciones los valores no cambiaban. Debido a que todos los algoritmos utilizan procesos aleatorios, incluyendo la red neuronal artificial, para cada

una de las configuraciones se realizaron 5 corridas, de éstas se eligieron 3 que no tuvieran intervalos muy grandes en la temperatura de molde (ya que es el parámetro más difícil de modificar a pie de máquina) para poder disminuir el tiempo de experimentación.

En la *Gráfica 7* se muestra un ejemplo de cómo disminuye la deflexión a través de las iteraciones realizadas. Se muestra que a partir de la iteración 50, el optimizador que llegó a la convergencia primero fue el de hormigas león, que junto con el optimizador de lobos grises tuvieron la respuesta más baja.



Gráfica 7 desempeño de los optimizadores, Lobos grises (azul), Ballenas (rey) y Hormigas león (verde)

Las *Tablas 18, 19 y 20* muestran la configuración de parámetros que el optimizador propone para disminuir la deflexión, donde la columna de deflexión virtual es donde se muestra la deflexión que predice la red neuronal artificial; por otro lado, la siguiente columna muestra la deflexión que fue medida de forma real y la última columna muestra la variación que existe entre el valor predicho y el real. Las tablas se hicieron para cada uno de los optimizadores.

Tabla 18 Conjunto de parámetros obtenidos a partir de distintas configuraciones de la RNA optimizador Lobos grises

<u>C</u>	<u>TF</u> [°C]	<u>TM</u> [°C]	<u>VI</u> [mm/s]	<u>TE</u> [s]	<u>TS</u> [s]	<u>PS</u> [MPa]	<u>Def. Virtual</u> [mm]	<u>Def. real</u> [mm]	<u>Variación</u> %
3	119	85	290	50.00	16.2	330	4.486	4.767	05.89
3	114	90	370	50.00	16.5	427	4.472	4.927	09.22
3	106	90	315	50.00	16.0	422	4.468	4.330	03.18
12	125	87	366	41.97	19.5	384	2.859	4.387	34.83
12	125	84	322	45.26	16.0	407	3.039	4.453	31.76
12	107	88	291	49.21	17.0	333	2.785	3.900	28.59
14	123	88	337	50.00	16.0	411	4.575	4.077	12.23
14	125	85	370	39.56	19.3	345	4.449	4.310	03.22
14	125	83	370	50.00	16.0	348	4.255	3.967	07.27

Tabla 19 Conjunto de parámetros obtenidos a partir de distintas configuraciones de la RNA optimizador Ballenas grises

<u>C</u>	<u>TF</u> [°C]	<u>TM</u> [°C]	<u>VI</u> [mm/s]	<u>TE</u> [s]	<u>TS</u> [s]	<u>PS</u> [MPa]	<u>Def. Virtual</u> [mm]	<u>Def. real</u> [mm]	<u>Variación</u> %
3	122	85	290	48.17	16.8	344	4.489	4.243	05.78
3	110	89	327	50.00	16.4	396	4.498	3.867	06.32
3	105	88	309	44.10	16.2	330	4.506	3.520	28.01
13	125	88	360	45.58	20.0	384	3.154	4.017	21.47
13	105	86	370	45.72	17.4	416	3.280	3.990	17.81
13	109	89	314	47.85	16.8	330	2.844	3.873	26.57
14	116	80	290	38.00	179.0	369	4.767	3.920	21.60
14	119	86	370	45.58	17.4	349	4.464	3.777	18.20
14	125	90	370	45.73	18.7	450	4.360	3.917	11.32

Tabla 20 Conjunto de parámetros obtenidos a partir de distintas configuraciones de la RNA optimizador Hormigas León

<u>C</u>	<u>TF</u> [s]	<u>TM</u> [°C]	<u>VI</u> [°C]	<u>TE</u> [s]	<u>TS</u> [s]	<u>PS</u> [MPa]	<u>Def. Predicha</u> [mm]	<u>Def. Real</u> [mm]	<u>% de</u> <u>variación</u>
3	119	85	290	50.00	16.2	330	4.486	3.720	20.59
3	114	90	370	50.00	16.6	427	4.472	3.843	16.37
3	105	87	309	43.60	16.0	332	4.506	3.727	20.90
13	125	87	367	42.00	19.5	384	2.858	3.757	23.94
13	125	87	304	42.25	16.5	340	3.296	3.593	8.29
13	106	88	291	49.36	20.0	332	2.784	3.037	8.34
14	125	88	291	48.09	16.6	450	4.760	4.073	16.86
14	125	85	370	39.67	19.3	344	4.449	3.997	11.31
14	125	90	290	38.00	16.0	334	4.360	4.177	4.38

Con la información obtenida se puede observar que existe una variación entre el 3 y 34 % en la predicción de la red neuronal artificial, es decir, la deflexión virtual y la deflexión real medida en las piezas, sin embargo, se puede señalar que existió una disminución en la deflexión predicha por la configuración 13; además, se puede mostrar en la *Tabla 21* la disminución en la deflexión con respecto a la deflexión obtenida para crear la base de datos, es decir, se obtuvo un promedio de las deformaciones antes y después de utilizar los optimizadores, encontrando un 15.09% de disminución y hasta un 35.62%, considerando el promedio de las mediciones antes de la optimización y la configuración con el optimizador de hormigas león 13-3.

Tabla 21 Comparación de deformaciones entre la base de datos y la optimización

<u>Deflexión promedio [mm]</u>			
<i>Base de datos</i>	<i>Optimizadores</i>	<i>Disminución [%]</i>	<i>Disminución máxima [%]</i>
4.718	4.006	15.09	35.63

Se observa en la *Tabla 22* que el optimizador que mejor desempeño obtuvo fue el de hormigas león, tanto en promedio como la disminución máxima; por otro lado, el

optimizador de lobos grises obtuvo el peor resultado con un 7.86% de disminución promedio y un 17.32% de disminución máxima.

Tabla 22 Evaluación de optimizadores de forma individual

<u>Optimizador</u>	<u>Def. Prom.</u> [mm]	<u>Def mín.</u> [mm]	<u>% Disminución prom</u>	<u>% disminución máx</u>
<i>Lobos grises</i>	4.350	3.900	07.86	17.32
<i>Ballenas grises</i>	3.900	3.520	17.27	25.38
<i>Hormigas león</i>	3.770	3.040	20.09	35.62

Optimización de la deflexión en dirección 'X'

Como se realizó en la optimización de la deflexión en dirección 'Y', se comenzó con la determinación de los parámetros influyentes, para ello se realizó un diseño de experimentos L8 mostrado en la *Tabla 23*, mientras que los resultados se muestran en la *Tabla 24* y la *Gráfica 8*.

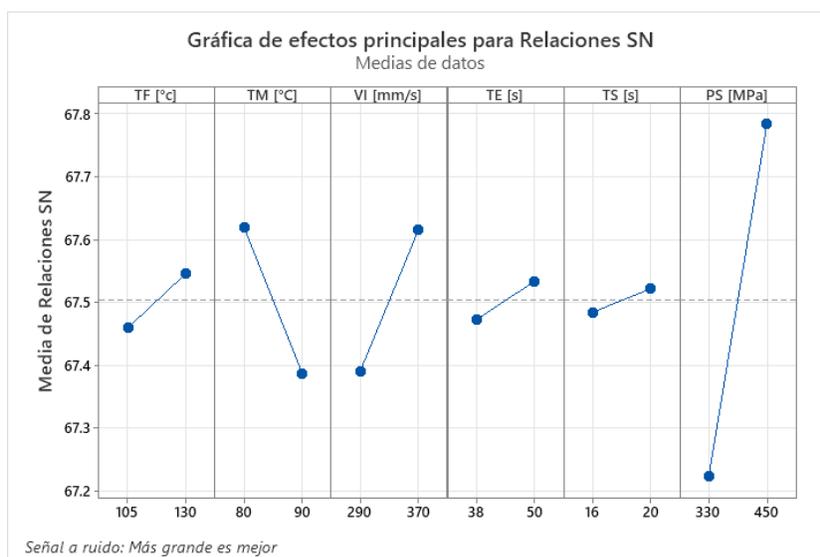
En este caso, se combinaron las deformaciones encontradas en ambas cavidades al sumarlas y obteniendo un promedio de cada una, tal como se realizó en la deflexión en la dirección 'Y'.

Tabla 23 Arreglo ortogonal L8 experimentaciones hechas a pie de máquina 'Dir. X'

<u>C</u>	<u>TF</u> [RPM]	<u>TM</u> [°C]	<u>VI</u> [mm/s]	<u>TE</u> [s]	<u>TS</u> [s]	<u>PS</u> [MPa]	<u>Diámetro</u> [mm]
<i>1</i>	105	80	290	38	16	330	<i>2348.44</i>
<i>2</i>	105	80	290	50	20	450	<i>2374.64</i>
<i>3</i>	105	90	370	38	16	450	<i>2345.98</i>
<i>4</i>	105	90	370	50	20	330	<i>2373.34</i>
<i>5</i>	125	80	370	38	20	330	<i>2291.12</i>
<i>6</i>	125	80	370	50	16	450	<i>2614.09</i>
<i>7</i>	125	90	290	38	20	450	<i>2474.05</i>
<i>8</i>	125	90	290	50	16	330	<i>2180.36</i>

Tabla 24 Tabla de respuesta para las relaciones señal-ruido

<u>Nivel</u>	<u>TF</u> [°C]	<u>TM</u> [°C]	<u>VI</u> [mm/s]	<u>TE</u> [s]	<u>TS</u> [s]	<u>PS</u> [MPa]
1	67.46	67.62	67.39	67.47	67.48	67.22
2	67.55	67.39	67.62	67.53	67.52	67.78
Delta	0.09	0.23	0.22	0.06	0.04	0.56
Clasificar	4	2	3	5	6	1

