



**UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO
FACULTAD DE ESTUDIOS SUPERIORES CUAUTITLÁN**

**Aplicación de una red neuronal artificial, para la
determinación del Calor específico durante la descongelación
de carne de cerdo.**

T E S I S

**QUE PARA OBTENER EL TÍTULO DE:
INGENIERO EN ALIMENTOS**

**PRESENTA:
ISRAEL NAVARRO LIMÓN**

**ASESOR: Dr. JOSÉ LUIS ARJONA ROMÁN
COASESOR: Dr. RICARDO PARAMONT HERNÁNDEZ
GARCÍA**

CUAUTITLÁN IZCALLI, ESTADO DE MÉXICO 2014



Universidad Nacional
Autónoma de México

Dirección General de Bibliotecas de la UNAM

Biblioteca Central



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.

No hay un modo fácil de hacerlo. No importa cuán talentoso seas, tu talento te va a fallar si no estás capacitado, si no estudias, si no trabajas realmente duro y no te dedicas a ser mejor cada día.

Will Smith

Dedicatorias

Este logro es dedicado en especial a:

*A mis dos grandes mujeres de mi vida, mi madre **Herminia Marcelino Rivera** y mi madre **Yolanda Limón Marcelino** por a verme brindado su tiempo, apoyo, comprensión y ese amor incondicional e ilimitado.*

*A mi padre **Isaias Campistrano Hernández** por todo ese apoyo, comprensión, amor y tolerancia que siempre me regalas.*

A mi pequeño engranaje para mi ser que me impulsa día con día.

A mi mano derecha mi confidente por ese enorme apoyo y cariño que me regalas.

A mis primos los limones y el resto de la familia por su apoyo.

Agradecimientos

*A mi madre **Herminia Marcelino Rivera**: Por ser uno de mis pilares en mi vida, el cual origino los cimientos de mi ser. También por haberme regalado tu tiempo comprensión, consejos y ese peculiar gran amor cálido, puro y sincero que creaba un campo de tranquilidad, cuando todo alrededor se derrumbaba.*

Terminaste el ciclo de la vida y partiste al otro lado de ella, pero en mi mente tu eres eterna, donde quiera que te encuentres recuerda que te amo y gracias a ti lo é logrado.

*A mis padres **Yolanda Limón Marcelino e Isaías Campistrano Hernández**:*

Por ser mis otros pilares en mi vida y los mejores maestros de ella. Por su gran esfuerzo y sacrificio que han realizado para brindarme la oportunidad de lograr esta meta, por su amor, comprensión y tolerancia. Por esas enseñanzas que siempre llevo con migo de las cuales nunca olvido, que caer es permitido levantarse obligatorio, este logro no es solo mío sino también de ustedes, los amo son los mejores en esa labor de ser padres.

*A mi hermano **Isaías Campistrano Limón**: Por la ayuda que siempre recibo de ti, por ese tiempo recorrido aprendiendo de las situaciones, que esta vida nos ofrece y por ser mi primer amigo en ella, gracias carnal.*

*A la **UNAM**: Por permitirme desde el bachillerato la oportunidad que mi corazón fuera azul y mi piel dorada, también por la formación académica y personal que gran institución me ha brindado.*

*A **Dr. José Luis Arjona Román**: Por haber creído en mi para llevar a cabo este trabajo y ser uno de los mejores maestro que é conocido. También por el apoyo intelectual tan peculiar suyo, y esas tantas pendejadas que se fueron reduciendo gradualmente. Por enseñarme que en la vida existen los pretextos y los resultados.*

*A **Dr. Ricardo Paramount Hernández García**: Agradezco el hecho que existan personas como usted, las cuales brindan su apoyo y compartan su enorme intelecto, por ayudarme y guiarme para concluir este trabajo donde gran parte fue gracias a usted.*

A **Dr. Rosalía Meléndez Pérez y Dr. Marta Elvia Rosas Mendoza:** Por esas horas de convivencia echando humo, por su sencillez, carisma, motivación y apoyo obsequiado.

A cada uno de los profesores que me transmitieron sus conocimientos y me enseñaron a ignorar menos les agradezco.

A **Karen Morín Trejo:** Por la suerte en que todo en el universo se sincronizara para conocerte, llegaste en una etapa de mi vida crucial y me brindaste tu apoyo y cariño incondicional. Por ese tiempo gastado entre pláticas larga de filosofía y sueños anhelados. Por mostrarme que el éxito viene ligado de un gran esfuerzo y sacrificio. Por ser una persona muy especial de la cual é aprendido mucho y lo más importante, por ser mi mejor amiga chica banda, te quiero.

“El sol brilla todos los días, no le teme a la inmensidad ni oscuridad del universo, no espera y solo sigue su naturaleza.”

Karen Morín

A **Dina (La chica del listón rojo):** Por a verme permitido conocerte y regalarme tu cariño, amistad y apoyo. Por ese tiempo de convivencia entre risas, bromas y tratos pactados. Por ser una personal genial, sencilla y divertida en los raros ratos, que nos encontramos, no olvides que te quiero y me debes algo.

A **Edith y Angélica:** Les agradezco por su compañía, apoyo y cariño, por esos días que al término de clase, nos dirigíamos a nuestro lugar predilecto para comenzar con la cábula y el bullying. Por esas tardes de pistol en la nopalera, las motos o Black and White lugares sobraban para echar las heladas, y aun que me abandonaron las sigo apreciando.

A **Mis Amigos y compañeros (Diego, Cesar, Antonio, Héctor, José Luis, Omar, Benjamín, Ignacio, Iván y demás):** Gracias por su apoyo y claro por las fiestas y borracheras eternas, que mitigaban el stress, y por esas vivencias dentro y fuera del salón de clases que son inolvidables.

“Mil derrotas no te hacen un ser vencido, si luchas puedes perder, si no luchas estas perdido”

El B

Índice

Resumen	1
Introducción	2
1. Marco Teórico	4
1.1 Antecedentes de una Red Neuronal Artificial (RNA)	4
1.2 Fundamento Biológico de las Redes Neuronales Artificiales	5
1.3 Definición de Red Neuronal Artificial	7
1.4 Red Neuronal de Propagación del Error Hacia Atrás (Backpropagation)	7
1.4.1 Red Multicapa	8
1.4.2 Regla Delta Generalizada	12
1.4.3 Mínimos locales	14
1.4.4 Aplicaciones	15
1.5 Calor Específico	16
1.5.1 Calorimetría Diferencial de Barrido Modulada	18
1.6 Congelación de la Carne y sus Efectos	22
1.7 Color	28
1.7.1 Sistemas de Espacios de Color	30
1.8 Análisis de Textura de Imagen	33
1.8.1 Textura Estadística	34
2. Metodología Experimental	37
2.1 Descripción del Cuadro Metodológico	37
2.1.1 Planteamiento del Problema	37
2.1.2 Objetivo General	37
2.1.3 Objetivo Particular 1	37
2.1.4 Cuadro Metodológico	38
2.1.5 Objetivo Particular 2	39
2.2 Actividades Experimentales del Objetivo Particular 1	39
2.2.1 Actividad 1. Congelación de la carne de cerdo (<i>Longissimus Dorsi</i>)	39
2.2.1.1 Actividad 1.1. Toma de microfotografías durante la descongelación de la carne de cerdo (<i>Longissimus Dorsi</i>).	39
2.2.1.1.1. Determinación de parámetros de textura estadística	40
2.2.1.1.2. Determinación de parámetros de color	41
2.2.1.1.3. Determinación de parámetros de color	41
2.2.1.1.4. Determinación del calor específico por medio del MDSC	41
2.2.2 Actividad 1.2. Determinación del calor específico por medio del MDSC	42
2.3 Actividades Experimentales del Objetivo Particular 2	42
2.3.1 Actividad 2. Selección de variables de entrada	42
2.3.2 Actividad 2.1. Generar y Entrenar a la Red Neuronal Artificial	43
2.3.3 Actividad 2.2. Determinación de la validez de la red neuronal artificial entrenada.	47
3. Análisis de Resultados y Discusión	48
3.1 Resultados de la Actividad 1. Congelación de las placas de carne	48
3.2 Resultados de las Actividades 1.1, 1.1.1 y 1.1.2. Obtención de las microfotografías y la determinación de la variación de los parámetros de textura estadística y color	48

Índice

3.3 Resultados de la Actividad 1.2. Determinación del Calor Especifico	56
3.4 Resultados de la Actividad 2. Selección de variables de entrada	57
3.5 Resultados de la Actividad 2.1 Generar y Entrenar a la Red Neuronal Artificial	59
3.6 Actividad 2.2. Determinación de la validez de la red	61
4. Conclusiones	65
5. Referencias	66

Índice de Figuras

Figura 1. Estructura de una neurona biológica (Lahoz, 2004).	5
Figura 2. Representación de una red multicapa de N capas (Henseler, 1995).	9
Figura 3. Organización de las conexiones de los pesos correspondientes a una neurona i .	10
Figura 4. Grafica de la función sigmoideal.	11
Figura 5. Grafica de la superficie del error mostrando un mínimo local y un global.	14
Figura 6. Representación de una forma de la superficie de error, donde w representa los posibles valores de la matriz de pesos de la red.	14
Figura 7. Conformación de una celda de un calorímetro MDSC (Meuter, Rahie, y Mele 1999).	19
Figura 8. Representación del cubo del espacio RGB.	30
Figura 9. Representación espacial del sistema CIELab.	31
Figura 10. Representación de tonalidades de grises desde blanco hasta negro.	32
Figura 11. Representación de diferentes direcciones θ (0, 45, 90, y 135°) y la distancia (d) entre los pixeles utilizados para construir la matriz de co-ocurrencia en niveles de tonos en gris.	34
Figura 12. Representación de matrices de co-ocurrencia, (a) el valor de gris de los píxeles de una imagen de una tonalidad de 0-3 y (b) Matriz de co-ocurrencia construida a partir de (a) con distancia de 1 en las cuatro direcciones.	35
Figura 13. Diagrama de flujo representativo del proceso de entrenamiento de la red de propagación hacia atrás.	46
Figura 14. Muestra cómo se obtienen los valores de C_p con la red ya entrenada.	47
Figura 15. Historia térmica de la congelación de la carne de cerdo.	48
Figura 16. Imágenes de la descongelación de la carne a diferentes temperaturas, donde se observa los periodos (I, II, y III) de formación de escarcha y la fusión de hielo (IV).	49
Figura 17. Representación del comportamiento de la Entropía Estadística en la superficie de la carne, durante los periodos (I, II, y III) de formación de escarcha y fusión de hielo (IV).	50
Figura 18. Representación del comportamiento de la Rugosidad en la superficie de la carne, durante los periodos (I, II, y III) de formación de escarcha y fusión de hielo (IV).	52

Índice de Figuras

Figura 19. Comportamiento de los parámetros L^* , a^* y b^* en la superficie de la carne, durante los periodos (I, II, y III) de formación de escarcha y fusión de hielo (IV).	54
Figura 20. . Comportamiento de los parámetros R, G y B en la superficie de la carne, durante los periodos (I, II, y III) de formación de escarcha y fusión de hielo (IV).	54
Figura 21. Comportamiento de la Luminosidad en tonos de grises en la superficie de la carne, durante los periodos (I, II, y III) de formación de escarcha y fusión de hielo (IV).	55
Figura 22. Representación del descenso del error E durante el entrenamiento.	60
Figura 23. Comportamiento del C_p de agente supervisor y el generado por la red de 7 variables.	61
Figura 24. Representación del comportamiento y diferencias entre los diferentes valores del calor específico obtenidos del MDSC y las redes neuronales entrenadas artificiales V5 y V7.	64

Índice de Tablas

Tabla 1. Aplicaciones de la red de propagación del error hacia atrás en Ingeniería de Alimentos (Weibiao, 2009).	15
Tabla 2. Composición química de la carne de cerdo (Longissimus Dorsi).	22
Tabla 3. Condiciones para la toma de microfotografías.	40
Tabla 4. Tabla de sistemas de color y sus respectivos parámetros.	41
Tabla 5. Método del calorímetro MDSC.	41
Tabla 6. Tabla de entrenamiento que se introduce a la red.	45
Tabla 7. Valores de Cp obtenidos del calorímetro referente a la temperatura superficial registrada de la carne durante la descongelación.	56
Tabla 8. Valores de R ² del análisis de regresión lineal de las variables.	57
Tabla 9. Variables de entrada para la red neuronal artificial.	58
Tabla 10. Arquitectura de las redes neuronales entrenadas.	59
Tabla 11. Tabla de prueba para la red entrenada.	62
Tabla 12. Valores del calor específico obtenidos por el MDSC y de las redes neuronales V7 y V5.	62
Tabla 13. ANOVA unidireccional: Cp MDSC, Cp Red V7 y Cp Red V5.	64

Resumen

El siguiente de trabajo se realizó en la UNAM en la Facultad de Estudios Superiores Cuautitlán Campus 4, en el taller multidisciplinario de Ingeniería de Procesos de Separación por Transferencia de Masa.

Al procesar alimentos perecederos como es el caso de la carne de cerdo la transferencia de calor y de masa están presentes durante los procesos de transformación, conservación y almacenamiento. Una de las propiedades térmicas importantes que se afecta a nivel estructural en la carne por los procesos anteriores, es el calor específico.