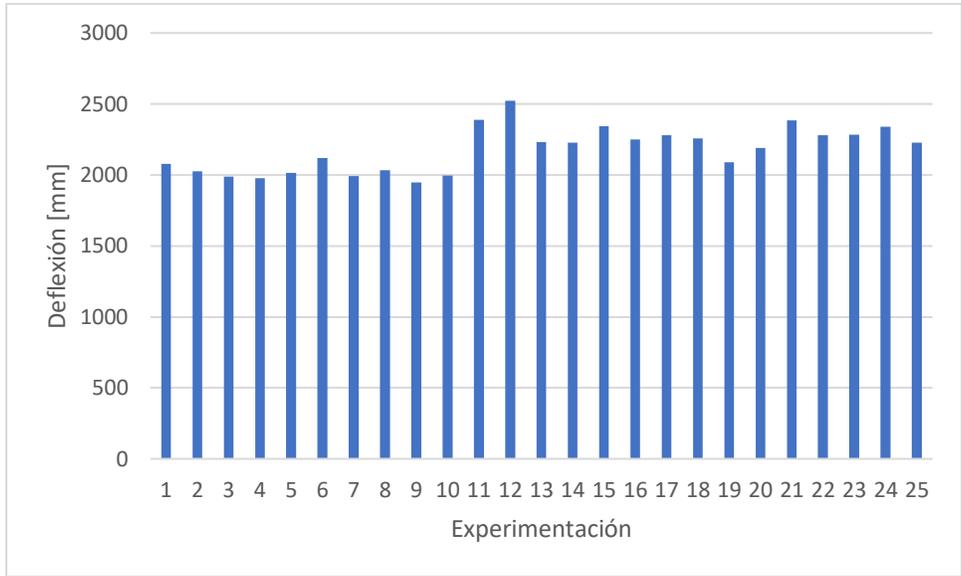


Gráfica 8 Efectos principales para las relaciones S-N

Se muestra que la presión de sostenimiento es la más influyente en la deflexión en dirección 'X', mientras que el tiempo de enfriamiento y de sostenimiento son los menos influyentes, sin tomar en cuenta las correlaciones entre los factores.

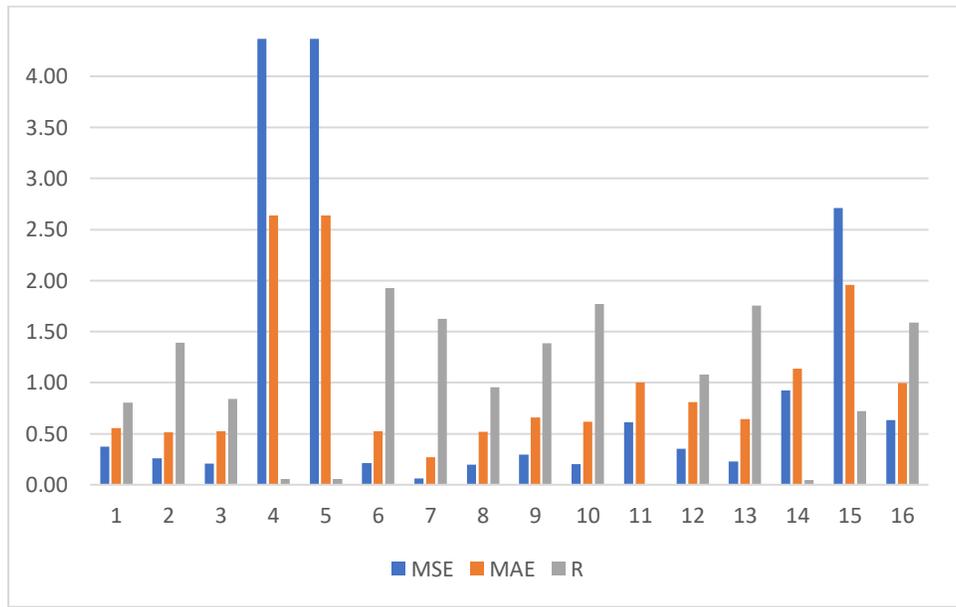
Una vez determinados los parámetros influyentes, se procedió a realizar la base de datos que se muestra en la *Gráfica 9* a partir de un arreglo ortogonal L25.

Para determinar los parámetros de la RNA se realizaron experimentaciones como las hechas anteriormente. En la *Gráfica 10* se muestran los evaluadores y las configuraciones con los mejores valores; de éstas, las que se eligieron fueron cuatro (6,7,8 y 10) para disminuir el número de experimentaciones y, así, el consumo de material en exceso, los evaluadores fueron normalizados con respecto al promedio para una mejor visualización.

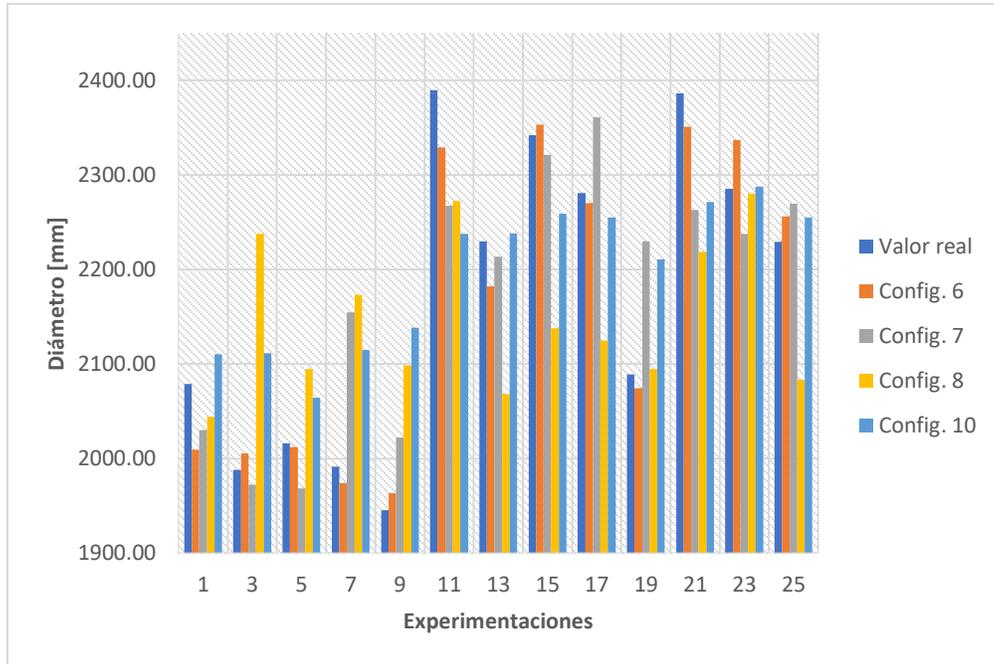


Gráfica 9 Base de datos experimentaciones hechas a pie de máquina dirección 'X'

Mientras que en la *Gráfica 11* se muestra el desempeño de las configuraciones seleccionadas, observando que la configuración 6 tiene valores muy cercanos al valor real, mientras que las configuraciones 7 y 8 tienen los valores más alejados, corroborando la evaluación de los parámetros mostrados en la *Gráfica 10*.

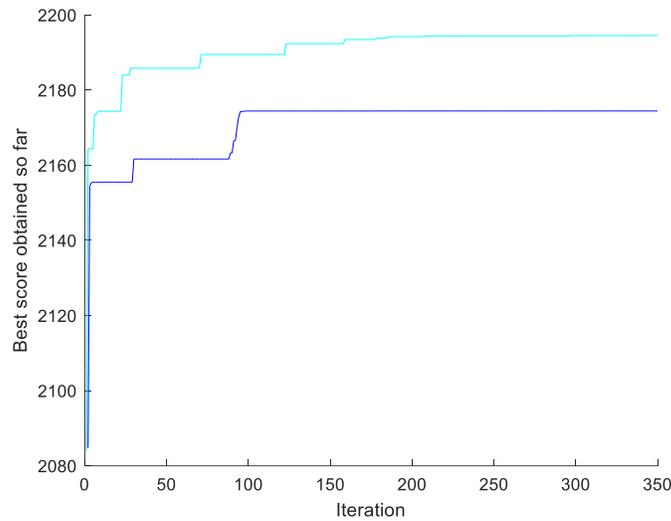


Gráfica 10 Evaluadores de configuraciones RNA



Gráfica 11 Desempeño de las configuraciones de la RNA

Tras haber creado la base de datos se continuó con la puesta en marcha de los optimizadores para disminuir la deflexión, y, en este caso, se realizaron cambios en el código de los optimizadores y se tomaron en cuenta solo dos de ellos (Lobos grises y Ballenas grises), debido a que no se encontró una función compatible con el optimizador de Hormigas león para poder utilizarlo. Se realizaron 350 iteraciones y, en la *Gráfica 12*, se observa el funcionamiento de los dos optimizadores, mostrando también que, mientras que el optimizador que llegó a la convergencia primero fue el de ballenas grises, el que obtuvo una mejor respuesta fue el de lobos grises.



Gráfica 12 desempeño de los optimizadores, lobos grises (cian) y ballenas grises (rey)

A continuación, se muestran los parámetros proporcionados por los dos optimizadores; cabe resaltar que sólo se utilizaron tres de las 5 corridas que se hicieron para cada una de las configuraciones de la RNA. En las *Tablas 25 y 26* se muestran tanto las configuraciones como la deflexión predicha por las RNA y la deflexión real.