En este trabajo se obtuvieron valores del calor específico durante un periodo de descongelación de la carne de cerdo por medio de la Calorimetría Diferencial de Barrido Modulada (MDSC), y con una técnica de la Inteligencia Artificial que trata de emular el procesamiento de información y aprendizaje del cerebro humano, que lleva por nombre Redes Neuronales Artificiales. Se programó una red neuronal tipo de propagación del error hacia atrás, la cual aprendió a correlacionar valores de color, textura estadística y temperatura superficial con el valor del calor específico obtenido por el MDSC.

Se obtuvieron satisfactoriamente dos redes neuronales artificiales que pueden ser utilizadas para la determinación del calor específico de la carne durante un periodo de descongelación, ya que con análisis estadísticos mostró que si tienen una validez para su uso.

Introducción

Una tecnología que está siendo implementada para predecir parámetros referentes con el procesamiento de alimentos, como es el caso del calor específico son las llamadas Redes Neuronales Artificiales (RNA), que se encuentran en una rama de Inteligencia Artificial (IA), las cuales pueden aprender el comportamiento térmico de los alimentos durante los tratamientos (Zueco, Alhama y Gonzalez, 2004). Una RNA es un algoritmo de cálculo que se basa en una analogía del sistema nervioso. La idea general consiste en emular la capacidad de aprendizaje del cerebro, de manera que la RNA aprenda a identificar un patrón de asociación entre los valores de un conjunto de variables (Lahoz, 2004). Las RNA son herramientas poderosas y eficaces programables para modelar un proceso complejo, especialmente para información que incluye una relación no lineal que es común en la Ingeniería de Alimentos. En las últimas décadas, varios estudios han demostrado el potencial de las redes neuronales como una alternativa poderosa para el modelado convencional en muchas áreas (Meng y Ramaswamy, 2009). El diseño óptimo de procesos requiere el conocimiento de las propiedades de ingeniería de los alimentos incluyendo propiedades térmicas. El calor específico (C_p) es una propiedad intensiva dependiente de la temperatura, especialmente dentro de la gama de temperaturas en la cual interviene un cambio de fase (Polley, Snyder y Kotnour, 1980; Rao y Rizvi, 1986). Es utilizado en cálculos de equilibrio de energía y transferencia de calor como una propiedad térmica que afecta de alguna manera en los procesos térmicos de alimentos, para la predicción del tiempo, control y optimización en la industria alimentaria (Kaletunc, 2007). Una de las técnicas de análisis térmico utilizadas para determinar el calor específico en los alimentos es la Calorimetría Diferencial de Barrido Modulada (MDSC). El principio de funcionamiento de la MDSC difiere de la Calorimetría Diferencial de Barrido (DSC), en que la MDSC utiliza dos tipos de calentamientos simultáneos, una tasa de calentamiento lineal que proporciona información similar a DSC estándar y una tasa de calentamiento sinusoidal o modulado que permite la medición simultánea de capacidad calorífica de la muestra (Meuter, Rahie y Mele, 1999). Al procesar los alimentos estos sufren

variaciones en ciertas propiedades como pueden ser la textura y el color. Una nueva técnica para evaluar el cambio en la textura en los alimentos es el análisis de textura de imagen, en el cual el procesamiento de imágenes depende de la suposición con la cual se puede definir las propiedades estadísticas locales de un pixel en escala de grises. (Zheng, Dna-Wen y Zheng 2006). Textura Estadística es un método que se encuentra en el análisis de imagen, la cual permite extraer una gran cantidad de información por la variedad de descriptores, en los que se encuentran la Entropía Estadística (ET) que representa el desorden o aleatoriedad de una imagen y la Suma de Cuadrados (SOS) que representa la rugosidad de una imagen, son posible de obtener a través de una matriz de co-ocurrencia, esta matriz es la relación estadística de una intensidad de pixeles a la de sus pixeles vecinos (Fernández, Castillero y Aguilera, 2003). De igual manera que la textura de un alimento el color juega un factor importante, el cual puede determinar información básica de calidad para la percepción humana. Las mediciones de color se pueden realizar por la inspección visual, instrumentos tradicionales como el colorímetro, o la visión por computador (Wu y Sun, 2013). La evaluación del color se puede efectuar utilizando espacios de color, como CIELab que tiene tres parámetros el valor de L^* es la luminancia o componente de luminosidad, a^* que mide valores de color que van de rojo a verde y el parámetro b^* que mide valores de colores entre amarillo y azul. Sin embargo, el modelo de espacio de color RGB también puede ser utilizado debido a que tiene parámetros asociados con los colores primarios (Quevedoa, y Valencia, 2013).

Este trabajo se realizó para la determinación del calor específico utilizando redes neuronales entrenadas con variables que no son usualmente empleadas para este fin, como lo son parámetros de textura estadística, color y temperatura superficial de la superficie de la carne de cerdo en un periodo de descongelación.

1. Marco Teórico

1.1 Antecedentes de una Red Neuronal Artificial (RNA)

El cerebro humano es uno de los órganos que mayor fascinación ha causado a los científicos siendo objeto de modelización y simulación desde la aparición de los primeros ordenadores (Lahoz, 2004). La posibilidad de construir una máquina que pueda emular al cerebro humano, sigue siendo una gran tarea, desde mediados de los años 40 el resultado fue el nacimiento de una área de investigación prometedora en Inteligencia Artificial nombrada como Redes Neuronales Artificiales. Una RNA es un modelo conexionista cuyos elementos o nodos, conectados entre sí simulan las funciones desempeñadas por las células cerebrales denominadas neuronas.

En el año 1943 McCulloch y Pitts propusieron la primera red neuronal, su red estaba basada en el concepto de autómeta, sin embargo, esta red neuronal carecía de la posibilidad de aprendizaje, una de las funciones más características del cerebro humano. La primera RNA con la capacidad de poder aprender fue el perceptrón en 1962 propuesta por Rosenblatt, mediante la modificación adaptativa de las conexiones entre neuronas. A finales de los años 80 y a principios de los 90, la popularidad de las RNA condujo que se propusiera el término computación neuronal que ha sido empleado por algunos especialistas para referirse al área de Inteligencia Artificial, dedicada al estudio de las Redes Neuronales Artificiales. En la década de los 90 se publicaron numerosas obras sobre RNA destacando por su rigor y detalle de los dos volúmenes de la obra *Parallel Distributed Processing* (Rumelhart, Hinton y McClelland, 1986) una de las referencias clásicas. Las RNA sorprendentemente muestran muchas funciones del cerebro humano, capaces de aprender, memorizar un conjunto de patrones, clasificarlos, inferir o clasificar a que clase pertenece un nuevo objeto a partir de la experiencia acumulada por la red neuronal durante el reconocimiento de otros previos, siendo por tanto capaces de reconocer símbolos, tales como letras y números o cualquier objeto o patrón. La fascinación por los resultados obtenidos con las RNA ha conducido que psicólogos y biólogos, entre otros especialistas

hayan intentado entender el cerebro humano y animal a partir de los modelos computacionales de las RNA.

1.2 Fundamento Biológico de las Redes Neuronales Artificiales

Las neuronas son las células que conforman el cerebro humano. Con un tamaño variable y comprendido entre 3 y 1.000 μm son células excitables, al exhibir la propiedad de transmisión de señales de una neurona a otra. La estructura de una neurona está conformada por el soma o cuerpo celular, el axón y las dendritas como se muestra en la figura 1.




Figura 1. Estructura de una neurona biológica (Lahoz, 2004).

En términos generales, las dendritas y el cuerpo celular reciben señales de entrada; el cuerpo celular las combina e integra y emite señales de salida. El axón transporta esas señales a los terminales axónicos, que se encarga de distribuir la información a un nuevo conjunto de neuronas. Por lo general, una neurona recibe información de miles de otras neuronas y a su vez envía información a miles de neuronas más (Lahoz, 2004).

Si se considera un modelo general de una neurona que incluya las características entrada y salida de un modelo, entonces las dendritas o ramificaciones representan en la neurona las estructuras responsables de la recepción de las

señales de entrada. Una vez procesadas por la neurona las señales de entrada, producirá dos tipos de señales una de ellas eléctrica que se denomina potencial de acción, cuyo origen se sitúa en la unión del soma y el axón es el resultado de la despolarización de la membrana. Como todas las células es capaz de mantener en su interior un líquido, cuya composición difiere marcadamente de la composición del líquido del exterior. La diferencia radica en las concentraciones de los iones de K^+ y Na^+ . El medio externo es unas 10 veces más rico en Na^+ que el interno, mientras que el medio interno es unas 10 veces más rico en K^+ que el externo. Esta diferencia de concentraciones produce un potencial de aproximadamente 70 milivoltios, negativo en el interior de la célula (Flores. 2008). Dicho fenómeno implica la salida de K^+ desde el interior del axón hasta el medio exterior y la entrada de Na^+ desde el medio exterior hasta el interior del axón, invirtiendo la polaridad de la membrana en dicha región, siendo la carga positiva en el interior y la carga negativa en la parte exterior.

El segundo tipo de señal que genera la neurona es químico, concretamente se realiza mediante moléculas de sustancias transmisoras (neurotransmisores) que fluyen a través de unos contactos especiales llamados sinapsis, que tienen la función de receptor y están localizados entre los terminales axónicos y las dendritas de la neurona siguiente.

Existe dos tipos de sinapsis: a) las sinapsis excitadoras, cuyos neurotransmisores provocan disminuciones de potencial en la membrana de la célula postsináptica, facilitando la generación de impulsos a mayor velocidad y b) las sinapsis inhibitoras, cuyos neurotransmisores tienden a estabilizar el potencial de la membrana, dificultando la emisión de impulso. Casi todas las neuronas reciben entradas procedentes de sinapsis excitadoras e inhibitoras. En cada instante, alguna de ellas estarán activadas y otras se hallarán en reposo; la suma de los efectos excitadores e inhibidores determina si la célula será o no estimulada es decir, si emitirá o no un tren de impulsos y a qué velocidad (Lahoz, 2004). Algunos aspectos para la similitud directa entre la actividad sináptica y la análoga con las redes neuronales artificiales son que las señales que llegan a la sinapsis son las

entradas a la neurona; estas son ponderadas (atenuadas o amplificadas) a través de un parámetro, denominado peso, asociado a la sinapsis correspondiente.

Estas señales de entrada pueden excitar a la neurona (sinapsis con peso positivo) o inhibirla (sinapsis con peso negativo). El efecto es la suma de las entradas ponderadas. Si la suma es igual o mayor que el umbral de la neurona, entonces la neurona se activa y por consecuencia genera una salida. Esta es una situación de todo o nada cada neurona se activa o no se activa.

1.3 Definición de Red Neuronal Artificial

Una RNA es un algoritmo de cálculo que se basa en una analogía del sistema nervioso. La idea general consiste en emular la capacidad de aprendizaje del sistema nervioso, de manera que la RNA aprenda a identificar un patrón de asociación entre los valores de un conjunto de variables predictoras (*entradas*) y los estados que se consideran dependientes de dichos valores (*salidas*) (Agatonovic y Beresford, 1999).

También se podrían definir a las RNA como, modelos matemáticos simplificados de las redes de neuronas que constituyen el cerebro humano. Estos modelos están compuestos por un conjunto de “neuronas artificiales” o conjunto de unidades que procesan e intercambian información utilizando un enfoque conexionista a la computación (Chen y Shaw, 2009).

1.4 Red Neuronal de Propagación del Error Hacia Atrás (Backpropagation)

En 1986 fue dada a conocer la red neuronal de Propagación del error hacia atrás por Rumelhart, Hinton y Williams, convirtiéndose rápidamente en un modelo clásico por sus aplicaciones y su elegancia formal. Esta red neuronal requiere de una o más capas de neuronas intermedias u ocultas. La principal aportación de los autores previamente nombrados fue la generalización de la regla delta o regla de Widrow del Perceptrón, por lo cual esta nueva regla es llamada la regla delta generalizada (Lahoz, 2004).

La aplicación de la regla delta generalizada requiere dos fases. En la primera fase, las entradas se propagan hacia adelante a la unidad o unidades de salida, donde se calcula el error de la red. En la segunda fase el error calculado se propaga de la neurona de salida hacia atrás a través de la red y se utiliza para la adaptación de las conexiones de los pesos entre neuronas artificiales que minimicen una medida del error durante el aprendizaje. Debido a la segunda fase de este procedimiento, esta red neuronal es nombrada como la propagación del error hacia atrás (Henseler, 1995). Este tipo de red también se caracteriza por que la regla de aprendizaje incorpora un agente supervisor que evalúa a la red enseñándole como debería corregir su comportamiento dinámico durante el aprendizaje

1.4.1 Red Multicapa

Las RNA multicapas están constituidas por una serie de procesadores elementales denominados neuronas artificiales, a las que es frecuente referirse con el nombre de nodos. Constituyen dispositivos simples de cálculo, que vienen procedente de un vector de entrada de un mundo externo, a partir de estímulos de otras neuronas (Hilera, 1995). Proporciona una única respuesta (salida), generalmente se pueden encontrar tres tipos de neuronas artificiales como se muestra en la figura 2 las cuales son:

- Las neuronas de entrada que reciben señales desde el entorno, proveniente de sensores o de otros sectores del sistema (como archivo de almacenamiento de patrones de aprendizaje).
- Las neuronas ocultas o intermedias que reciben estímulos y emiten salidas dentro del sistema, sin mantener contacto ninguno con el exterior. En ellas se llevan a cabo el procesamiento básico de información. Las neuronas de la capa oculta pueden estar interconectadas de distintas maneras, lo que determina las distintas topologías de redes neuronales.

- Las neuronas de salida procesan la información que reciben y envían una señal directamente fuera del sistema una vez finalizado el tratamiento de la información (salidas de la red).

Estas unidades de procesamiento como ya se describieron anteriormente se encuentran en un nivel o capa diferente en la RNA. Se conoce como capa al conjunto de neuronas cuyas entradas provienen de la misma fuente y cuyas salidas se dirigen al mismo destino como se representa en la figura 2.

Una red de múltiples capas como lo es la red de propagación del error hacia atrás consiste en capas consecutivas, es decir una capa cero de neuronas de entrada, más capas con neuronas ocultas y una capa de neuronas salida. La salida de la capa de entrada se presenta a la primera capa oculta. Las neuronas en una capa oculta que no reciben entradas de la capa de entrada, están conectadas a las neuronas de una capa oculta anterior. Por lo tanto la salida de una neurona oculta se envía a la siguiente capa que puede ser otra capa oculta o la capa de salida. Finalmente la capa de salida envía su salida para el medio exterior. Una red de múltiples capas que consiste en N capas se representa en la figura 2.

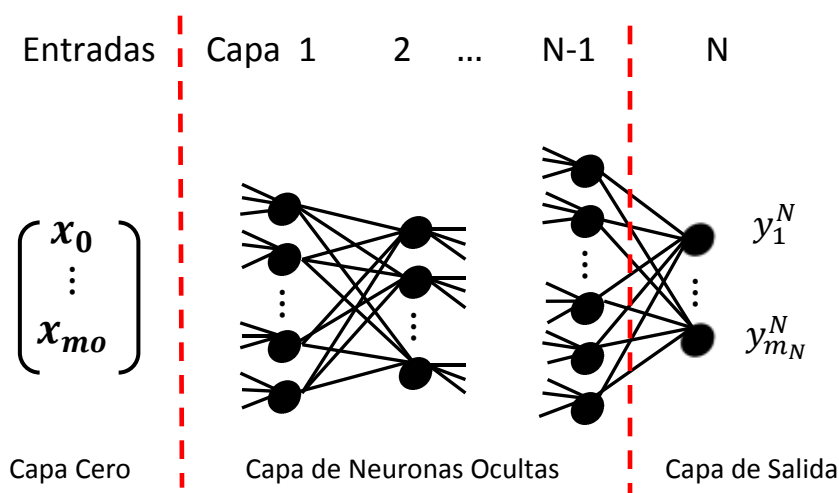


Figura 2. Representación de una red multicapa de N capas (Henseler, 1995).

La conexión entre la neurona i -ésimo en la capa p con la neurona j -ésimo en la capa $p-1$ en una red multicapa, tiene un peso ω_{ij}^p denotado por un valor numérico mediante el cual la red adquiere conocimiento (Lahoz, 2004), como se muestran en la figura 3, el número de neuronas en las capa está indicado m_p .




Figura 3. Organización de las conexiones de los pesos correspondientes a una neurona i .

Las salidas de la red se obtienen mediante la propagación de las entradas a través de las capas consecutivas (figura 2) hasta que llega a la capa de salida. Por lo tanto, este procedimiento se conoce como propagación hacia adelante.

Si las entradas i -enésima de las neuronas en la capa p son $y_1^{p-1}, \dots, y_{m_{p-1}}^{p-1}$ (es decir, las salidas de la capa $p-1$) con los pesos correspondientes $\omega_{i1}^p, \dots, \omega_{im_{p-1}}^p$ al considerar que la información es aditiva las entradas neta que recibe una neurona (σ) es la suma del producto de la información individual por el valor del peso que conecta ambas neuronas que se determina con la siguiente ecuación.

$$\sigma_i^p = \sum_{j=1}^{m_{p-1}} \omega_{ij}^p y_j^{p-1} \quad (1)$$

Cada neurona donde se procesa la información como son las neuronas de las capas ocultas y de salida deben de generar una salida, que transforme el estado

actual de activación de cada neurona en una señal de salida y_i^p para la cual se requiere una función de transferencia f que tiene que ser no decreciente y derivable como es el caso de la función sigmoidea (figura 4).




Figura 4. Gráfica de la función sigmoideal.

La función sigmoidea determina el estado de activación de una neurona artificial asumiendo que dicho estado se encuentra en un intervalo de $[0,1]$ como se muestra en la figura 4, y es necesaria para la determinación de la salida y_i^p ecuación 2.

$$y_i^p = f(\sigma_i^p) = \frac{1}{1+e^{-\sigma_i^p}} \quad (2)$$

Esto resulta en una red multicapa de neuronas de cálculo, con la función de transferencia sigmoidea f de la suma ponderada σ_i^p de sus entradas (Rumelhart et al., 1986).

1.4.2 Regla Delta Generalizada

El procedimiento de la propagación del error hacia atrás (Rumelhart et al., 1986) es esencialmente un método de gradiente descendente que minimiza el error E mediante la adaptación de pesos. El error se mide como la suma de los errores cuadráticos de la respuesta actual y_k^N y la respuesta deseada (agente supervisor) Y_i de la neurona en la capa de salida como se muestra en la ecuación 3.

$$E = \frac{1}{2} \sum_{k=1}^{m_N} (y_k^N - Y_i)^2 \quad (3)$$

La superficie de error se define como una función de los parámetros de red, es decir los pesos. El error E se reduce al mínimo por un cambio (Δ) en los pesos, en la dirección del descenso de gradiente, o bien es proporcional al gradiente negativo de E , se realiza utilizando la siguiente ecuación 4 que se resuelve aplicando la regla de la cadena.

$$\Delta \omega_{ij}^p = -\eta \frac{\partial E}{\partial \omega_{ij}^p} \quad (4)$$

La constante η se llama la tasa de aprendizaje, y es un número real positivo normalmente menor a uno. El aumento de la tasa de aprendizaje cercano a uno, por un lado acelera el proceso de adaptación, pero por otro lado puede hacer que el sistema se vuelva inestable.

El derivado de E con respecto a los pesos que pertenecen a capas ocultas es más difícil de determinar debido a que E se define en términos del error cometido por la capa de salida. Sin embargo, puede ser mostrado que el error en la capa p , lo cual se puede expresar en términos de los errores que se producen en la siguiente capa $p + 1$ y así sucesivamente. Esta derivación introduce un error de Delta δ_i^p para todas las neuronas en la red que se utiliza para calcular los componentes del gradiente de error.

$$\frac{\partial E}{\partial \omega_{ij}^p} = \delta_i^p y_j^{p-1} \quad (5)$$

El error delta δ_i^p se define como la derivada parcial de E con respecto a la entrada neta σ_i^p de la neurona i en la capa p.

$$\delta_i^p \stackrel{\text{def}}{=} \frac{\partial E}{\partial \sigma_i^p} \quad (6)$$

La derivada parcial $\partial E / \partial \sigma_i^p$ es de hecho una medida para el cambio deseado en la salida de la neurona específica j con el fin de reducir al mínimo a E. El error delta se extiende a través de la red de vuelta de la última capa hacia la primera capa oculta, inmediatamente después a la capa de entrada por un proceso de propagación hacia atrás.

El valor calculado de δ_i^p en la ecuación 6 es el resultado de la regla delta generalizada que se puede utilizar para el cálculo de los pesos $\omega_{ij}^p(t)$ en función de su valor en la iteración anterior $t - 1$ y el error:

$$\omega_{ij}^p(t) = \omega_{ij}^p(t-1) - \eta \delta_i^p y_j^{p-1} \quad (7)$$

$$\delta \begin{cases} \delta_i^p = y_i^p (1 - y_i^p) \sum_{k=1}^{m_{p+1}} \omega_{ik}^N \delta_k^N & 1 < p < N \\ \delta_k^N = y_k^N (1 - y_k^N) (y_k^N - Y_i^N) & p = N \end{cases} \quad (8)$$

Se observa que el factor de $y_i^p (1 - y_i^p)$ en el cálculo del error delta en una capa oculta ($1 < p < N$) y de salida ($p = N$), corresponde a la derivada de la función sigmoidea (ecuación 2). Es decir, se puede demostrar que para la derivada de una función sigmoidea $f(x)$ con respecto a x se mantiene $f'(x) = f(x)(1 - f(x))$.

1.4.3 Mínimos locales

El procedimiento de gradiente descendiente que utiliza la red neuronal de propagación del error hacia atrás, busca un error mínimo en la superficie de error. Cada punto de la superficie de la función del error corresponde a un conjunto de valores de los pesos de la red. Una vez que se alcance el mínimo que no hay forma de salir, sin tener en cuenta el hecho de que pueda existir otro mínimo mejor. Si existe un mejor mínimo entonces la posición actual se encuentra en un mínimo local del espacio de error. Sin embargo, si es el punto más bajo entre todos se habla de un mínimo global figura 5 y 6.

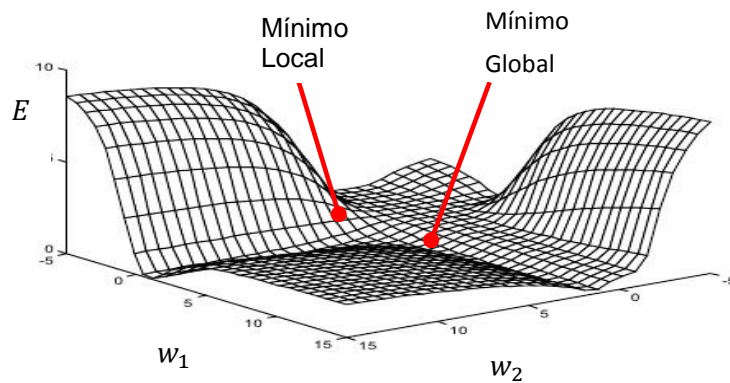


Figura 5. Grafica de la superficie del error mostrando un mínimo local y un global.




Figura 6. Representación de una forma de la superficie de error, donde w representa los posibles valores de la matriz de pesos de la red.

La posible aparición de los mínimos no globales puede conducir fácilmente a una falla de la búsqueda del descenso de gradiente. Si se produce esta situación se podría tratar a partir de un ajuste de peso inicial diferente.

1.4.4 Aplicaciones

La red neuronal de propagación del error hacia atrás es una herramienta eficaz para modelar un proceso complejo, donde la información incluye una relación no lineal lo cual es común en la Ingeniería de alimentos (Zueco, Alhama y Gonzalez, 2004). En la tabla 1 se muestran algunas aplicaciones en el procesamiento de alimentos.

Tabla 1. Aplicaciones de la red de propagación del error hacia atrás en Ingeniería de Alimentos (Weibiao, 2009).

Modelo de Red	Aplicación	Neuronas de Entrada	Neuronas de Salida	Referencia
Propagación del error hacia atrás	Predicción de la velocidad y tiempo de congelación.	Espesor, ancho, longitud del producto, coeficiente de transferencia de calor, conductividad, densidad y el calor específico, contenido de humedad, la temperatura inicial del producto y la temperatura ambiente.	Tiempo de Congelación	(Mittal y Zhang, 2000)
	Predicción de la conductividad eléctrica de la variación de las composiciones de leche recombinada.	Contenido de grasa, contenido de proteínas, lactosa y la temperatura	Conductividad eléctrica de la leche recombinada.	(Therdthai y Zhou 2001)
	Predicción del potenciador en el sabor de los alimentos.	Conjunto de datos de la matriz ortogonal que contiene espectros de absorción en los rangos de 200 a 350 nm	El contenido del maltol, etil maltol, etil vainillina y vainillin	(Ni, Zhang y Kokot, 2007)
	Predicción de la temperatura y contenido de humedad del proceso de ahumado	proporción de proteína-grasa, contenido de humedad, temperatura inicial, la temperatura ambiente, el tiempo de proceso y la humedad relativa	El contenido promedio de humedad, la temperatura media y la temperatura central	(Mittal y Zhang, 2000)
	Clasificación de la miel mediante la señal olfativa	información de los sensores de gas de semiconductor y el sensor de flujo de gas	Calidad aromática diferente de la miel	(Linder y Poppl y 2003)
	Clasificación binaria de microorganismos condición de crecimiento y supervivencia	Temperatura, pH, concentración de ácido acético, la concentración de sacarosa y de sal	Eliminación o supervivencia de microorganismos	(Yu, Davidson y Yang, 2006)
	Predicción de vida útil de los aperitivos de arroz	Características de los alimentos, las propiedades del empaque, condiciones de almacenamiento	Vida útil	(Siripatrawan y Jantawat, 2008)
	Predicción de proceso de alta presión.	La presión aplicada, la tasa de compresión, temperatura ajustada, la temperatura ambiente.	Temperatura y tiempo.	(Torrecilla, Otero y Sanz, 2007)

En la última década esta red por su gran versatilidad ha sido empleada en el campo de la ingeniería en alimentos, para el control, optimización y determinación de diferentes parámetros entre ellos los termodinámicos como es el calor específico, durante el procesamiento de productos alimenticios (Hanrahan, 2009).