Tabla 25 Conjunto de parámetros obtenidos a partir de distintas configuraciones de la RNA optimizador Lobos grises

<u>C</u>	<u>TF</u> [s]	<u>TM</u> [°C]	<u>VI</u> [°C]	<u>TE</u> [s]	<u>TS</u> [s]	<u>PS</u> [MPa]	<u>Def. Predicha</u> [mm]	<u>Def. Real</u> [mm]	% de <u>variación</u>
6	253.0	80	290	50.00	16.0	450	2833.90	2357.44	16.81
6	253.0	90	290	50.00	17.4	450	2438.90	2146.80	11.98
6	253.0	90	290	48.16	20.0	450	2616.70	2352.79	10.09
7	253.0	90	290	38.00	16.0	330	2370.80	2020.39	14.78
7	253.0	80	315	38.00	20.0	439	2359.80	2561.57	08.55
7	253.0	80	370	50.00	18.6	330	2211.50	2121.94	04.05
8	266.0	89	290	44.80	20.0	424	2316.00	2250.18	02.84
8	253.0	80	294	38.56	19.7	443	2277.30	2143.70	05.87
8	253.0	90	290	44.39	16.0	330	2194.50	2234.46	01.82
10	260.0	80	370	50.00	20.0	349	2274.00	2191.01	03.65
10	253.0	80	367	50.00	20.0	450	2556.90	2174.77	14.95
10	254.6	80	293	38.00	18.6	330	2464.40	2199.89	10.73

Tabla 26 Conjunto de parámetros obtenidos a partir de distintas configuraciones de la RNA optimizador Ballenas Grises

<u>C</u>	<u>TF</u> [s]	<u>TM</u> [°C]	<u>VI</u> [°C]	<u>TE</u> [s]	<u>TS</u> [s]	<u>PS</u> [MPa]	<u>Def. Predicha</u> [mm]	<u>Def. Real</u> [mm]	<u>% de</u> <u>variación</u>
6	253.0	90	290	50.00	17.4	450	2438.90	2146.8	11.98
6	253.0	90	290	48.17	20.0	450	2616.70	2352.8	10.09
6	253.0	80	370	50.00	16.0	450	2404.30	2184.3	09.15
7	266.0	90	370	38.00	20.0	409	2262.00	2141.5	05.33
7	253.0	90	290	38.00	16.0	330	2370.80	2020.4	14.78
7	253.0	80	336	38.00	20.0	450	2359.80	2254.5	04.46
8	253.0	80	290	49.68	19.9	348	2317.20	2265.9	02.21
8	263.0	89	307	45.03	18.5	353	2316.00	2190.9	05.40
8	261.0	80	343	40.08	17.8	367	2277.30	2109.4	07.37
10	253.0	80	370	50.00	20.0	450	2556.90	2209.8	13.57
10	266.0	90	370	38.00	16.0	450	2561.70	2419.6	05.55
10	262.7	80	290	38.00	18.6	330	2464.40	2237.4	09.21

Se muestra en las *Tablas 25 y 26* que existe una variación entre la deflexión real y la simulada desde 2.21% hasta 14.78%; por otro lado, en la *Tabla 27* se muestran las deformaciones promedio de la base de datos y de los datos obtenidos una vez aplicados los optimizadores, encontrando que hubo solo un aumento del 1.91% en el diámetro calculado, mientras que el aumento máximo presentado en la configuración 10-2 del optimizador de Lobos grises logró alcanzar un aumento del 17.58%.

Tabla 27 Deflexión en la dirección 'X'

<u>Deflexión promedio [mm]</u>			
<i>Base de</i>	<i>Optimizadores</i>	<i>Aumento</i>	<i>Aumento</i>
<i>datos</i>		<i>[%]</i>	<i>máximo [%]</i>
2178.67	2220.35	1.91	17.58

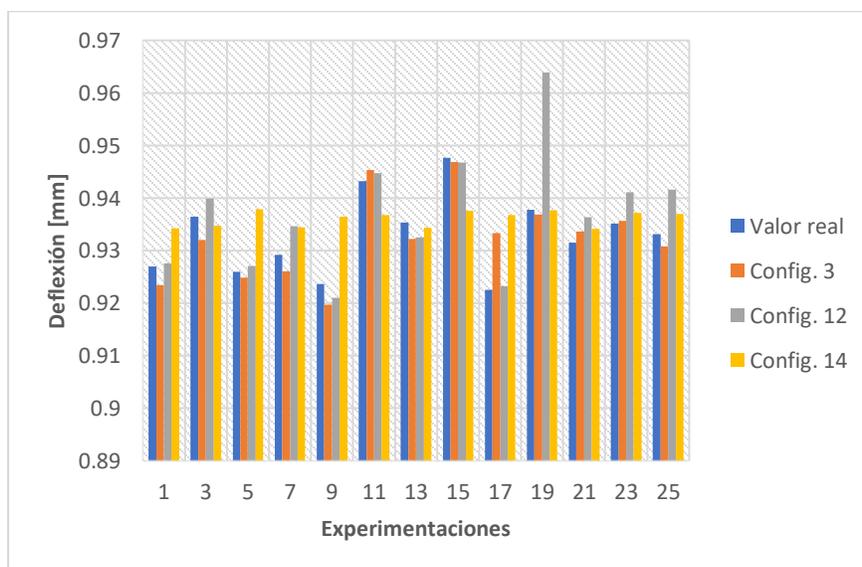
En la *Tabla 28* se muestra que el optimizador de ballenas grises solamente obtuvo un aumento del 1.49% de forma promedio y un 11.06% de aumento máximo, mientras que el optimizador de lobos grises tuvo mejores resultados.

Tabla 28 Evaluación de optimizadores de forma individual

<u>Optimizador</u>	<u>Def. Prom.</u> [mm]	<u>Def. mín.</u> [mm]	<u>% aumento prom</u>	<u>% aumento máx</u>
<i>Lobos grises</i>	2229.57	2561.57	2.34	17.58
<i>Ballenas grises</i>	2211.11	2419.60	1.49	11.06

Información obtenida por medio de simulaciones después del moldeo científico

Como se pudo observar en la parte anterior de este capítulo, es necesario determinar el rango en los que las variables pueden ser utilizadas, para hacerlo se utilizó el moldeo científico; debido a ello, la sección de la información obtenida a través de simulaciones tuvo que realizarse de nuevo, tomando en cuenta los rangos mostrados en la sección anterior y considerando que los rangos utilizados por primera vez no podían ser utilizados en las condiciones de operación de la máquina y de los equipos periféricos. A continuación, se muestra el desempeño de las configuraciones de la RNA en la *Gráfica 13* y los datos obtenidos con los rangos nuevos en las *Tablas 29, 30 y 31*.



Gráfica 13 Desempeño de las configuraciones de la RNA

Tabla 29 Conjunto de parámetros obtenidos a partir de distintas configuraciones de la RNA optimizador Lobos grises

<u>C</u>	<u>TF</u> [°C]	<u>TM</u> [°C]	<u>TI</u> [s]	<u>TE</u> [s]	<u>TS</u> [s]	<u>PS</u> [MPa]	<u>Def.</u> <u>Predicha</u> [mm]	<u>Def.</u> <u>Moldflow</u> [mm]	<u>Variación</u> %
3	266	90	0.23	43.04	19.18	37.48	0.929	0.803	15.62
3	265	90	0.24	50.00	18.99	33.65	0.922	0.808	14.07
3	257	90	0.25	38.00	16.03	34.54	0.948	0.824	14.99
12	253	80	0.23	47.89	18.15	45.00	0.893	0.814	9.80
12	258	80	0.21	38.01	16.46	41.47	0.900	0.805	11.80
12	266	80	0.22	38.36	17.16	43.22	0.909	0.828	9.73
14	253	90	0.21	44.28	19.79	33.00	0.929	0.805	15.38
14	253	80	0.21	48.35	19.86	33.00	0.933	0.810	15.15
14	266	90	0.23	44.97	20.00	45.00	0.932	0.809	15.20

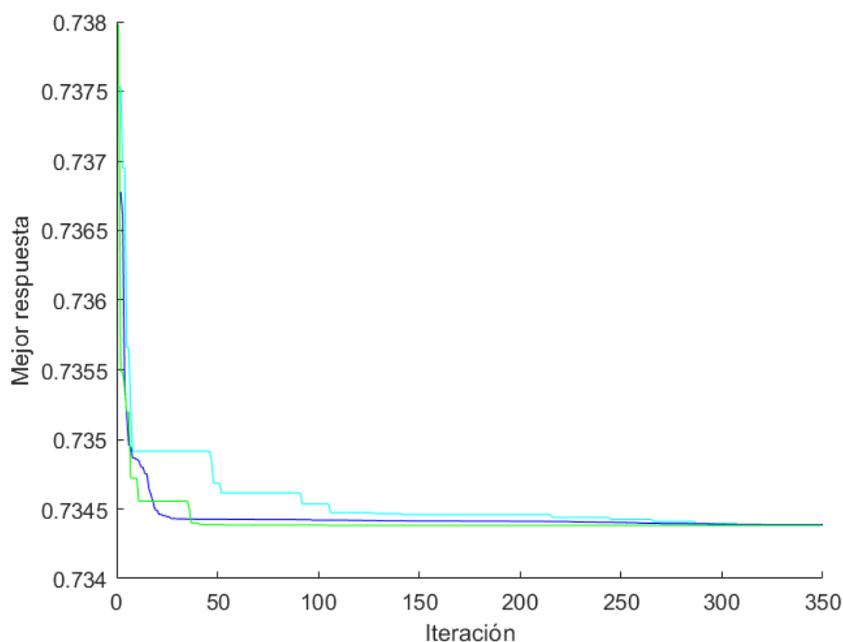
Tabla 30 Conjunto de parámetros obtenidos a partir de distintas configuraciones de la RNA optimizador Ballenas grises

<u>C</u>	<u>TF</u> [°C]	<u>TM</u> [°C]	<u>TI</u> [s]	<u>TE</u> [s]	<u>TS</u> [s]	<u>PS</u> [MPa]	<u>Def.</u> <u>Predicha</u> [mm]	<u>Def.</u> <u>Moldflow</u> [mm]	<u>Variación</u> %
3	266	90	0.23	42.68	17.32	38.04	0.927	0.807	14.78
3	255	90	0.23	44.29	20.00	43.54	0.949	0.788	20.43
3	253	90	0.24	47.87	17.70	36.01	0.926	0.805	15.10
12	255	88	0.24	48.67	18.74	38.19	0.912	0.801	13.90
12	266	87	0.23	38.00	18.85	43.68	0.901	0.802	12.33
12	263	90	0.23	50.00	20.00	45.00	0.910	0.809	12.48
14	264	90	0.25	50.00	20.00	38.73	0.929	0.824	12.70
14	259	90	0.23	38.00	18.44	35.90	0.929	0.798	16.44
14	266	90	0.23	44.99	20.00	45.00	0.932	0.809	15.20

Tabla 31 Conjunto de parámetros obtenidos a partir de distintas configuraciones de la RNA optimizador Hormigas león

<u>C</u>	<u>TF</u> [°C]	<u>TM</u> [°C]	<u>TI</u> [s]	<u>TE</u> [s]	<u>TS</u> [s]	<u>PS</u> [MPa]	<u>Def.</u> <u>Predicha</u> [mm]	<u>Def.</u> <u>Moldflow</u> [mm]	<u>Variación</u> %
3	266	90	0.23	43.14	19.08	37.69	0.922	0.808	14.07
3	256	90	0.21	50.00	16.00	44.99	0.948	0.789	20.19
3	257	90	0.25	38.00	16.00	34.40	0.925	0.804	15.04
12	263	90	0.21	45.27	17.26	43.22	0.916	0.805	13.73
12	253	80	0.23	47.87	18.16	45.00	0.893	0.814	9.80
12	257	80	0.21	38.00	16.42	41.67	0.900	0.805	11.79
14	253	87	0.25	40.37	18.78	33.57	0.929	0.794	17.01
14	253	80	0.21	48.40	19.79	33.00	0.933	0.794	17.45
14	266	90	0.23	45.01	20.00	45.00	0.932	0.809	15.20

En la *Gráfica 14* se muestra un ejemplo de cómo se comporta cada uno de los algoritmos con una configuración en la RNA; a través de las iteraciones comienza a disminuir la respuesta analizada, se observa que tanto el optimizador de ballenas grises como el de hormigas león llegan a la convergencia antes de las 50 iteraciones, llegando junto con el optimizador de lobos grises a la misma respuesta. Por otro lado, en la *Tabla 32* se muestra que existe una variación entre la deflexión predicha por la RNA y la obtenida en Moldflow, que va desde el 9 hasta el 20%, sin embargo, se muestra cómo la deflexión disminuye en comparación con la obtenida en la base de datos de Moldflow, por lo menos 12.59% comparando las predicciones con la base de datos.