1.5 Calor Específico

La transferencia de calor está presente en el procesamiento de alimentos, es necesaria la evaluación de diferentes propiedades térmicas en las cuales se encuentra el calor específico.

El calor específico es una propiedad intensiva que se refiere a la cantidad de calor que se gana por una unidad de masa para lograr un cambio unitario en la temperatura (Paul y Heldman, 2014).

$$C_p = \frac{Q}{m(\Delta T)} \quad (9)$$

Dónde:

Q= ganancia o pérdida de calor (kJ)

m= masa (kg)

ΔT = cambio de temperatura en el material (°C)

C_p = calor específico (kJ / [kg °C]).

El calor específico es una parte esencial del análisis térmico del procesamiento de alimentos o de los equipos utilizados en el calentamiento o de refrigeración. Esta propiedad está en función de los diversos componentes que constituyen un alimento, su contenido de humedad, temperatura y presión. El calor específico aumenta a medida que el contenido de humedad del producto aumenta. En la mayoría de las aplicaciones de procesamiento, se utiliza el calor específico a presión constante, excepto en el procesamiento de alta presión. En el diseño de los procesos y equipos de procesamiento, es necesario contar con valores numéricos del calor específico del alimento y los materiales que se utilizaran.

Se pueden determinar valores de calor específico utilizando ecuaciones empíricas, obtenidas por los datos experimentales de ajuste en modelos matemáticos. Típicamente, estos modelos matemáticos se basan en uno o más constituyentes del alimento y dado que el agua es uno de los más importantes, muchos de estos modelos se expresan en función del contenido de agua.

Uno de los primeros modelos para determinar el calor específico fue propuesto por Siebel (1892) lo cual resultó en la siguiente ecuación.

$$C_p = 0.837 + 3.349X_w \quad (10)$$

Dónde:

X_w = el contenido de agua expresado como una fracción.

Este modelo no muestra el efecto de la temperatura o de otros componentes de un producto alimenticio. La influencia de los componentes del producto se expresó en una ecuación empírica propuesta por Charm (1978) como:

$$C_p = 2.093X_f + 1.256X_s + 4.187X_w \quad (11)$$

Donde X es la fracción de masa, y los subíndices f es la grasa, s es el extracto seco magro, y w es el agua. Heldman y Singh (1981) propusieron la siguiente expresión basada en los componentes de un producto alimenticio:

$$C_p = 1.424X_h + 1.549X_p + 1.675X_f + 0.837X_a + 4.187X_w \quad (12)$$

Donde X es la fracción de masa; los subíndices en el lado derecho son:

h= hidratos de carbono

p= proteínas

f= grasa

a= ceniza

w= humedad

Las anteriores ecuaciones no incluyen una dependencia de la temperatura. Sin embargo, para los procesos donde existen cambios de temperatura, hay que utilizar modelos predictivos de calor específico, que incluyen la dependencia de la temperatura.

Choi y Okos (1986) presentan un modelo integral para predecir calor específico basado en la composición y la temperatura. Su modelo es el de la siguiente manera:

$$C_p = \sum_{i=1}^n C_{p_i} X_i \quad (13)$$

Donde X_i es la fracción del componente i -ésimo, n es el número total de componentes en un alimento, y C_{p_i} es el calor específico del componente i -ésimo en función de la temperatura.

Existe otra forma en determinar el calor específico por medio de la técnica de calorimetría diferencia de barrido modulada que está relacionada con la medición de los cambios de energía en los materiales.

1.5.1 Calorimetría Diferencial de Barrido Modulada

La calorimetría diferencial de barrido modulada (MDSC) se ha utilizado para medir, como una función de la temperatura, la diferencia en las entradas de energía entre una sustancia y su referencia, con ambos materiales que están siendo sometidos a un programa de temperatura controlada (Biliaderis, 1983).

La mayoría de los diseños comunes para hacer mediciones de calorimetría diferencial de barrido (DSC) y MDSC están diseñados con un flujo de calor cuya representación esquemática se presenta en la Figura 7. El esquema es similar al diseño de celda usado en los equipos de TA Instruments.




Figura 7. Conformación de una celda de un calorímetro MDSC (Meuter, Rahie, y Mele 1999).

En este diseño, un disco metálico hecho de aleación de constantán es el principal medio de transferencia de calor hacia la muestra y la referencia. La muestra contenida en un recipiente de metal y la referencia en un mismo recipiente pero vacío, están posadas en plataformas elevadas formadas en el disco constantán. Como el calor se transfiere a través del disco, el flujo de calor diferencial para la muestra y la referencia se mide mediante termopares de chromel y alumel en el disco de constantán, (Verdonck, Schaap y Thomas, 1999) .

Los termopares están conectados en serie para medir el flujo de calor diferencial utilizando el equivalente térmico de la ley de Ohm:

$$Q = \frac{\Delta T}{R_D} \quad (14)$$

Dónde:

Q = es el flujo de calor (w/m^2)

ΔT = gradiente o diferencial de temperatura entre la muestra y la referencia ($^{\circ}K$)

R_D =resistencia térmica del disco de constantán ($m^2\text{°K/w}$)

El gas de purga es suministrado en la cámara de muestras a través de un orificio en el bloque de calentamiento antes de entrar en la cámara de muestras. El resultado es un ambiente térmico estable uniforme, que asegura una buena sensibilidad por la calibración. El régimen de temperatura visto por la muestra y referencia es de calentamiento o enfriamiento. La MDSC es una extensión de la técnica de calorimetría diferencial de barrido (DSC), la cual supera las limitaciones de DSC las cuales son:

1. El análisis de transiciones complejas
2. La necesidad de incrementar la sensibilidad
3. La necesidad de aumentar la resolución

La MDSC aplica un perfil de calentamiento diferente a la muestra y referencia. Específicamente es una modulación sinusoidal se superpone en el calentamiento lineal convencional o rampa de enfriamiento para producir un perfil en el que la temperatura promedio de la muestra cambia continuamente con tiempo pero no en una forma lineal (Schawe, 1996).

Aunque los cambios de temperatura real de la muestra son de una manera sinusoidal durante este proceso, las señales analizadas se representan en última instancia, en comparación con una temperatura lineal, que se calcula a partir del valor medio medido por el termopar de la muestra.

La ecuación general que describe el flujo de calor resultante en cualquier punto del experimento es:

$$\frac{dH}{dt} = C_p \left(\frac{dT}{dt} \right) + f(T,t) \quad (15)$$

Dónde:

dH/dt = al flujo de calor total (cuyas unidades son mW o W/g) debido a la velocidad de calentamiento lineal.

C_p = es el componente de capacidad calorífica del flujo de calor total y se calcula con el calor específico ($J/g^{\circ}C$) por masa de la muestra (g).

dT/dt = es la velocidad de calentamiento medida ($^{\circ}C/s$).

$f(T,t)$ = es la componente cinética (mW o W/g)

De la ecuación 15, el flujo de calor total, medida también mediante DSC convencional, se organiza de dos componentes: (1) la capacidad de calor de la muestra y la tasa de cambio de temperatura y (2) temperatura absoluta y el tiempo. El componente de capacidad de calor $C_p dT/dt$, se conoce como el flujo de calor reversible, mientras que el componente cinético se conoce como de flujo de calor no reversible (Murase et al., 2002). Debido a la velocidad de calentamiento modulado, existe una curva de flujo de calor modulado resultante, y el flujo de calor total registrado como el resultado cuantitativo final se calcula de forma continua como la media móvil de la señal de flujo de calor modulado en bruto. El componente del flujo de calor reversible total se calcula multiplicando la capacidad de calorífica medida con el promedio de la velocidad de calentamiento utilizado en el experimento (Boller, Schick y Wunderlich, 1995). El flujo de calor no reversible total o componente cinético se determina como la diferencia aritmética entre el flujo de calor total y el componente de capacidad de calor. La calorimetría diferencial de barrido puede ser utilizada para la determinación de varias propiedades características de una muestra. Usando esta técnica es posible caracterizar propiedades termodinámicas como calor específico entalpía de fusión entre otras así como también diferentes procesos como la fusión y la cristalización. De igual forma se pueden apreciar comportamientos de propiedades termodinámicas en los alimentos, al someterlos algún proceso de transformación al aumentar o disminuir la temperatura como es el caso de la congelación y descongelación de la carne.

1.6 Congelación de la Carne y sus Efectos

La carne es definida como la estructura compuesta por fibra muscular estriada, acompañada o no de tejido conjuntivo elástico, grasa, fibras nerviosas, vasos linfáticos y sanguíneos, de las especies animales autorizadas para el consumo humano (NOM-009-ZOO-1994). El valor nutritivo de la carne de cerdo es señalado como uno de los alimentos más completos y de gran importancia en la dieta humana, debido a su gran aporte de proteínas. Por su composición química como la muestra la tabla 2, la carne es un alimento perecedero ya que es un buen medio en donde proliferan los microorganismos por su alta humedad, pH cercano al neutro y abundancia de nutrimentos. Por lo cual es necesaria la aplicación de un método de conservación el cual minimice las pérdidas de nutrimentos, la carga microbiana, la actividad enzimática y asegure una buena calidad del producto final.

La congelación es adecuada como método de conservación para la carne, la cual se logra sin el uso de conservantes o de calentamiento que altere de una forma significativa la estructura nativa de proteínas y las características de la carne (Xanthakis, Havet, y Chevallier 2013).

Tabla 2. Composición química de la carne de cerdo (*Longissimus Dorsi*).

Componente	Porcentaje (%)
Agua	75
Proteínas	20
Lípidos	3.4
Carbohidratos	1.6

(Rodríguez, 2008)

La congelación es un proceso que consiste en la aplicación de temperaturas bajas a un alimento, hasta que la mayor parte del agua de constitución, se transforme en cristales de hielo (Duno, 1996).

La congelación consta de tres etapas las cuales son:

1. Enfriar el producto a su punto de congelación (pre-enfriamiento o la etapa de enfriamiento).
2. La eliminación del calor latente de cristalización (etapa de transición de fase).
3. Subenfriamiento del producto a la temperatura de almacenamiento (etapa de templado).

La parte de transición de fase del proceso de congelación implica la conversión de agua en hielo a través del proceso de cristalización y es el paso clave que determina la eficiencia del proceso y la calidad del producto congelado. Una de las propiedades térmicas que es muy importante en la congelación es el calor específico mencionado anteriormente, el cual es requerido para crear, controlar y optimizar equipos de congelación, como también en la determinación del tiempo y tipo de congelación (rápida o lenta) de igual forma es requerido para balances de materia y energía asimismo la determinación de diferentes propiedades térmicas en los alimentos (Paul y Heldman, 2014).

La congelación de los tejidos en la carne se inicia por la cristalización del agua en los espacios extracelulares puesto que la concentración de soluto es menor que en los espacios intracelulares. En la congelación de la carne la formación de grandes cristales de hielo que son en su mayoría extracelular producidos por una congelación lenta, resulta en daños significativos a los tejidos. Por otra parte, la formación de cristales finos que se distribuyen de manera uniforme tanto dentro como fuera de las células resultantes de una congelación rápida, conduce a la calidad del producto a ser mejor conservado debido a que proporciona menos daños al tejido (Sun y Zheng , 2006).

El proceso de cristalización consta de dos principales etapas sucesivas; nucleación y crecimiento de cristales. La interacción entre estos dos pasos determina las características de los cristales, como su tamaño, la distribución y su morfología. La cristalización es un fenómeno termofísico importante a través del

cual una sustancia forma cristales debido al subenfriamiento o sobresaturación. La etapa de nucleación se define como la formación de un nuevo cristal y ocurre ya sea en una solución libre de cristales, que se llama nucleación primaria, o en la presencia de cristales creados anteriormente, que se define como nucleación secundaria. La nucleación primaria puede ser homogénea, si la solución no contiene partículas extrañas sólidas ni cristales o heterogénea si presenta partículas extrañas o cristales. Sin embargo, la nucleación heterogénea es la nucleación dominante (Zaritzky et al., 2006).

En el caso de nucleación primaria, y especialmente para la homogénea, se requiere por lo general de gran fuerza impulsora que es el subenfriamiento. La nucleación secundaria se produce por la ruptura de los cristales, debido a las colisiones entre ellos y la eliminación de capas superficiales semiordenadas (Myerson, 2002).

Después de la formación de los núcleos, el siguiente paso del proceso de cristalización es el crecimiento de cristales. Los pocos cristales iniciales que aparecieron al comienzo proporcionan una estructura sobre la cual todo el material se deposita en la forma de cristales (Mersmann, 2001). Este crecimiento es controlado por la forma y dirección de la remoción del calor en el sistema liberándose calor específico del líquido y calor latente de fusión. La principal fuerza impulsora de la cristalización es la reducción de la temperatura. El tamaño de los cristales de hielo es crucial para la calidad final de la carne ya que pueden causar un daño irreversible a la estructura celular que a su vez degrada la textura, color, sabor, y el valor nutricional. Todos estos parámetros son influenciados por la congelación, el almacenamiento y su posterior descongelación.

En la congelación y descongelación influye principalmente la fracción de agua que contiene la carne. Como el agua se congela, la concentración de los solutos restantes (proteínas, carbohidratos, lípidos, vitaminas y minerales) aumenta, alterando de esta manera la homeostasis del sistema de la carne (Lawrie, 1998). Algunos atributos de la carne que se vean afectados por la congelación y su descongelación los cuales percuten en la calidad de la carne son los siguientes.

Humedad

La congelación y descongelación alteran tanto el contenido y la distribución de la humedad en el tejido, también se sabe que afectan la cantidad de exudado (pérdida por goteo). Se ha encontrado que la pérdida en la capacidad de retención de agua está relacionada con la perturbación de la estructura de las fibras del músculo, así como la modificación o la desnaturalización de las proteínas. La composición del goteo en su mayoría son de proteínas sarcoplásmicas (Savage, Warris, y Jolley 1990).

Desnaturalización de proteínas

Se ha pensado tradicionalmente que la desnaturalización de proteínas podría resultar durante la congelación debido a un aumento de la fuerza iónica intracelular después de la migración de agua a los espacios extracelulares. Tras el análisis de muestras de carne para la desnaturalización de proteínas utilizando DSC, Wagner y Añón (1985) reportaron que la miosina fue la proteína más afectada por la congelación. Las proteínas miofibrilares fueron desnaturalizadas causándose desdoblamiento, estos investigadores llegaron a la conclusión de que la congelación lenta provoca desnaturalización de las proteínas más pronunciada que la congelación rápida.

La oxidación de lípidos y proteínas

La temperatura final a la que la carne se congela y almacena si es superior a los -20 °C todavía contiene una cantidad de agua no congelada que permanece disponible para reacciones químicas. La congelación provoca un aumento en la concentración de soluto tanto intracelularmente como extracelularmente, por ende el aumento de la reactividad química durante el almacenamiento congelado (Fennema, 1975). La fracción de agua no congelada también es importante en términos de la oxidación, ya que pueden producirse reacciones químicas durante el almacenamiento como la oxidación lipídica primaria (peroxidación) en la carne. Esto puede conducir a la oxidación lipídica secundaria de radicales libres, tras la

descongelación que conduce a cambios adversos en el color, olor y el sabor (Owen, y Lawrie 1975). La oxidación de proteínas puede estar vinculada a cualquiera de los factores pro-oxidantes, tales como lípidos oxidados, los radicales libres, pigmentos hemo y enzimas oxidativas.

El malonaldehído es uno de los sustratos que reaccionan con derivados de la proteína para formar carbonilos (cetonas y aldehídos) (Xiong, 2000). Las proteínas y la oxidación de los lípidos son, por lo tanto, sin duda interrelacionadas. La oxidación de proteínas en la carne puede llevar a la disminución de la calidad durante el consumo, debido a la menor ternura, jugosidad, el deterioro del sabor y la decoloración (Rowe, Maddock , O'Lonegan , y Huff - Lonegan , 2004) .

Color

La mioglobina se ha identificado en exudado por electroforesis en gel, lo que representa, en parte el cambio de la estabilidad del color de la carne después de la congelación y descongelación (Anon y Cavelo, 1980). La desnaturalización de la fracción de globina de la molécula de mioglobina tiene lugar en algún momento durante la congelación, almacenamiento y descongelación (Calvelo, 1981).

La desnaturalización conduce a un aumento en la susceptibilidad de la mioglobina a la auto-oxidación y la subsiguiente pérdida de presentación de color. Esta teoría ha sido verificada por muchos autores al comparar el grado de coloración y la capacidad de la carne para resistir la oxidación a metamioglobina durante la congelación y descongelación (Abdallah, Marchello, y Ahmad, 1999, y Farouk y Swan 1998).

Cuando se inicia la oxidación de lípidos resulta en la formación de pro-oxidantes capaces de reaccionar con oximioglobina, que a su vez conduce a la formación de metamioglobina. La misma lógica se aplica a la oxidación de proteínas (Farouk y Swan, 1998). La oxidación en consecuencia, se puede comparar con una reacción en cadena dentro de la carne, iniciado por la fracción lipídica. Si la oxidación de lípidos se acelera por el almacenamiento congelado, esto aumentaría la cantidad de radicales libres presentes, que conduce a un aumento de la tasa de oxidación

de la mioglobina haciendo que la metamioglobina comience a acumularse en la superficie de la carne a un ritmo rápido (Abdallah, Marcello y Ahmad, 1999), lo que explicaría por qué se observa una disminución más rápida de la estabilidad del color después de la congelación de la carne (Xiong, 2000).

Escarcha

Cuando se almacenan los alimentos a temperatura de congelación y no se controla las aperturas de puertas de las instalaciones de refrigeración adecuadamente o después de descongelar los alimentos, estos tienen contacto con aire caliente y húmedo contribuyendo a la formación de escarcha.

La formación de escarcha se produce cuando el aire húmedo pasa sobre una superficie cuya temperatura está por debajo de la temperatura de congelación del agua (Fossa y Tanda 2010). Como es el caso durante la descongelación de la carne de cerdo.

El proceso de deposición de la escarcha implica simultáneamente transferencia de masa y calor en condiciones inestables (Cui y Jiang 2010).

Neal y Tree (1984) señalaron que la escarcha podría ser considerada como un medio poroso formado por pequeñas partículas de hielo y aire. Según Hayashi, Aoki y Yuhara (1977), el proceso de formación de escarcha sobre una superficie fría se puede dividir en tres períodos característicos:

1. **Período de crecimiento de los cristales:** Este período corresponde al crecimiento de cada cristal de hielo perpendicular a la superficie fría sin la interacción entre los cristales. El vapor de agua se condensa en la superficie fría y se forman los núcleos de cristalización futuros.
2. **Período de crecimiento de la capa de escarcha:** La incorporación de cristales contribuye a una capa de escarcha, aumentando el espesor con el tiempo. Se caracteriza por la rigidez de una capa porosa. Los cristales de hielo crecen en direcciones diferentes y forman dendritas en forma de aguja. Durante este proceso, el vapor del aire circundante se condensa

entre las dendritas. Después de un cierto tiempo, la capa de escarcha se convierte en un medio poroso con dendritas, gotas de líquido y aire. En este período, la mayoría de la masa transferida desde el aire húmedo a la capa de escarcha contribuye al aumento de la densidad de esta.

3. Periodo pleno de crecimiento o estabilización de la capa de escarcha:

Este aparece cuando la temperatura de la superficie aumenta hasta el punto de fusión del agua (0° C a una atmósfera de presión). Como la escarcha crece, la liberación de calor latente se traducirá en un aumento de la temperatura de la superficie. La escarcha depositada será parcialmente fundida y se filtra a través de los poros de la capa de la escarcha porosa, eventualmente alcanza la superficie fría, donde se congela nuevamente. Este proceso cíclico de condensación, fusión y recongelación continúa hasta que se obtiene un equilibrio térmico.

El proceso de la formación de escarcha en materiales alimenticios complejos como lo es la carne, tiene una gran importancia por la deshidratación superficial que se genera, produciendo pérdida de peso del producto y como consecuencia la modificación de las características de calidad como el color (Laguerre y Fick, 2007) y textura por el daño estructural de las fibras de la carne.

1.7 Color

Los alimentos se evalúan teniendo en cuenta su tamaño, figura, forma, color, condición de frescura y finalmente la ausencia de defectos visuales. El color es el primer atributo de calidad de los alimentos evaluado por los consumidores, y por lo tanto es un componente importante y relevante para la aceptación del mercado (Costa et al., 2011).

El color es una respuesta perceptual mental para el espectro visible de la luz (distribución de la potencia de la luz frente a la longitud de onda) reflejada o emitida por un objeto. Tal señal de respuesta interactúa con la retina del ojo, y se

transmite entonces al cerebro por el nervio óptico, lo que hace que el ser humano asigne colores. Por lo tanto, el color no es una propiedad intrínseca del objeto, ya que si se cambia la fuente de luz, el color del objeto cambia también (Meléndez-Martínez, Vicario y Heredia, 2005). La percepción del color es un fenómeno muy complejo que depende de la iluminación del objeto en su ambiente, de las características del ojo que percibe, el cerebro, los ángulos de iluminación y visualización.

Cuando un alimento como la carne se somete a un cierto proceso de congelación y descongelación, este produce variaciones en el color del producto alimenticio. Será necesaria una medición rápida y objetiva del color durante las operaciones de elaboración y los períodos de almacenamiento, como control de calidad para su clasificación y comercialización (Wu y Sun, 2013).

El análisis por computadora para la medición del color en alimentos es una técnica prometedora actualmente, que proporciona una caracterización detallada de la uniformidad del color en cada píxel de una imagen digital, pueden detectar una muy pequeña cantidad de variación de color y son por lo tanto populares en la evaluación en los productos alimenticios durante el procesamiento, tales como los efectos de los cambios de temperatura y el tiempo de almacenamiento (Lana, Tijsskens y Van Kooten, 2005).

Una diferencia significativa entre el análisis por un programa de cómputo y la colorimetría es la cantidad de información espacial proporcionada. La alta resolución espacial permite la visión por computador para analizar cada píxel de la superficie total, se calcula el promedio, desviación estándar del color, especifica la apariencia, mide las formas y los colores no uniformes, selecciona una región de interés flexible, inspecciona más de un objeto al mismo tiempo, genera el mapa de distribución de color y proporciona un registro permanente manteniendo la imagen (Balaban y Odabasi 2006).

El análisis de color de una imagen digital por medio de software, utiliza diferentes espacios y escalas de color, los cuales están formulados para seleccionar colores y facilitar el procesamiento de datos referentes a ellos (Pascale, 2003).

1.7.1 Sistemas de Espacios de Color

Espacio de color RGB (Rojo, Verde y Azul)

El sistema RGB es producido por cualquier aditivo o de la mezcla sustractiva de los espectros de los tres colores que son el rojo (R), verde (G) y azul (B). Sus correspondientes estímulos primarios monocromáticos se producen en 700, 546 y 436 nm, respectivamente. En un sistema de color digital de 8 bits se cuantifica por triestímulo numéricos R, G, B los valores que van desde 0 (negro) y 255 (blanco). Las combinaciones de R, G, B primarias pueden producir una gama de $(2^8)^3$ diferentes colores (Wyszecki y Stiles, 1982). La gama de colores del sistema forma un cubo que comprende coordenadas cartesianas RGB ortogonales (Figura 19). Cada color se representa entonces por un punto en o en el cubo. Todos los colores grises están presentes en la diagonal principal desde el negro ($R = G = B = 0$) a blanco ($R = G = B = 255$) (Viscarra, Miasby y McMratney 2006).

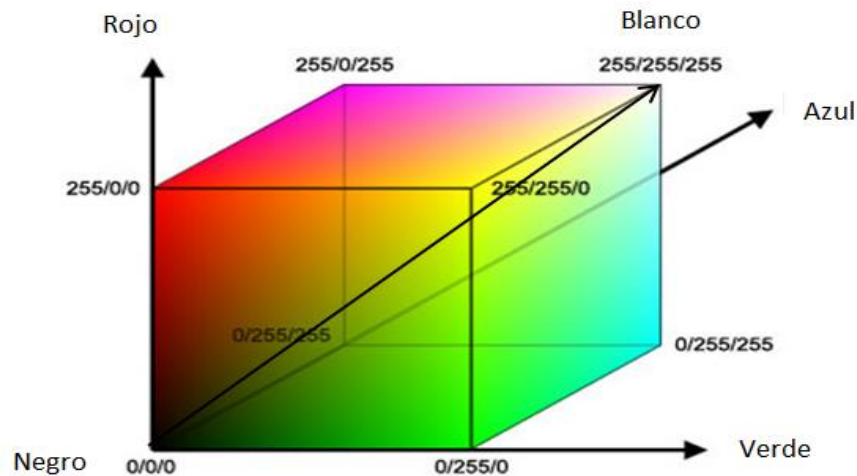


Figura 8. Representación del cubo del espacio RGB.

Espacio de Color CIELab

Es el modelo cromático usado para describir todos los colores que percibe el ojo humano fue desarrollado para superar los problemas del modelo X y Y por la Comisión Internacional de Iluminación (CIE) razón por la cual se abrevia CIELab. Los asteriscos (*) forman parte del nombre ya que representan los tres parámetros L^* , a^* y b^* del modelo (Wyszecki y Stiles, 1982). En la figura 9 se puede observar el espacio CIELab con sus parámetros los cuales se interpretan de la siguiente manera:

- L^* : indica luminosidad expresada como porcentaje desde cero que indica negro hasta 100 que indica blanco.
- a^* : posición del color que va de rojo al verde (valores negativos de $-a^*$ indican verde y valores positivos de a^* indican rojo) con valores que van de -120 a 120.
- b^* : posición entre amarillo y azul valores negativos indican azul y los positivos amarillo los cuales van desde -120 a 120.