Gráfica 14 comportamiento de la respuesta a través de las iteraciones. Lobos grises (cian), Ballenas grises (rey), Hormigas león (verde)

Tabla 32 Comparación de deflexión entre base de datos y optimizadores

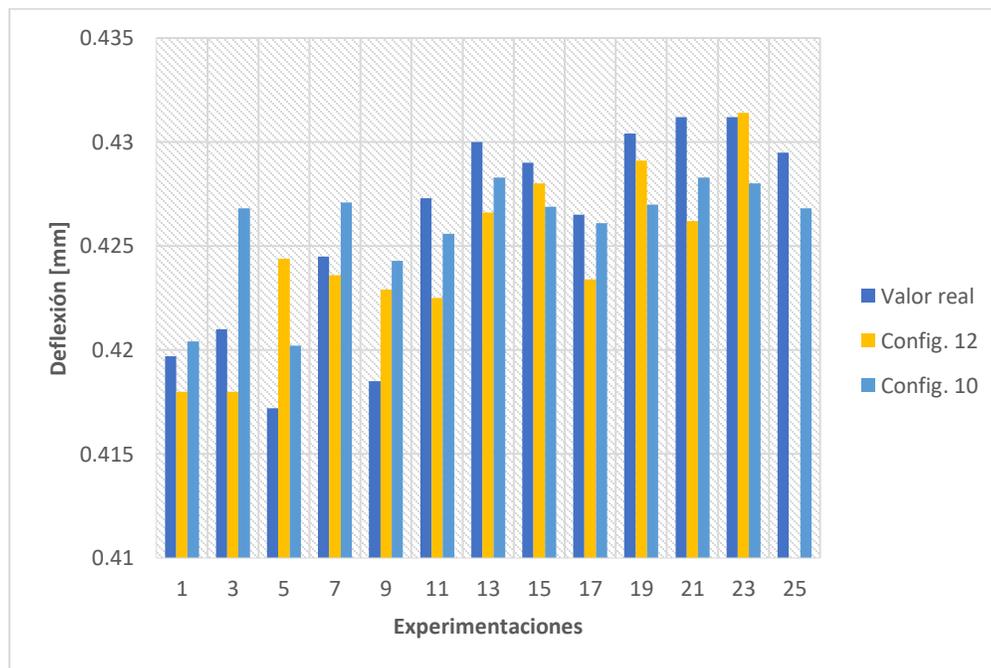
<u>Deflexión promedio [mm]</u>			
<i>Base de datos</i>	<i>Optimizadores</i>	<i>Moldflow</i>	<i>Disminución %</i>
0.935	0.922	0.806	12.59

Observando la *Tabla 33*, se muestra que el optimizador que mayor disminución promedio logró fue el de hormigas león, 14.21% de disminución, mientras que el optimizador de ballenas grises obtuvo la máxima disminución de 15.79%; no obstante, el optimizador de lobos grises obtuvo el menor desempeño.

Tabla 33 Evaluación desempeño de optimizadores

<u>Optimizador</u>	<u>Def. Prom.</u> [mm]	<u>Def mín.</u> [mm]	<u>% Disminución prom</u>	<u>% disminución máx</u>
<i>Lobos grises</i>	0.812	0.805	13.21	13.91
<i>Ballenas grises</i>	0.805	0.788	13.96	15.79
<i>Hormigas león</i>	0.802	0.789	14.21	15.65

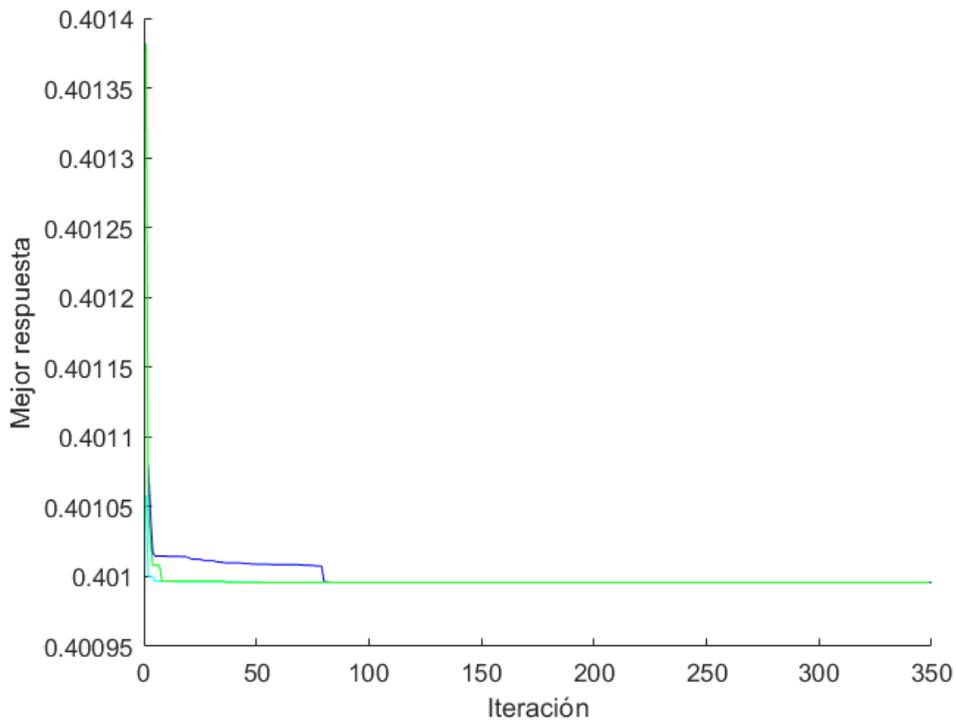
Para el caso de la disminución de la deflexión en la dirección en 'X' se realizó el mismo proceso que en el punto anterior, se tomó en cuenta una base de datos de 25 experimentaciones, se eligieron dos configuraciones de la RNA y se aplicaron los tres optimizadores. En la *Gráfica 15* se observa un buen desempeño de las configuraciones en la mayoría de los casos, verificando los datos arrojados por los evaluadores.



Gráfica 15 Desempeño de las configuraciones de la RNA

En la *Gráfica 16* se muestra el desempeño de los optimizadores, encontrando que los tres llegan a la misma respuesta y que, tanto el optimizador de hormigas león como el de lobos grises, llegan a la convergencia antes de las 50 iteraciones, mientras que el de ballenas grises lo hace hasta 70 iteraciones.

En las *Tablas 34, 35 y 36* se muestran los parámetros y las respuestas predichas por el modelado de la RNA y las obtenidas por medio de experimentaciones hechas en Moldflow, de la misma forma, se realiza la comparación entre las deformaciones predichas y las obtenidas mediante las experimentaciones mediante un cálculo de la variación.



Gráfica 16 Desempeño de los optimizadores

Tabla 34 Conjunto de parámetros obtenidos a partir de distintas configuraciones de la RNA optimizador Lobos grises

<u>C</u>	<u>TI</u>	<u>TM</u>	<u>TF</u>	<u>TE</u>	<u>TS</u>	<u>PS</u>	<u>Def.</u>	<u>Def.</u>	%
	[s]	[°C]	[°C]	[s]	[s]	[MPa]	<u>Pred.</u>	<u>Moldflow</u>	
							[mm]	[mm]	Variación
12	253	83.87	0.19	38	16	330	0.431	0.398	7.73
12	253.0	80.87	0.27	38.00	20.0	450.00	0.432	0.392	9.13
12	253.0	80.00	0.19	50.00	16.0	336.04	0.401	0.389	3.09
12	253.0	80.00	0.22	38.00	20.0	330.00	0.425	0.399	6.12
12	266.0	90.00	0.19	38.00	16.0	450.00	0.433	0.403	6.93
10	253.0	80.00	0.22	38.00	16.0	448.56	0.422	0.406	3.65
10	253.0	80.00	0.27	50.00	19.7	330.00	0.424	0.392	7.64
10	253.0	80.00	0.26	50.00	16.0	450.00	0.418	0.394	5.83
10	266.0	80.00	0.19	50.00	16.0	330.00	0.425	0.403	5.16
10	266.0	80.00	0.24	38.00	20.0	396.80	0.431	0.398	4.06

Tabla 35 Conjunto de parámetros obtenidos a partir de distintas configuraciones de la RNA optimizador Ballenas grises

<u>C</u>	<u>TI</u>	<u>TM</u>	<u>TF</u>	<u>TE</u>	<u>TS</u>	<u>PS</u>	<u>Def.</u>	<u>Def.</u>	% Variación
	[s]	[°C]	[°C]	[s]	[s]	[MPa]	<u>Pred.</u> [mm]	<u>Moldflow</u> [mm]	
12	253.0	83.85	0.19	38.00	16.0	330.0	0.431	0.398	7.73
12	253.0	80.88	0.27	38.00	20.0	450.00	0.432	0.392	9.13
12	253.0	80.00	0.19	50.00	16.0	335.94	0.401	0.389	3.09
12	253.0	80.00	0.22	38.00	20.0	330.00	0.425	0.399	6.12
12	266.0	90.00	0.19	38.00	16.0	450.00	0.433	0.403	6.93
10	253.0	80.00	0.21	38.00	16.0	437.79	0.422	0.399	5.48
10	253.0	80.00	0.27	50.00	19.7	330.00	0.424	0.392	7.64
10	266.0	80.00	0.27	49.85	16.0	450.00	0.418	0.403	3.68
10	266.0	80.00	0.19	50.00	16.0	330.00	0.425	0.403	5.16
10	266.0	80.00	0.24	38.00	20.0	397.24	0.431	0.398	4.06