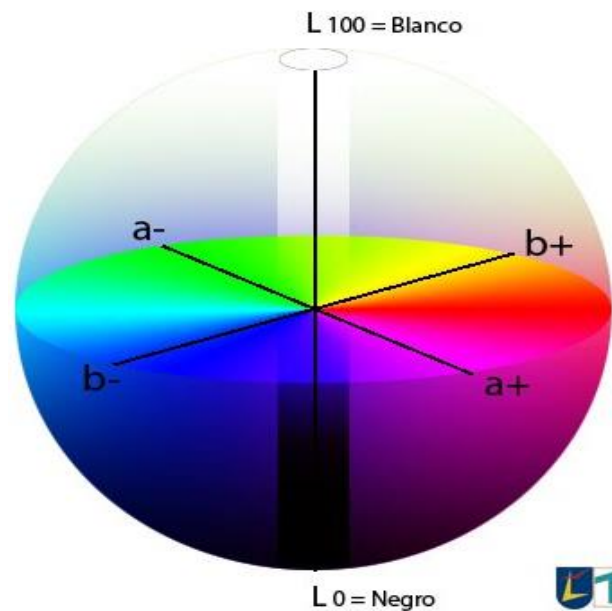


Figura 9. Representación espacial del sistema CIELab.

El espacio CIELab permite especificar estímulos de color en un espacio tridimensional con el eje L^* y las coordenadas colorimétricas a^* y b^* que forman un plano perpendicular a L^* (Viscarra, Miasby, y McMratney 2006).

Escala de Grises

Es una escala de tonos empleada en la imagen digital que utiliza un valor de brillo que comprende un intervalo de tonos en grises que va de blanco (0%) hasta negro (100%) como lo muestra la figura 10, la cantidad de tonos de grises que se puedan determinar dependerá del número de bits que se utilice para cada píxel. Si la imagen es de 8bits solo se podrán obtener 256 tonos (2^8), una imagen de 16bits tendrá 65,536 (2^{16}) y así a medida que aumenten el número de bits. La escala de grises se utiliza para la variación de la tonalidad de cada píxel en una imagen digital y también para poder determinar ciertos parámetros en un análisis de textura de imagen.




Figura 10. Representación de tonalidades de grises desde blanco hasta negro.

1.8 Análisis de Textura de Imagen

Recientemente el análisis de imágenes por programas computacionales que emplea técnicas de procesamiento de imágenes se han desarrollado rápidamente, pueden caracterizar cuantitativamente complejas propiedades como el tamaño, forma, color y textura. Los sistemas de procesamiento de imágenes desempeñan un papel cada vez más importante en la evaluación de la calidad de alimentos, manteniendo la precisión y consistencia al tiempo que elimina la subjetividad de las inspecciones manuales (Cheng y Da-Wen, 2004).

La industria alimentaria se encuentra entre las diez principales industrias que utilizan técnicas de procesamiento de imágenes (Gunasekaran, 1996), que han sido probados con éxito para la evaluación objetiva y no destructiva de varios productos alimenticios como nuggets de pollo, manzana deshidratada, secado de papa entre otros (Timmermans, 1998).

En el análisis de imagen, la textura es un atributo que representa la disposición espacial de los niveles de gris de los píxeles en una región (Anon, 1990).

Los píxeles son los componentes básicos de las imágenes. Hay dos tipos de información contenida en cada pixel, el valor del brillo y las coordenadas de ubicación que se asignan en la imagen.

El concepto de análisis de textura de imagen por programas computacionales es totalmente diferente al concepto de textura en la industria alimentaria la cual comprende tales propiedades como la dureza, cohesión, viscosidad, elasticidad, adhesividad, fragilidad, masticabilidad y gomosidad lo que por lo general hace referencia a lo que detecta la boca humana, mientras que la textura de la imagen hace referente a propiedades como la finura, granulosidad, rugosidad y suavidad (Li, Tan, y Shatadal , 2001), las cuales son caracterizadas por la disposición espacial de la valores de brillo de los píxeles de una región en una imagen.

1.8.1 Textura Estadística

Uno de los descriptores de la textura de imagen importantes en la industria alimentaria, es la textura estadística, método más ampliamente utilizado para la clasificación de la calidad de productos alimenticios (Zheng, Dan-Wen, y Zheng, 2006).

La textura de imagen está basada en matrices de co-ocurrencias, también conocidas como matrices de dependencia espacial de niveles de gris (GLCM, por Grey-Level Co-ocurrences Matrix). Las características de la textura se extraen por algunos enfoques estadísticos de la matriz de co-ocurrencia (Haralick, Shanmugan y Dinstein, 1973). La construcción de la matriz de co-ocurrencia depende de dos parámetros los cuales son la dirección de pares de píxeles θ y la distancia entre los pares de píxeles (d). La dirección θ se puede seleccionar de cuatro diferentes valores de 0, 45, 90, y 135° (Palm, 2004) como lo muestra la figura 11.




Figura 11. Representación de diferentes direcciones θ (0, 45, 90, y 135°) y la distancia (d) entre los píxeles utilizados para construir la matriz de co-ocurrencia en niveles de tonos en gris.

La matriz se construye mediante el recuento del número de los pares de píxeles (x_1, y_1) (x_2, y_2) con el valor de k y l que son las tonalidades de gris en la dirección θ y la distancia d . Las diferentes tonalidades de grises designadas en la imagen, se les denotan un cierto valor para su recuento (figura 12 (a)), este valor puede variar de 0 a 256 si la imagen es trabajada en 8bits, al término del recuento de los valores de grises, se forman las matrices en cualquiera de las cuatro direcciones (figura 12 (b)).




Figura 12. Representación de matrices de co-ocurrencia, (a) el valor de gris de los píxeles de una imagen de una tonalidad de 0-3 y (b) Matriz de co-ocurrencia construida a partir de (a) con distancia de 1 en las cuatro direcciones.

Después de la construcción de la matriz de co-ocurrencia, la matriz se normaliza por la siguiente función:

$$p(K,I) = \frac{p(K,I)}{R} \tag{16}$$

Donde R es la función normalizada, que se fija por lo general como la suma de la matriz (Shiranita, Miyajima y Takiyama, 1998). De la ecuación 16, se calculan 14

características de textura (Haralick, Shanmugan y Dinstein, 1973). Entre estas 14 características se encuentran las siguientes:

1. Entropía (ET) que indica el desorden o la aleatoriedad de una imagen
Texturas complejas tienden a tener mayor entropía:

$$ET = - \sum_k \sum_I p(k,I) \log(p(k,I)) \quad (17)$$

Donde $p(k, I)$ es la frecuencia relativa de ocurrencia de dos valores de píxeles (uno con intensidad k y el otro con intensidad I).

2. Suma de los cuadrados (Sum Of Squares (SOS)), también conocida como la varianza, es la obtención de la rugosidad de la imagen:

$$SOS = \sum_k \sum_I (k - \mu)^2 p(k,I) \quad (18)$$

$$\mu = \sum_k \sum_I kp(k-I) \quad (19)$$

Dónde: μ es el valor medio de la matriz ya obtenida.

2. Metodología Experimental

En el siguiente capítulo se presentará la metodología que se desarrolló y llevó a cabo en este trabajo. Donde se presenta el problema, los objetivos y las actividades que se realizaron.

2.1 Descripción del Cuadro Metodológico

2.1.1 Planteamiento del Problema

Aplicación de una red neuronal artificial para la determinación del calor específico durante la descongelación de carne de cerdo.

2.1.2 Objetivo General

Aplicar un modelo de red neuronal artificial suministrándole variables de Color (L^* , a^* , b^* , R, G y B), Luminosidad en tonos de grises, Textura estadística (ET y SOS) y Temperatura Superficial, para que aprenda la correlación que existe entre estas variables y el calor específico (C_p) durante la descongelación de la carne de cerdo (*Longissimus Dorsi*).

2.1.3 Objetivo Particular 1

Determinar la variación del color (L^* , a^* , b^* , R, G y B), Luminosidad en tonos de grises y parámetros de Textura estadística (ET y SOS) de una microfotografía durante la descongelación de la carne de cerdo para ser utilizadas como entradas de la red neuronal artificial. Así mismo la obtención del valor del calor específico utilizando el MDSC durante la fusión del hielo para ser empleado como agente supervisor en la red.

Variable independiente: Tiempo

Variable dependiente: Temperatura

Variabes de respuesta: L^* , a^* , b^* , R, G, B, Luminosidad en tonos de grises, ET, SOS y Calor específico

2.1.4 Cuadro Metodológico

2.1.5 Objetivo Particular 2

Generar una red neuronal artificial modelo de propagación del error hacia atrás, utilizado como agente superior el calor específico determinado por MDSC. Seleccionando por su independencia a las variables de color (L^* , a^* , b^* , R, G y B), Luminosidad en tonos de grises, Textura estadística (ET y SOS) y Temperatura superficial, para ser utilizadas como variables de entrada en la red y demostrar la validez de ésta.

2.2 Actividades Experimentales del Objetivo Particular 1

2.2.1 Actividad 1. Congelación de la carne de cerdo (*Longissimus Dorsi*)

Fueron colocadas tres placas de carne de 3cm de ancho y largo por 1cm de espesor, sobre una charola de unicel de 15x15cm cada una. Se envolvieron con plástico termocongelable de PVC cerrándolas herméticamente con un selladora (fresh look turbo seal) y pistola de aire caliente (REVLON 865 ionic). Una vez en vueltas se sometieron a una congelación a -27°C en una cámara de congelación Tor-REY modelo CV, durante 15 días de almacenamiento.

2.2.1.1 Actividad 1.1. Toma de microfotografías durante la descongelación de la carne de cerdo (*Longissimus Dorsi*).

Al haber transcurrido los 15 días de almacenamiento se desarrolló la placa de carne dejándola un minuto de atemperamiento. En el Estereomicroscopio Leica EZ4D se colocó un banco óptico y encima de este una caja petri conteniendo la placa de carne, con un fondo verde que permite tener un contraste de luz. En seguida se realizó la toma de microfotografías de la superficie de la carne con el Estereomicroscopio Leica programando su software con las condiciones de la tabla 3. Las microfotografías se tomaron cada 30 segundos y simultáneamente se registró la temperatura superficial de la placa de carne por medio de un termómetro digital infrarrojo (Cole Parmer 800-323-4340), hasta alcanzar una temperatura de 9°C . La toma de microfotografía se realizó para cada placa de carne.

Tabla 3. Condiciones para la toma de microfotografías.

Luces del Estereomicroscopio	Brillo	Gamma	Saturación	Zoom
3	87%	2	260	8x

2.2.1.2 Actividad 1.1.1. Determinación de parámetros de textura estadística

Las imágenes obtenidas de las microfotografías se sometieron a una pixelación en tonalidades de grises mediante el programa Open Cv, el cual se encargó de realizar la matriz de co-ocurrencia, determinando los siguientes parámetros de textura estadística:

ET= Entropía (orden de pixeles)

$$ET = - \sum_k \sum_I p(k,I) \log(p(k,I))$$

Donde p (K, I) es la frecuencia relativa de ocurrencia de dos valores de píxeles (uno con intensidad k y el otro con intensidad I).

SOS =Suma de los cuadrados (rugosidad de imagen)

$$SOS = \sum_k \sum_I (k - \mu)^2 p(k,I)$$

$$\mu = \sum_k \sum_I kp (k - I)$$

Dónde: μ es el valor medio de la matriz ya obtenida.

La obtención de estos parámetros de textura estadística se realizó por triplicado.

2.2.1.3 Actividad 1.1.2. Determinación de parámetros de color

Las imágenes obtenidas de las microfotografías se les cambio su formato a TIF para procesarlas en Photoshop CS5, seleccionando en este software los espacios de color CIELab y RGB así como también la escala de grises, para obtener de cada imagen un valor promedio de estos parámetros de color que se muestran en la tabla 4. La determinación de estos parámetros se realizó por triplicado.

Tabla 4. Tabla de sistemas de color y sus respectivos parámetros.

Sistema de Color	Parámetros de Color
CIELab	L*, a* y b*
RGB	R, G y B
Escala de Grises	Luminosidad en escala de grises

2.2.1.4 Actividad 1.2. Determinación del calor específico por medio del MDSC

Se cortó una muestra de carne de un peso de 16.1 mg con un bisturí, para tener datos más confiables de esta prueba de calorimetría por medio del MDSC se realizó por triplicado, para mantener la homogeneidad de los resultados todas las muestras tuvieron un peso similar a 16.1 ± 0.5 mg. Posteriormente la muestra se colocó dentro de una charola de aluminio cerrándola herméticamente con una tapa del mismo material. De igual forma se realizó con una charola vacía la cual fue la muestra de referencia.

Se programó el método de la tabla 5 en el calorímetro MDSC, la muestra y la de referencia se introdujeron al calorímetro, una vez colocadas en la celda se inició el proceso. Posteriormente se determinó el valor del calor específico durante un intervalo de temperatura de -20° a 8.6°C en el cual se efectuó la fusión del hielo, mediante el programa Universal Analysis 2000 versión 3.5B.

Tabla 5. Método del calorímetro MDSC

Datos	Condiciones
Peso de la muestra	16.1mgr
Equilibrar	-50°C
Modulación	±0.796°C cada 60s
Mantener	-50°C
Ramp	5°C/min hasta 130°C

2.3 Actividades Experimentales del Objetivo Particular 2

2.3.1 Actividad 2. Selección de variables de entrada

Se seleccionaron valores del calor específico determinados por medio del MDSC en el intervalo de la fusión del hielo, mediante el valor de la temperatura superficial tomada durante la descongelación de la carne, ya que esta temperatura se puede considerar como la temperatura registrada por el calorímetro MDSC de la muestra de carne de cerdo durante la fusión del hielo por ser una porción diminuta (16.1mg). Así mismo se seleccionaron valores de los parámetros de color (L^* , a^* , b^* , R, G y B), Luminosidad en tonos de grises y Textura estadística (ET y SOS) con la misma temperatura superficial. Como la Red Neuronal Artificial de propagación del error hacia atrás requiere que sus entradas sean independientes entre sí, se realizó un análisis estadístico de regresión lineal por medio de Minitab 15, para la obtención del valor de R^2 y descartar aquellas variables seleccionadas que tengan un alto grado de dependencia entre sí.

2.3.2 Actividad 2.1. Generar y Entrenar a la Red Neuronal Artificial

La red neuronal artificial de propagación del error hacia atrás se programó en Microsoft Excel Office 2010, utilizando macros y las siguientes ecuaciones.

1. Cálculo para las salida de las neuronas de la red

Para una neurona oculta

$$\sigma_i^p = \sum_{j=1}^{m_{p-1}} \omega_{ij}^p y_j^{p-1}$$

$$y_i^p = f(\sigma_i^p) = \frac{1}{1 + e^{-\sigma_i^p}}$$

Para una neurona de salida

$$\sigma_k^N = \sum_{i=1}^{m_{p-1}} \omega_{ik}^N y_i^p$$

$$y_k^N = f(\sigma_k^N) = \frac{1}{1 + e^{-\sigma_k^N}}$$

2. Cálculo del error para las neuronas de la capa de salida (δ_k^N) y para las neuronas de la capa oculta (δ_i^p).

$$\delta_k^N = y_k^N (1 - y_k^N)(y_k^N - Y_k^N)$$

$$\delta_i^p = y_i^p (1 - y_i^p) \sum_{k=1}^{m_{p+1}} \omega_{ik}^N \delta_k^N$$

Dónde:

$y_k^N (1 - y_k^N)$ = la derivada de la función sigmoideal para una neurona de salida.

$(y_k^N - Y_k^N)$ = al error de la neurona k de salida.

$\sum_{k=1}^{m_{p+1}} \omega_{ik}^N \delta_k^N$ = a la suma ponderada de los errores de la neurona de salida k.

$y_i^p (1 - y_i^p)$ = la derivada de la función sigmoideal para una neurona oculta.

3. Cálculo para la modificación de los pesos de la red

Pesos de la conexión entre la capa oculta y salida

Pesos de la conexión entre la capa oculta y entrada

$$w_{ik}^N(t) = w_{ik}^N(t - 1) + \Delta w_{ik}^N$$

$$w_{ij}^p(t) = w_{ij}^p(t - 1) + \Delta w_{ij}^p$$

Dónde:

$$\Delta w_{ik}^N = -\eta \frac{\partial E}{\partial w_{ik}^N} = -\eta \delta_k^N y_i^p = \text{regla de aprendizaje}$$

$$\Delta w_{ij}^p = -\eta \frac{\partial E}{\partial w_{ij}^p} = -\eta \delta_i^p y_j^{p-1} = \text{regla de aprendizaje}$$

$w_{ik}^N(t - 1)$ y $w_{ij}^p(t - 1)$ = valor del peso anterior

4. Cálculo del error E el cual se realiza conforme a la cantidad de iteraciones.

$$E = \frac{1}{2} \sum_k (y_k^N - Y_i^N)^2$$

Dónde

y_k^N = salida de la red

Y_i^N = salida deseada

Una vez programada la red neuronal artificial se seleccionó la arquitectura de esta, definiendo la cantidad de neuronas de entrada y ocultas así como el valor de la regla de aprendizaje (η) y la cantidad de iteraciones (épocas) a realizar.

Posteriormente se normalizaron los valores de las variables de entrada seleccionadas y de la salida deseada (supervisor) de la siguiente forma:

$$x = \frac{z - \min(z)}{\max(z) - \min(z)} \quad (20)$$

Dónde:

x= Valor normalizado

z= Valor sin normalizar

min(z)= Valor mínimo de los valores a normalizar

max(z)= Valor máximo de los valores a normalizar

Después se introdujeron una tabla de entrenamiento con los valores normalizados de las variables de entrada seleccionadas (L^* , a^* , b^* , R, G, B, ET, SOS y Ts) que son representadas como X_1, \dots, X_{m1} y la salida deseada (C_p del MDSC) representada con y_1 como lo muestra la Tabla 6.

Tabla 6. Tabla de entrenamiento que se introduce a la red.

	X_1	X_2	X_3	...	X_{m1}	y_1
1	-	-	-	...	-	-
2	-	-	-	...	-	-
.
.
.
q_e	-	-	-	...	-	-
.
.
.
Q_e	-	-	-	...	-	-

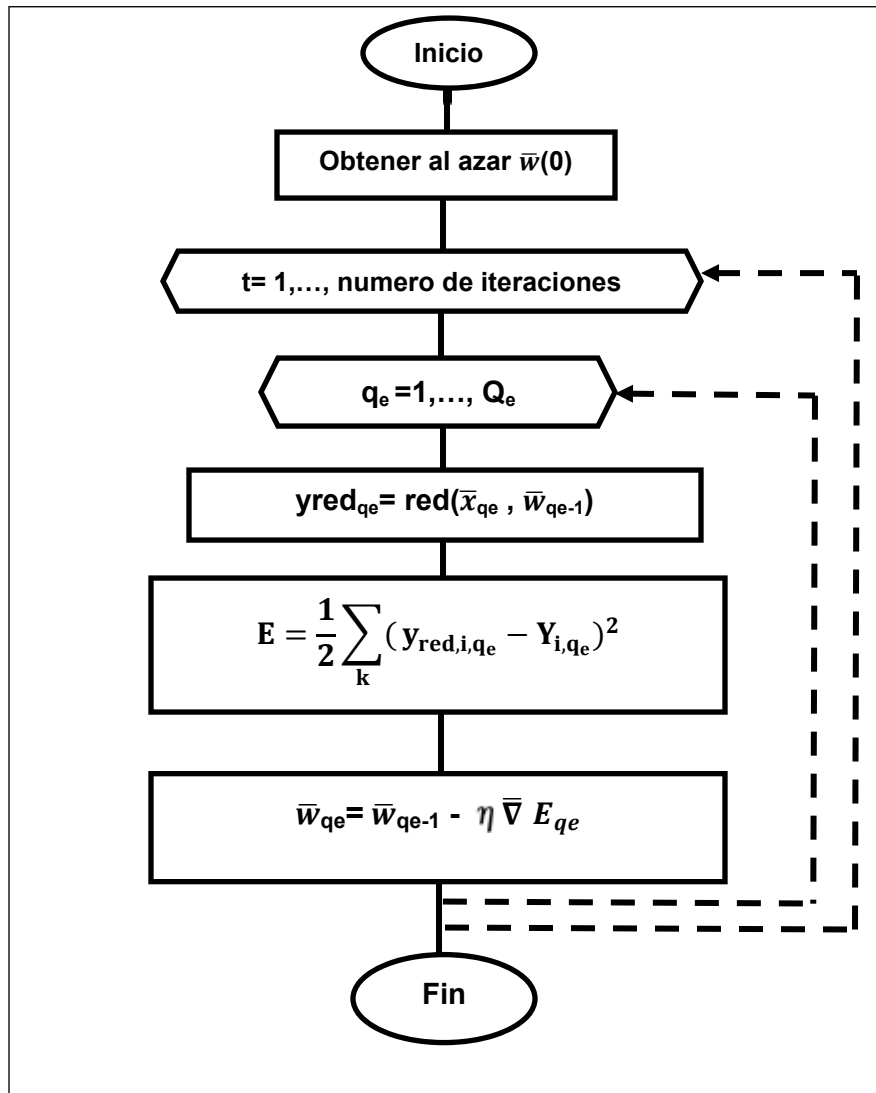


Figura 13. Diagrama de flujo representativo del proceso de entrenamiento de la red de propagación hacia atrás.

En seguida se inicia el entrenamiento con la inicialización de todos los pesos de la red, que se obtienen de manera aleatoria con números pseudoaleatorios de distribución unitaria en $(-1,1)$. Así mismo realiza el proceso de entrenamiento como lo muestra la figura 13 hasta que se concluyan las iteraciones definidas, para que se realice el descenso del gradiente $(\bar{\nabla} E_{q_e})$ y que a su vez se disminuya el error E a un valor aceptable. Si una vez terminado el entrenamiento no se disminuye el error E requerido, se tendrá que aumentar las iteraciones, o cambiar la arquitectura de la red modificando la cantidad de neuronas ocultas y se volverá a entrenar la red.

2.3.3 Actividad 2.2. Determinación de la validez de la red neuronal artificial entrenada.

Una vez entrenada la red se le suministró una tabla de prueba como se muestra la figura 14, la cual contiene valores de variables de entrada diferentes a los utilizados para el entrenamiento, pero que se encuentran dentro del intervalo de valores utilizados en este entrenamiento. Para obtener valores de Cp de la red entrenada y analizarlos estadísticamente con los valores determinados en el MDSC, realizando un análisis de varianza de dos vías y prueba de Tukey por medio de Minitab 15.

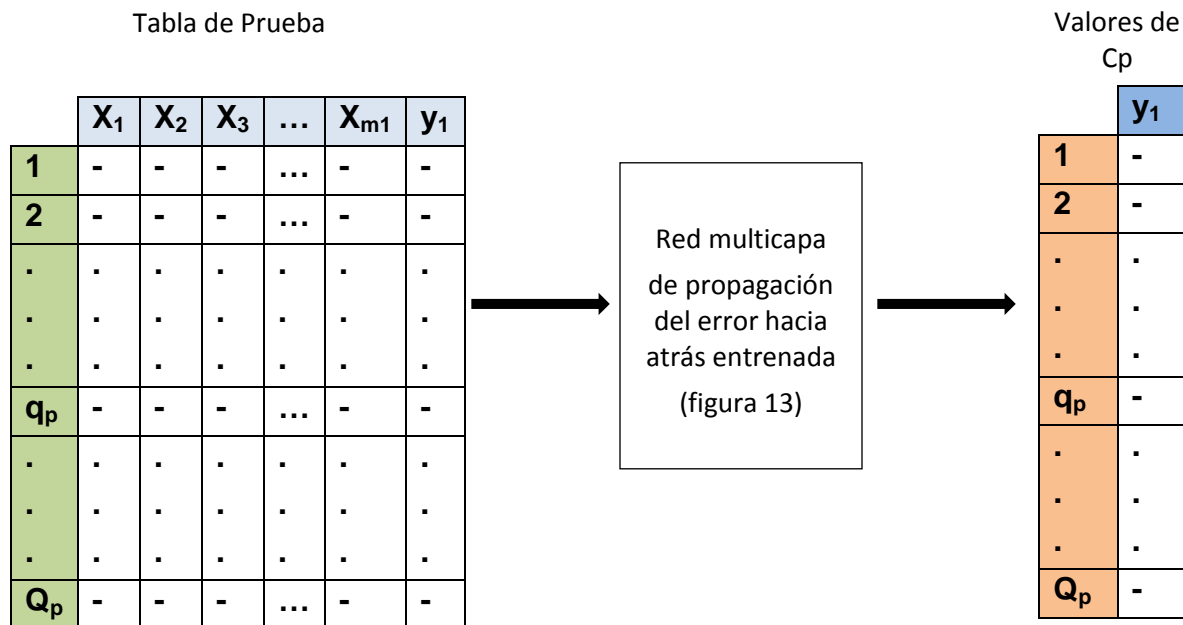


Figura 14. Muestra cómo se obtienen los valores de Cp con la red ya entrenada.

3. Análisis de Resultados y Discusión

A continuación en este capítulo se presentan los resultados obtenidos en la parte experimental y su análisis correspondiente.

3.1 Resultados de la Actividad 1. Congelación de las placas de carne

Se llevó a cabo la congelación de la carne de cerdo la cual alcanzo una temperatura de -27°C teniendo un descenso de la temperatura como lo muestra la figura 15.