Tabla 36 Conjunto de parámetros obtenidos a partir de distintas configuraciones de la RNA optimizador Hormigas León

<u>C</u>	<u>TI</u>	<u>TM</u>	<u>TF</u>	<u>TE</u>	<u>TS</u>	<u>PS</u>	<u>Def.</u>	<u>Def.</u>	% Variación
	[s]	[°C]	[°C]	[s]	[s]	[MPa]	<u>Pred.</u> [mm]	<u>Moldflow</u> [mm]	
12	253.0	83.85	0.19	38	16	330	0.431	0.398	7.73
12	253.0	80.88	0.27	38.00	20.0	450.00	0.432	0.392	9.13
12	253.0	80.00	0.19	50.00	16.0	335.94	0.401	0.389	3.09
12	253.0	80.00	0.22	38.00	20.0	330.00	0.425	0.399	6.12
12	266.0	90.00	0.19	38.00	16.0	450.00	0.433	0.403	6.93
10	253.0	80.00	0.22	38.00	16.0	448.23	0.422	0.399	5.38
10	253.0	80.00	0.27	50.00	19.7	330.00	0.424	0.392	7.64
10	253.0	80.00	0.26	50.00	16.0	450.00	0.418	0.394	5.83
10	266.0	80.00	0.19	50.00	16.0	330.00	0.425	0.403	5.16
10	266.0	80.00	0.24	38.00	20.0	395.14	0.431	0.398	4.06

Como se muestra en la *Tabla 37*, una vez utilizados los algoritmos de optimización fue posible disminuir hasta un 8.54% la deflexión en la dirección 'X' y en promedio un 6.34%. La deflexión máxima fue alcanzada por los tres optimizadores, sin embargo, en promedio quien más disminuyó la deflexión fue el optimizador de hormigas león, en un 6.47%, mostrado en la *Tabla 38*.

Tabla 37 Deflexión promedio para análisis de disminución (Moldflow)

		Deflexión promedio [mm]		
Base de datos	Optimizadores	Moldflow	Disminución [%]	Disminución máxima [%]
0.425	0.423	0.398	6.34	8.54

Tabla 38 Evaluación de los optimizadores

Optimizador	Def. Prom. [mm]	Def mín. [mm]	% Disminución prom	% disminución máx
<i>Lobos grises</i>	0.398	0.389	6.28	8.54
<i>Ballenas grises</i>	0.398	0.389	6.25	8.54
<i>Hormigas león</i>	0.397	0.389	6.47	8.54

Optimización a partir de datos obtenidos en Moldflow a pie de máquina

Tal como lo indica el subtítulo anterior, en esta sección se decidió realizar la optimización por medio de datos obtenidos con Moldflow, utilizándolos a pie de máquina para verificar si existía una mejora en la optimización, o bien si la deflexión disminuía de la misma forma; esta experimentación se realizó solamente para la deflexión en la dirección 'Y'. Con este propósito se tomaron los datos obtenidos en las *Tablas 34-36*, y en las *Tablas 39-41* se muestran columnas de la deflexión predicha por la RNA, la simulada por Moldflow y la obtenida en las mediciones hechas a pie de máquina, así como sus variaciones.

Por otro lado, cabe resaltar que las deformaciones mostradas en las *Tablas 39-41* fueron multiplicadas por dos para que la deflexión física coincidiera con la deflexión virtual.

Tabla 39 Conjunto de parámetros obtenidos a partir de distintas configuraciones de la RNA optimizador Lobos grises

	<u>Def.</u>	<u>Def.</u>	<u>Def.</u>	%	%
<u>C</u>	<u>pred.</u>	<u>Sim.</u>	<u>Real</u>	<u>Variación</u>	<u>variación</u>
	[mm]	[mm]	[mm]	<u>Pred-Sim</u>	<u>pred-real</u>
3	1.858	1.607	5.040	14.92	172.52
3	1.843	1.616	4.620	14.07	150.62
3	1.895	1.648	4.030	14.99	112.49
13	1.786	1.627	4.180	09.80	133.99
13	1.800	1.610	4.560	11.80	153.28
13	1.818	1.656	4.730	09.73	160.42
14	1.858	1.610	3.930	15.38	111.52
14	1.865	1.620	4.160	15.15	123.19
14	1.863	1.618	4.280	15.20	129.69

Tabla 40 Conjunto de parámetros obtenidos a partir de distintas configuraciones de la RNA optimizador Ballenas grises

	<u>Def.</u>	<u>Def.</u>	<u>Def.</u>	%	%
<u>C</u>	<u>pred.</u>	<u>Sim.</u>	<u>real</u>	<u>variación</u>	<u>variación</u>
	[mm]	[mm]	[mm]	<u>Pred-Sim</u>	<u>pred-real</u>
3	1.853	1.615	4.550	14.78	145.52
3	1.897	1.575	4.380	20.43	130.89
3	1.853	1.610	4.850	15.10	161.77
13	1.825	1.602	3.950	13.90	116.49
13	1.802	1.604	4.520	12.33	150.62
13	1.820	1.618	4.150	12.48	127.84
14	1.858	1.649	4.560	12.70	145.22
14	1.858	1.596	4.730	16.44	154.73
14	1.863	1.618	4.110	15.20	120.56

Tabla 41 Conjunto de parámetros obtenidos a partir de distintas configuraciones de la RNA optimizador Hormigas león

	<u>Def.</u>	<u>Def.</u>	<u>Def.</u>	%	%
<u>C</u>	<u>pred.</u>	<u>Sim.</u>	<u>real</u>	<u>variación</u>	<u>variación</u>
	[mm]	[mm]	[mm]	<u>Pred-Sim</u>	<u>pred-real</u>
3	1.843	1.616	4.530	14.07	145.92
3	1.897	1.578	4.050	20.19	113.54
3	1.851	1.609	4.670	15.04	152.17
13	1.832	1.611	3.610	13.73	96.89
13	1.786	1.627	4.410	09.80	146.68
13	1.800	1.610	4.920	11.79	173.30
14	1.857	1.587	4.530	17.01	143.94
14	1.865	1.588	3.910	17.45	109.43
14	1.863	1.618	3.820	15.20	105.18

Se observaron variaciones entre el 9.8 y el 20.43%, entre las deformaciones predichas por las RNA y las obtenidas mediante la simulación en Moldflow, mientras que las variaciones se dispararon al compararlas con las medidas a pie de máquina. Se muestran en las primeras tres columnas de la *Tabla 42* las referencias de la *Tabla 32*; en la cuarta columna de la *Tabla 42* se muestra la deflexión promedio real de las piezas inyectadas; mientras que en la penúltima columna se muestra la disminución en porcentaje de la deflexión comparada con la base de datos obtenida a pie de máquina; y en la última columna se muestra la disminución máxima.

Tabla 42 Deflexión promedio para análisis de disminución

<u>Deflexión promedio [mm]</u>					
<i>Base de datos</i>	<i>Optimizadores</i>	<i>Moldflow</i>	<i>Real</i>	<i>Disminución BDPM-MR</i>	<i>Disminución máxima</i>
				%	%
1.871	1.845	1.613	4.362	7.54	23.48

Se muestra en la *Tabla 43* que el mejor desempeño lo obtuvo el optimizador de hormigas león, tanto en la disminución promedio como en la disminución máxima, mientras que ballenas grises obtuvo el peor desempeño.

Tabla 43 Evaluación de optimizadores

<u>Optimizador</u>	<u>Def. Prom.</u> [mm]	<u>Def mín.</u> [mm]	<u>% Disminución prom</u>	<u>% disminución máx</u>
<i>Lobos grises</i>	4.390	3.930	6.90	16.70
<i>Ballenas grises</i>	4.420	3.950	6.26	16.27
<i>Hormigas león</i>	4.270	3.610	9.44	23.48

En la *Tabla 44* se muestra una comparativa del desempeño de los optimizadores, encontrando que el que mejor desempeño que tuvo en general fue el de Hormigas león.

Tabla 44 Comparativa del desempeño de los optimizadores para cada uno de los procesos

<u>Parámetro por disminuir</u>	<u>Optimizadores</u>		
	Lobos grises	Ballenas grises	Hormigas león
<i>Def. Moldflow 'Y' Antes de Moldeo científico.</i>	-	Peor desempeño	Mejor desempeño
<i>Def. Pie de máquina 'Y'</i>	Peor desempeño	-	Mejor desempeño
<i>Def. Pie de máquina 'X'</i>	Mejor desempeño	Peor desempeño	No aplica
<i>Def. Moldflow después de MC. 'Y'</i>	Peor desempeño	-	Mejor desempeño
<i>Def. Moldflow 'X'</i>	-	Peor desempeño	Mejor desempeño
<i>Def. Moldflow a pie de máquina</i>	-	Peor desempeño	Mejor desempeño

CONCLUSIONES

A través de diseños de experimentos y de análisis del concepto de señal-ruido, fue posible determinar la influencia de los parámetros de inyección en las deflexiones analizadas en dos direcciones de la pieza caso de estudio, encontrando mayor influencia de la velocidad de inyección, la presión de sostenimiento y la temperatura de masa fundida, tal como se encontró en [4], [12], [15] Con ello fue posible crear bases de datos a través de experimentaciones hechas a pie de máquina y de simulaciones hechas en Moldflow.

Con estas bases de datos se pudo entrenar una red neuronal artificial programada en Matlab, además, a diferencia de lo que se realizó en algunas investigaciones [3], [15], [18], no sólo se evaluó el número de neuronas por capa, si no que, a través de evaluadores como el coeficiente de correlación lineal de Pearson, el error medio absoluto y el error medio cuadrático, fue posible seleccionar la topografía de la red neuronal, es decir, el número de neuronas por capa, la regla de entrenamiento y la función de activación. Las configuraciones que mejor desempeño demostraron fueron 3 de 16 de las estudiadas.

Se observó que la definición del rango de parámetros está en función de las condiciones a pie de máquina, es decir, que los datos de proceso que nos indica el proveedor del material y, por ende, los datos que están dados de alta en la mayoría de los softwares de simulación del proceso de inyección de plásticos deben de ser corroborados en la máquina de inyección que se esté utilizando, así como con los equipos periféricos, y no sólo basarse en ellos para lograr una optimización, tal como se hizo en [15], [16], [20].

La investigación mostró que existen muchos tipos de optimizadores, ésta se enfocó en aquellos inspirados en la naturaleza y se tomaron en cuenta algunos de los desarrollados por el Dr. Mirjalili [39], [51], [53], como son Lobos grises, Ballenas grises y Hormigas león. Los tres optimizadores se ocuparon durante el desarrollo en la mayoría de las optimizaciones, con excepción de que en las Hormigas león no se pudo

utilizar la maximización de la circunferencia para la deflexión en la dirección en 'X', debido a que no se halló una función de programación compatible.

Los datos mostraron que las predicciones hechas a través de las RNA fueron distintos a los obtenidos, tanto por medio de simulaciones como a través de experimentaciones hechas a pie de máquina. Esto se puede deber a que existieron errores en las mediciones, a que el número de neuronas que se ocuparon para las distintas capas ocultas o, incluso, el número de capas ocultas fueron insuficientes; sin embargo, la disminución se logró utilizando los parámetros arrojados por la RNA después de la optimización, es decir, la optimización funcionó.

En el caso de la deflexión en dirección 'Y', se pudo disminuir hasta un 35.63% con datos obtenidos a pie de máquina, y hasta un 23.48% por medio de simulaciones en Moldflow; por otro lado, en la dirección 'X' hubo una disminución de hasta 17.58% y 12.59% con datos obtenidos a pie de máquina y a través de simulaciones respectivamente. Por otro lado, se observó durante la experimentación que existieron varios conjuntos de soluciones idénticos entre los optimizadores, es decir, que encontraron la misma solución.

La experimentación arrojó que el optimizador que obtuvo un mejor desempeño general fue el de hormigas león, alcanzando la mayor disminución de la deflexión y logrando la convergencia en menos iteraciones que los demás optimizadores; sin embargo, los resultados de los demás optimizadores no distan mucho de éste, lo que indica que es mejor utilizar distintos métodos de optimización para encontrar aquél que sea más compatible con el proceso a analizar. Por otro lado, también se mostró que el número de iteraciones pudo haberse disminuido con un método mejor de criterio de paro, ya que, aunque el valor seguía disminuyendo, esa disminución no era grande en comparación con los datos.

Los datos mostrados indican que es posible disminuir la deflexión a través de simulaciones y, aunque el valor disminuido es menor que aquél que permitió la optimización con datos a pie de máquina, es superior al mostrado en la aplicación de la optimización con los datos obtenidos por el software de Moldflow.

Trabajos a futuro

Se pueden realizar más experimentaciones para determinar si mediante proceso se puede disminuir aún más la deflexión, también se pueden considerar ajustes en el maquinado del molde, o bien en la elección del material a procesar. Por otro lado, es recomendable realizar experimentaciones con un mayor número de capas o de neuronas por capa para verificar si existe una diferencia sustancial en los resultados de desempeño de la red neuronal.

REFERENCIAS

- [1] S. Kulkarni, *Robust Process Development and Scientific Molding*. 2016.
- [2] D. O. Kazmer, *Injection Mold Design Engineering*, Primera. Alemania: Hanser Publishers, 2007.
- [3] E. Oliaei *et al.*, “Warping and Shrinkage Optimization of Injection-Molded Plastic Spoon Parts for Biodegradable Polymers Using Taguchi, ANOVA and Artificial Neural Network Methods,” *J. Mater. Sci. Technol.*, vol. 32, no. 8, pp. 710–720, 2016, doi: 10.1016/j.jmst.2016.05.010.
- [4] X. P. Dang, “General frameworks for optimization of plastic injection molding process parameters,” *Simul. Model. Pract. Theory*, vol. 41, pp. 15–27, 2014, doi: 10.1016/j.simpat.2013.11.003.
- [5] Y. Yang, B. Yang, S. Zhu, and X. Chen, “Online quality optimization of the injection molding process via digital image processing and model-free optimization,” *J. Mater. Process. Technol.*, vol. 226, pp. 85–98, 2015, doi: 10.1016/j.jmatprotec.2015.07.001.
- [6] X. Kong, Y. Yang, X. Chen, Z. Shao, and F. Gao, “Quality control via model-free optimization for a type of batch process with a short cycle time and low operational cost,” *Ind. Eng. Chem. Res.*, vol. 50, no. 5, pp. 2994–3003, 2011, doi: 10.1021/ie1016927.
- [7] R. Kerkstra and S. Brammer, “Decoupled® or Scientific Molding,” in *Injection Molding Advanced Troubleshooting Guide*, München: Carl Hanser Verlag GmbH & Co. KG, 2018, pp. 29–32.
- [8] X.-S. Yang, “Neural networks and deep learning,” *Introd. to Algorithms Data Min. Mach. Learn.*, pp. 139–161, 2019, doi: 10.1016/b978-0-12-817216-2.00015-6.
- [9] S. A. Elsheikhi and K. Y. Benyounis, *Mathematical Modeling and Optimization of Injection Molding of Plastics*, no. 1. Elsevier Ltd., 2017.

- [10] O. Ogorodnyk and K. Martinsen, “Monitoring and Control for Thermoplastics Injection Molding A Review,” *Procedia CIRP*, vol. 67, pp. 380–385, 2018, doi: 10.1016/j.procir.2017.12.229.
- [11] S. N. Sivanandam and S. N. Deepa, *Introduction to genetic algorithms*. 2008.
- [12] B. Ozcelik and T. Erzurumlu, “Comparison of the warpage optimization in the plastic injection molding using ANOVA, neural network model and genetic algorithm,” *J. Mater. Process. Technol.*, vol. 171, no. 3, pp. 437–445, 2006, doi: 10.1016/j.jmatprotec.2005.04.120.
- [13] B. S. Heidari *et al.*, “Optimization simulated injection molding process for ultrahigh molecular weight polyethylene nanocomposite hip liner using response surface methodology and simulation of mechanical behavior,” *J. Mech. Behav. Biomed. Mater.*, vol. 81, no. January, pp. 95–105, 2018, doi: 10.1016/j.jmbbm.2018.02.025.
- [14] G. Berti and M. Monti, “A virtual prototyping environment for a robust design of an injection moulding process,” *Comput. Chem. Eng.*, vol. 54, pp. 159–169, 2013, doi: 10.1016/j.compchemeng.2013.04.005.
- [15] A. A. Iniesta, J. L. G. Alcaraz, and M. I. R. Borbón, “Optimización de los parámetros del proceso de inyección de plásticos a través de un híbrido de redes neuronales artificiales y el algoritmo de la colonia artificial de abejas,” *Rev. Fac. Ing.*, no. 67, pp. 43–51, 2013.
- [16] R. Wang, J. Zeng, X. Feng, and Y. Xia, “Evaluation of effect of plastic injection molding process parameters on shrinkage based on neural network simulation,” *J. Macromol. Sci. Part B Phys.*, vol. 52, no. 1, pp. 206–221, 2013, doi: 10.1080/00222348.2012.700234.
- [17] M. Bahiraei, L. K. Foong, S. Hosseini, and N. Mazaheri, “Predicting heat transfer rate of a ribbed triple-tube heat exchanger working with nanofluid using neural network enhanced by advanced optimization

- algorithms,” *Powder Technol.*, vol. 381, pp. 459–476, 2021, doi: 10.1016/j.powtec.2020.12.003.
- [18] R. J. Bensingh, R. Machavaram, S. R. Boopathy, and C. Jebaraj, “Injection molding process optimization of a bi-aspheric lens using hybrid artificial neural networks (ANNs) and particle swarm optimization (PSO),” *Meas. J. Int. Meas. Confed.*, vol. 134, pp. 359–374, 2019, doi: 10.1016/j.measurement.2018.10.066.
- [19] M. G. Sahab, V. V. Toropov, and A. H. Gandomi, *A Review on Traditional and Modern Structural Optimization: Problems and Techniques*, First Edit. Elsevier Inc., 2013.
- [20] R. Spina, “Optimisation of injection moulded parts by using ANN-PSO approach,” *J. Achiev. Mater. Manuf. Eng.*, vol. 15, p. 146, 2006.
- [21] A. López, J. Aisa, A. Martinez, and D. Mercado, “Injection moulding parameters influence on weight quality of complex parts by means of DOE application: Case study,” *Meas. J. Int. Meas. Confed.*, vol. 90, pp. 349–356, 2016, doi: 10.1016/j.measurement.2016.04.072.
- [22] U. S. E. Of *et al.*, “Use of multicriteria optimization and neural networks as methods to improve the quality on pieces obtained by thermoplastic injection moulding,” pp. 2–5, 2012.
- [23] M. Moayyedian and A. Mamedov, “Multi-objective optimization of injection molding process for determination of feasible moldability index,” *Procedia CIRP*, vol. 84, pp. 769–773, 2019, doi: 10.1016/j.procir.2019.04.213.
- [24] C. T. Huang, R. T. Xu, P. H. Chen, W. R. Jong, and S. C. Chen, “Investigation on the machine calibration effect on the optimization through design of experiments (DOE) in injection molding parts,” *Polym. Test.*, vol. 90, no. 151, p. 106703, 2020, doi: 10.1016/j.polymertesting.2020.106703.
- [25] S. Canevarolo, *Polymer Science A Textbook for Engineers and Technologists*. Munich: Hanser

- Publications, 2020.
- [26] J. R. Fried, *Polymer Science & Technology*, Third. Prentice Hall, 2014.
- [27] C. Bonten, *Plastics Technology: Introduction and Fundamentals*. Cincinnati: Hanser Publications, 2019.
- [28] J. Dealy, D. Read, and R. Larson, *Structure and Rheology of Molten Polymers: From Structure to Flow Behavior and Back Again*. Cincinnati: Hanser Publications, 2018.
- [29] S. Koltzenburg, M. Maskos, and O. Nuyken, *Polymer chemistry*. 2017.
- [30] E. Hans-Georg, *Macromolecules*. Michigan: Springer, 1977.
- [31] N. Rudolph and T. A. Osswald, *Polymer Rheology*. Munich: Hanser, 2014.
- [32] N. Chandran, C. Sarathchandran, and S. Thomas, *Introduction to rheology*. Elsevier Inc., 2019.
- [33] M. L. Chaves, L. Sánchez-González, E. Díez, H. Pérez, and A. Vizán, “Experimental assessment of quality in injection parts using a fuzzy system with adaptive membership functions,” *Neurocomputing*, vol. 391, pp. 334–344, 2020, doi: 10.1016/j.neucom.2019.06.108.
- [34] T. Sakai and K. Kikugawa, *Injection Molding Machines, Tools, and Processes*, First Edit. Carl Hanser Verlag GmbH & Co. KG, 2009.
- [35] Demag Plastic Group, *La Inyección en Forma Breve y Sucinta*, 5a edición. Schwaig, 2004.
- [36] H. Pruner and W. Nesch, *Understanding Injection Molds*. 2013.
- [37] D. Reiner, *Injection Molds for Beginners*. Munich: Hanser Publishers, 2020.
- [38] G. F. Schiller, *A Practical Approach to Scientific Molding*, First Edit. Carl Hanser Verlag GmbH & Co. KG, 2018.
- [39] S. Mirjalili, “The ant lion optimizer,” *Adv. Eng. Softw.*, vol. 83, pp. 80–98, 2015, doi: 10.1016/j.advengsoft.2015.01.010.
- [40] R. Kerkstra, S. Brammer, R.

- Kerkstra, and S. Brammer, *Decoupled® or Scientific Molding*. 2018.
- [41] M. Abdel-Basset, L. Abdel-Fatah, and A. K. Sangaiah, *Metaheuristic algorithms: A comprehensive review*. Elsevier Inc., 2018.
- [42] L. Costa and P. Oliveira, “An introduction to optimization,” *Optim. Polym. Process.*, pp. 11–28, 2011, doi: 10.1109/map.1996.500234.
- [43] S. Gholizadeh, *Structural Optimization for Frequency Constraints*, First Edit., no. 2011. Elsevier Inc., 2013.
- [44] E. Cox, “Fundamental Concepts of Genetic Algorithms,” *Fuzzy Model. Genet. Algorithms Data Min. Explor.*, pp. 343–420, 2005, doi: 10.1016/b978-012194275-5/50011-6.
- [45] D. Mondal, A. Chakrabarti, and A. Sengupta, *Optimal and Robust Control*. 2020.
- [46] W. Roetzel, X. Luo, and D. Chen, *Optimal design of heat exchanger networks*, no. 3. Elsevier Inc., 2020.
- [47] A. Kumar, S. Pant, M. Ram, and S. B. Singh, *On solving complex reliability optimization problem using multi-objective particle swarm optimization*. Elsevier Ltd., 2017.
- [48] M. R. Monteiro, Y. R. Rodrigues, A. C. Z. de Souza, and P. F. Ribeiro, “Particle swarm optimization applied to reactive power dispatch considering renewable generation,” *Decis. Mak. Appl. Mod. Power Syst.*, pp. 247–267, 2020, doi: 10.1016/b978-0-12-816445-7.00010-4.
- [49] Z. E. Ahmed, R. A. Saeed, A. Mukherjee, and S. N. Ghorpade, *Energy optimization in low-power wide area networks by using heuristic techniques*. INC, 2020.
- [50] S. Kumar and A. Kumar, “A brief review on antlion optimization algorithm,” *Proc. - IEEE 2018 Int. Conf. Adv. Comput. Commun. Control Networking, ICACCCN 2018*, pp. 236–240, 2018, doi: 10.1109/ICACCCN.2018.8748862.
- [51] S. Mirjalili, S. M. Mirjalili, and A. Lewis, “Grey Wolf Optimizer,” *Adv. Eng. Softw.*, vol. 69, pp. 46–

- 61, 2014, doi:
10.1016/j.advengsoft.2013.12.007.
- [52] M. H. Nadimi-Shahraki, S. Taghian, and S. Mirjalili, “An improved grey wolf optimizer for solving engineering problems,” *Expert Syst. Appl.*, vol. 166, no. September 2020, p. 113917, 2021, doi: 10.1016/j.eswa.2020.113917.
- [53] S. Mirjalili and A. Lewis, “The Whale Optimization Algorithm,” *Adv. Eng. Softw.*, vol. 95, pp. 51–67, 2016, doi:
10.1016/j.advengsoft.2016.01.008.
- [54] S. Chakraborty, A. K. Saha, R. Chakraborty, and M. Saha, “An enhanced whale optimization algorithm for large scale optimization problems,” *Knowledge-Based Syst.*, vol. 233, p. 107543, 2021, doi:
10.1016/j.knosys.2021.107543.
- [55] M. I. Rodrigues and A. F. Iemma, *Experimental design and process optimization*. 2014.
- [56] D. C. Montgomery, *Design and Analysis of Experiments*, 10th ed. Danvers: Wiley, 2019.
- [57] D. Monzón and D. Monzón Paiva, “Introducción al diseño de experimentos,” *Rev. la Fac. Agron. la Univ. Cent. Venez.*, no. Alcance 34, p. 167 p., 1992.
- [58] K. Hinkelmann, *Design and Analysis of Experiments*, vol. 3. 2012.
- [59] F. Stephanie, O. Mike, T. Ben, and Z. John, “Design of experiments via taguchi methods: orthogonal arrays - ControlsWiki,” *michigan Chem. Process Dyn. Control. open text B.*, pp. 1–11, 2006, [Online]. Available:
https://controls.engin.umich.edu/wiki/index.php/Design_of_experiments_via_taguchi_methods:_orthogonal_arrays.
- [60] Z. Erzurum and Z. Ozturk, “Optimizing the artificial neural network parameters using biased random key genetic algorithm for time series forecasting,” *Appl. Soft Comput. J.*, 2021.
- [61] D. Livingstone, *Artificial Neural Networks Methods and Applications*. Sandown: Humana Press, 2008.
- [62] F. Lara Rosano, *Fundamentos de*

Redes Neuronales Artificiales.

México: UNAM, 1990.

- [63] I. Stanimirovic, *Deep Neural Networks and Applications.* Oakville: Arcler Press, 2020.
- [64] P. Peças, I. Ribeiro, E. Henriques, and A. Raposo, *Additive manufacturing in injection molds-life cycle engineering for technology selection.* Elsevier Inc., 2018.
- [65] C. Moller, “Matlab.” Mathworks, USA, 2020.
- [66] Viduca, “Procesos de producción,” 2020.
[https://www.viduca.com/es/content/8-procesos-de-produccion.](https://www.viduca.com/es/content/8-procesos-de-produccion)
- [67] J. C. González Sánchez, “Evaluación del moldeo científico aplicado a diferentes moldes para inyección de plásticos,” *Univ. Nac. Autónoma México*, pp. 1–102, 2020.

Anexos

Glosario de parámetros del proceso de inyección de plásticos

- **Temperatura del barril y de la masa:** la primera es la temperatura de las resistencias a lo largo del husillo en las distintas zonas. Por lo general, el perfil de temperaturas va en aumento para los materiales amorfos, mientras que para materiales semicristalinos al final; en la parte de la boquilla existe una disminución. La temperatura de la masa se refiere a la temperatura que se mide directamente de la masa fundida del material al salir de la boquilla.
- **Temperatura del molde:** esta temperatura es importante para los materiales semicristalinos, ya que la cristalización depende en gran medida de este parámetro y, con ello, sus propiedades mecánicas, así como en el acabado superficial de la pieza; además de mantener una temperatura en el molde evita problemas con la pieza en el momento de la expulsión.
- **Velocidad de inyección:** la velocidad de inyección se refiere a la velocidad con la que avanza el husillo al momento de inyectar; este parámetro determina ciertas propiedades del material, tales como, la viscosidad además de ciertos defectos en la pieza como las ráfagas.
- **Punto de conmutación:** es el punto en el cual la máquina deja de aplicar la presión de inyección y comienza a aplicar la presión de sostenimiento.
- **Presión de sostenimiento:** la presión de sostenimiento se refiere a la presión que se ejerce en el material al final de la fase de inyección, para que en el momento de la contracción del material se inyecte más material y se evite que la pieza no se llene.
- **Tiempo de sostenimiento:** es el tiempo en el cual se aplica la presión de sostenimiento y depende del sello de compuertas, es decir, del momento en el

que el punto de inyección o compuerta impida el flujo de material dentro de la cavidad.

- Tiempo de enfriamiento: es el tiempo necesario para que la pieza alcance la temperatura de expulsión, además de que, a partir de este tiempo, las dimensiones de la pieza no se verán alteradas.
- Revoluciones del husillo: es la velocidad rotacional del husillo, la cual depende del tipo de material que se utilice, así como del tamaño de la máquina empleada, ya que parte de esta energía permite fundir el material. Esta velocidad arrastra a los pellets desde la tolva hasta llegar a la cámara de reserva que se prepara para el siguiente ciclo de inyección.
- Contrapresión: La contrapresión es aquella presión en la cámara, contra la que tiene que plastificar el husillo durante la plastificación, y se usa para evitar que el husillo se mueva hacia atrás con facilidad, además de evitar que exista algún goteo en la nariz mientras el molde está abierto.

CELANEX® 5202 - PBT**Description**

15% glass, improved surface gloss

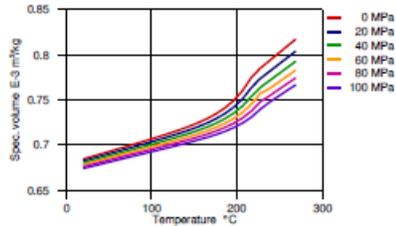
Celanex 5202 is a 15% glass filled polyester blend that features improved surface gloss and has an excellent balance of mechanical properties, processability, and color stability under heat and UV exposure. A typical application for Celanex 5202 is oven handles.

Physical properties	Value	Unit	Test Standard
Density	1440	kg/m ³	ISO 1183
Melt flow rate, MFR	25	g/10min	ISO 1133
MFR temperature	265	°C	ISO 1133
MFR load	2.16	kg	ISO 1133
Molding shrinkage, parallel (flow)	0.1 - 0.6	%	ISO 294-4, 2577
Molding shrinkage, transverse normal	0.7	%	ISO 294-4, 2577
Humidity absorption, 23°C/50%RH	0.17	%	ISO 62
Mechanical properties	Value	Unit	Test Standard
Tensile modulus	6100	MPa	ISO 527-1, -2
Tensile stress at break, 5mm/min	100	MPa	ISO 527-1, -2
Tensile strain at break, 5mm/min	2.5	%	ISO 527-1, -2
Flexural modulus, 23°C	5300	MPa	ISO 178
Flexural strength, 23°C	150	MPa	ISO 178
Charpy impact strength, 23°C	15	kJ/m ²	ISO 179/1eU
Charpy impact strength, -30°C	17	kJ/m ²	ISO 179/1eU
Charpy notched impact strength, 23°C	4.7	kJ/m ²	ISO 179/1eA
Charpy notched impact strength, -30°C	4.5	kJ/m ²	ISO 179/1eA
Izod impact notched, 23°C	4.4	kJ/m ²	ISO 180/1A
Mechanical properties (TPE)	Value	Unit	Test Standard
Shore D hardness-TPE, 15s	83		ISO 868
Thermal properties	Value	Unit	Test Standard
Melting temperature, 10°C/min	250	°C	ISO 11357-1/-3
Glass transition temperature, 10°C/min	50	°C	ISO 11357-1,-2,-3
DTUL at 1.8 MPa	180	°C	ISO 75-1, -2
DTUL at 0.45 MPa	215	°C	ISO 75-1, -2
Coeff. of linear therm expansion, parallel	0.42	E-4/°C	ISO 11359-2
Coeff. of linear therm expansion, normal	0.73	E-4/°C	ISO 11359-2
Flammability at thickness h	HB	class	UL 94
thickness tested (h)	0.80	mm	UL 94
Electrical properties	Value	Unit	Test Standard
Dielectric constant (Dk), 100Hz	2.7	-	IEC 60250
Dielectric constant (Dk), 1MHz	2.7	-	IEC 60250
Dissipation factor, 1MHz	140	E-4	IEC 60250
Volume resistivity, 23°C	7E14	Ohm*m	IEC 62631-3-1
Surface resistivity, 23°C	4E15	Ohm	IEC 62631-3-2
Electric strength, 23°C (AC)	17	kV/mm	IEC 60243-1
Comparative tracking index	PLC 3	-	UL 746
CTI 50 drops	225	V	IEC 60112

CELANEX® 5202 - PBT

Diagrams

Moldflow Specific volume-temperature (pvT)



Indirect Dilatometry

Typical injection moulding processing conditions

Pre Drying	Value	Unit
Necessary low maximum residual moisture content	0.02	%
Drying time	4	h
Drying temperature	120 - 130	°C
Temperature	Value	Unit
Hopper temperature	20 - 50	°C
Feeding zone temperature	230 - 250	°C
Zone1 temperature	230 - 250	°C
Zone2 temperature	235 - 255	°C
Zone3 temperature	235 - 255	°C
Zone4 temperature	240 - 260	°C
Nozzle temperature	250 - 265	°C
Melt temperature	250 - 270	°C
Mold temperature	90 - 110	°C
Hot runner temperature	250 - 265	°C
Speed	Value	
Injection speed	medium-fast	

Other text information

Pre-drying

To avoid hydrolytic degradation during processing, CELANEX resins have to be dried to a moisture level less than 0.02%. Drying should be done in a dehumidifying hopper dryer capable of dewpoints <-40°F (-40°C) at 250°F (121°C) for 4 hours.

Longer pre-drying times/storage

For subsequent storage of the material in the dryer until processed (<= 60 h) it is necessary to lower the temperature to 100° C.

Characteristics

Product Categories	Glass reinforced
Processing	Injection molding

CELANEX® 5202 - PBT

Delivery Form Pellets

Contact

Americas

8040 Dixie Highway
Florence, KY 41042 USA
Product Information Service
t: +1-800-833-4882
t: +1-859-372-3244
Customer Service
t: +1-800-526-4960
t: +1-859-372-3214
e: info-engineeredmaterials-am@celanese.com

Asia

4560 Jinke Road
Zhang Jiang Hi Tech Park
Shanghai 201210 PRC
Customer Service
t: +86 21 3861 9288
e: info-engineeredmaterials-asia@celanese.com

Europe

Am Unisys-Park 1
65843 Sulzbach, Germany
Product Information Service
t: +49-800-86427-531
t: +49-(0)-69-45009-1011
e: info-engineeredmaterials-eu@celanese.com

General Disclaimer

NOTICE TO USERS: Values shown are based on testing of laboratory test specimens and represent data that fall within the standard range of properties for natural material. These values alone do not represent a sufficient basis for any part design and are not intended for use in establishing maximum, minimum, or ranges of values for specification purposes. Colorants or other additives may cause significant variations in data values. Properties of molded parts can be influenced by a wide variety of factors including, but not limited to, material selection, additives, part design, processing conditions and environmental exposure. Any determination of the suitability of a particular material and part design for any use contemplated by the users and the manner of such use is the sole responsibility of the users, who must assure themselves that the material as subsequently processed meets the needs of their particular product or use. To the best of our knowledge, the information contained in this publication is accurate; however, we do not assume any liability whatsoever for the accuracy and completeness of such information. The information contained in this publication should not be construed as a promise or guarantee of specific properties of our products. It is the sole responsibility of the users to investigate whether any existing patents are infringed by the use of the materials mentioned in this publication. Moreover, there is a need to reduce human exposure to many materials to the lowest practical limits in view of possible adverse effects. To the extent that any hazards may have been mentioned in this publication, we neither suggest nor guarantee that such hazards are the only ones that exist. We recommend that persons intending to rely on any recommendation or to use any equipment, processing technique or material mentioned in this publication should satisfy themselves that they can meet all applicable safety and health standards. We strongly recommend that users seek and adhere to the manufacturer's current instructions for handling each material they use, and entrust the handling of such material to adequately trained personnel only. Please call the telephone numbers listed for additional technical information. Call Customer Services for the appropriate Materials Safety Data Sheets (MSDS) before attempting to process our products. The products mentioned herein are not intended for use in medical or dental implants.

Trademark

© 2021 Celanese or its affiliates. All rights reserved. Celanese®, registered C-ball design and all other trademarks identified herein with ®, TM, SM, unless otherwise noted, are trademarks of Celanese or its affiliates. Fortron is a registered trademark of Fortron Industries LLC.

Redes neuronales artificiales programadas en Matlab

Las redes neuronales artificiales pueden ser programadas en distintos softwares, uno de ellos es Matlab; este software tiene una herramienta especializada en RNA el cual puede ser configurado con tan sólo unos cuantos parámetros. Estos parámetros son tipo de red neuronal, función de activación, regla de aprendizaje, número de capas y número de neuronas por capa, los cuales fueron definidos anteriormente y, en los siguientes párrafos, se hablará a profundidad de aquellos tipos de reglas de aprendizaje y de funciones de activación que se manejan en el software.

Configuración de RNA

En el software descrito se configura la RNA a través de distintos comandos, entre ellos se encuentran los mostrados en la *Figura 36*, los cuales determinan ciertos parámetros dentro de la RNA, tales como el tipo de red neuronal utilizada. En el caso de este

proyecto se utilizó el comando 'feedforwardnet', el cual entrega una red neuronal con una sección de capas ocultas de tamaño 'hiddensize', es decir, con un cierto número de capas ocultas. La primera capa de la red neuronal está conectada a las entradas del proceso, cada una de las siguientes capas están conectadas a la siguiente hasta llegar a la capa de salida con las salidas analizadas correspondientes. Una red neuronal con configuración feedforward es capaz de mapear las entradas y las salidas, encontrando algún patrón o ajuste entre ellas [65].

```
red=feedforwardnet([10,13], 'trainbr');
red.trainParam.epochs=(1000);
red.trainParam.mu=0.1;
red.trainParam.mu_dec=0.1;
red.trainParam.mu_inc=10;
red.layers{1}.transferFcn='logsig';
red.layers{2}.transferFcn='logsig';
configure(red, input, targets);
red.divideParam.trainRatio=90/100;
red.divideParam.valRatio=5/100;
red.divideParam.testRatio=5/100;
[red, tr]=train(red, input, targets);
```

Figura 36 Código de RNA en Matlab

Reglas de aprendizaje

Las reglas de aprendizaje que se emplearon en este trabajo se seleccionaron de acuerdo con la descripción de éstas dentro del software. Se eligieron aquellas que presentaban una mejoría con respecto a otras al disminuir el tiempo de cómputo, por ejemplo, la primera de ellas es la trainbfg (Cuasi-Newton Backpropagation), la cual es una aproximación del cálculo de matrices Hessianas disminuyendo el tiempo de cálculo al no realizar segundas derivadas. La segunda regla de aprendizaje es la trainoss (One - step secant method), en donde la mejoría está en la disminución de almacenaje de información, ya que no guarda por completo las matrices Hessianas.

Se utilizaron otras dos reglas de aprendizaje trainr y trainrp, la primera es conocida como entrenamiento incremental aleatorio con funciones de aprendizaje, en la cual, para cada iteración, todos los vectores se presentan de forma aleatoria actualizando los valores de peso y bias de las neuronas; por otro lado, la siguiente regla de

entrenamiento es conocida como Resilient Backpropagation, en donde a través de sólo tomar en cuenta el signo de las derivadas parciales se puede decidir hacia dónde se moverá el valor del peso.

Funciones de activación

Las funciones de activación se seleccionaron de acuerdo con aquellas curvas cuya transición de valores fuera más suave. En la *Figura 37* se muestran las gráficas de estas funciones.

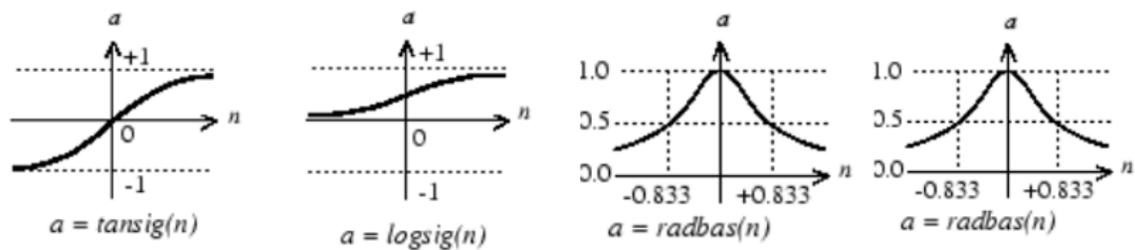


Figura 37 Funciones de activación utilizadas