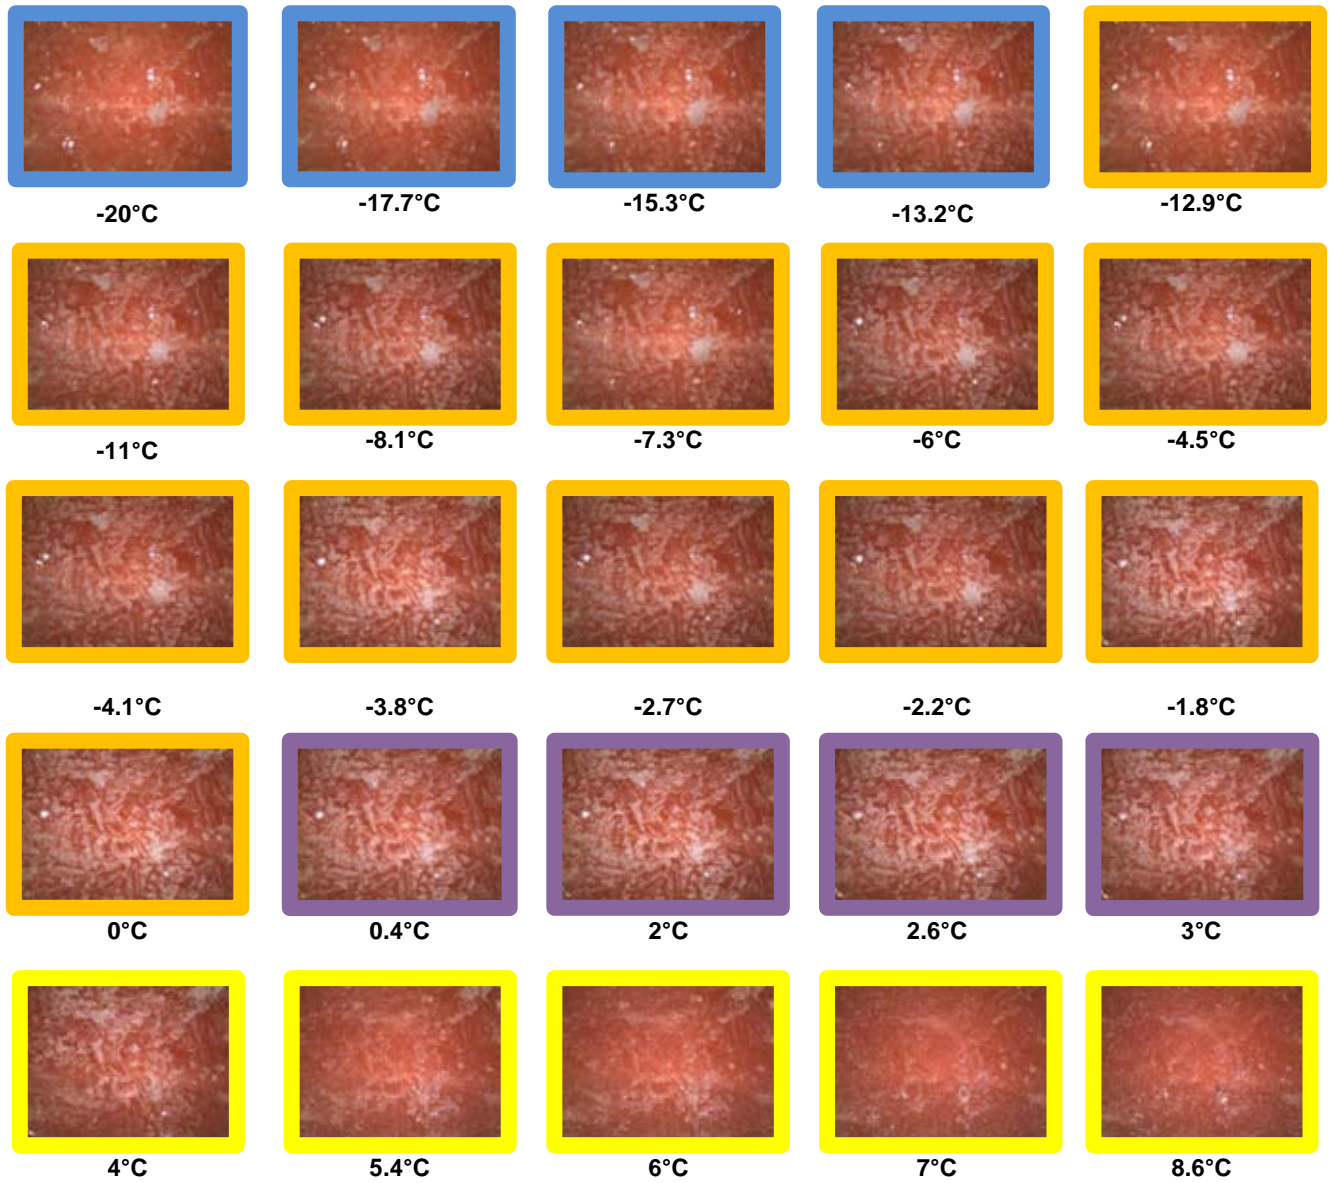


Figura 15. Historia térmica de la congelación de la carne de cerdo.

3.2 Resultados de las Actividades 1.1, 1.1.1 y 1.1.2. Obtención de las microfotografías y la determinación de la variación de los parámetros de textura estadística y color

Después de la congelación y almacenamiento durante 15 días de la carne, se tomaron las microfotografías durante el periodo de descongelación obteniendo imágenes a diferentes temperaturas como lo muestra la figura 16.



- Primer periodo (I) —
- Segundo periodo (II) —
- Tercer periodo (III) —
- Fusión del hielo (IV) —

Figura 16. Imágenes de la descongelación de la carne a diferentes temperaturas, donde se observan los periodos (I, II, y III) de formación de escarcha y la fusión de hielo (IV).

- **Entropía Estadística (ET)**

Los valores de entropía estadística obtenidos por medio de la matriz de co-ocurrencia de la serie de microfotografías tomadas durante la descongelación de la carne, se graficaron y son representados en las figura 17.




Figura 17. Representación del comportamiento de la Entropía Estadística en la superficie de la carne, durante los periodos (I, II, y III) de formación de escarcha y fusión de hielo (IV).

La entropía estadística es afectada a medida que la temperatura superficial de la carne aumenta (figura 17), estos cambios son influenciados por la formación de escarcha. En este proceso de formación de escarcha intervienen simultáneamente la transferencia de calor y de masa, los cuales son producto del gradiente de temperatura entre la temperatura de la superficie de la carne (-21 a 2°C) y el aire circundante del medio (24°C) así como la humedad relativa de este último (39%).

Como la entropía estadística determina el desorden de la tonalidad en los píxeles de la imagen, al irse realizando el proceso de la formación de escarcha de una forma no homogénea en la superficie de la carne, tiene un efecto al variar la tonalidad en grises de los píxeles, lo que ocasiona el aumento de la entropía

estadística de una forma no lineal. En las figuras 16 y 17 se observan los tres periodos que conforman el proceso de formación de escarcha de acuerdo con (Hayashi et, al., 1977) en el intervalo de -21 a -13°C se produce el primer periodo (I), en el cual el vapor de agua del aire en el medio se condensa en la superficie de la carne formando los núcleos de cristalización futuros. En este periodo la entropía estadística aumenta de 7.46 a 7.75 debido al agua condensada que se posiciona en la superficie de la carne y empieza la cristalización, esto se puede visualizar en la figura 16 en las imágenes que comprenden este periodo que se encuentra en el intervalo de temperatura de -20 a -13.2°C .

En el intervalo de temperatura de -13 a 0°C la entropía estadística se eleva alcanzando un valor de 8.18 en 0°C , debido que en ese intervalo de temperatura se efectúa el segundo periodo, que comprende el crecimiento de la capa de escarcha, donde se van incorporando cristales que contribuyen a la generación de esta capa que aumenta a medida que transcurre el tiempo y se incrementa la temperatura. En la figura 16 se observa en el intervalo de temperatura -13.2 a 0°C la evolución de la capa de escarcha en el periodo de descongelación de la carne.

El último periodo de la formación de escarcha se desarrolla en el intervalo de temperaturas de 0 a 2°C , llevándose a cabo el pleno crecimiento de escarcha al alcanzar la temperatura del punto de fusión del agua (0°C a una atmósfera de presión), produciendo que el vapor de agua condensado en la superficie y la escarcha que se funde parcialmente, se filtre a través de los poros de la misma escarcha hasta alcanzar la parte más fría y congelarse. Este proceso cíclico de condensación, fusión y congelación se lleva a cabo hasta alcanzar el equilibrio térmico, generando que la entropía estadística en este último periodo tienda a ser constante. Así mismo en la figura 17 se muestra en el intervalo de 2 a 3°C un aumento de la entropía estadística de 0.14 al fundirse la escarcha pero ya no realizando el ciclo de condensación, fusión y congelación. Después de los 3°C la entropía estadística se incrementa hasta una temperatura de 6°C por el hecho que el hielo se está fundiendo, después de esta temperatura la entropía estadística tiende a ser constante debido a que en la superficie de la carne el

hielo sea fundido, teniendo una mayor homogeneidad en los tonos de grises de la imagen al no ser afectados por los cristales de hielo.

- **Rugosidad (SOS)**

De igual forma que la entropía estadística, la rugosidad de imagen se ve influenciada por la formación de escarcha en la superficie y el incremento de la temperatura superficial durante la descongelación como lo muestra la figura 18.




Figura 18. Representación del comportamiento de la Rugosidad en la superficie de la carne, durante los periodos (I, II, y III) de formación de escarcha y fusión de hielo (IV).

La rugosidad de imagen crece de un valor de 1004.54 a 1251.39 en el intervalo de temperatura de -21 a -13°C debido a la irregularidad que se está generando en la superficie de la carne producto de la condensación del agua que se realiza en el primer periodo para el crecimiento de cristales en la formación de escarcha y por lo tanto al igual que la entropía estadística la rugosidad incrementa.

Posteriormente en el intervalo de -13 a 0°C la rugosidad sigue aumentando, por los cristales hielo que se forman, generando una capa de escarcha que no crece

homogéneamente en toda la imagen teniendo zonas que no están cubiertas totalmente por escarcha como se muestran en la figura 16.

En el intervalo de temperatura de 0 a 2°C del gráfico en la figura 18, se observa un cambio no tan prolongado en la rugosidad, donde existe una diferencia de 12.38, producido por el último periodo (III) de formación de escarcha donde se ha alcanzado la temperatura de fusión del agua (0°C a una atmósfera de presión) llevándose a cabo el ciclo de condensación, fusión y congelación. Después de este intervalo se empieza a fundir el hielo sin volverse a congelar, lo cual cambia la rugosidad en el intervalo de temperatura de 2 a 3°C con una diferencia de 178.35, la fusión de hielo continua de igual manera que el aumento de la rugosidad hasta llegar a una temperatura de 6°C.

Al llegar a la temperatura a 7°C el valor de rugosidad desciende, manteniendo un comportamiento constante hasta los 8°C, posteriormente la rugosidad aumenta hacia a los 9°C con una diferencia de 115.77 producto de la fusión de gran parte del hielo, como se muestra en la figura 16 y que una fracción del agua se filtre a través de los poros formados por los cristales de hielo durante la congelación. Este descenso de la rugosidad y su comportamiento que tiende a ser constante en el intervalo de 7 a 8°C se puede contrastar con el comportamiento de la entropía estadística en el mismo intervalo, al fundirse el hielo la pixelación de imagen en tonos de grises es más homogénea por ende la rugosidad disminuye al ya no existir cristales de hielo en la superficie de la carne que generen irregularidades.

- **Parámetros de Color**

Por otra parte referente a las variaciones de los parámetros de color en los espacio CIELab, RGB y escala de grises, estos fueron graficados en las figuras 19, 20 y 21 donde se observa el mismo comportamiento en todos los parámetros de color (L^* , a^* , b^* , R, G, B y luminosidad en grises). Este comportamiento en la variación del color es influenciado por la formación de escarcha. Como se muestra en las figuras 19, 20 y 21, las líneas rojas verticales que dividen estos gráficos representan los tres periodos que comprenden la formación de la escarcha.

El primer periodo se efectúa en el intervalo de temperaturas de -21 a -13°C los parámetros color L*, a*, b*, R, G, B y luminosidad en grises disminuyen por el agua condensada que se posiciona en la carne formando cristales de hielo que crecen verticalmente a una tasa casi constante.

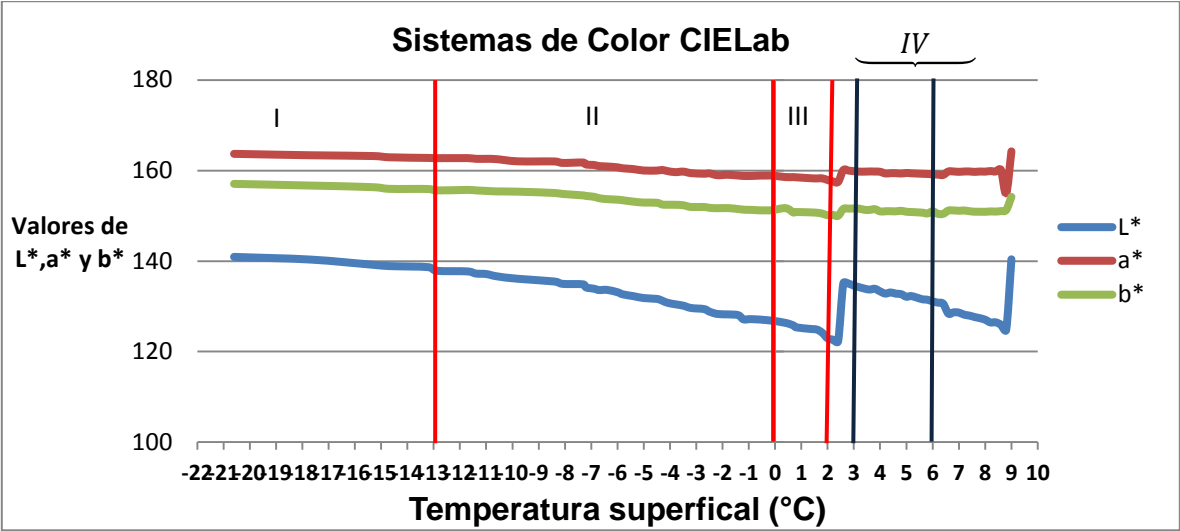


Figura 19. Comportamiento de los parámetros L*, a* y b* en la superficie de la carne, durante los periodos (I, II, y III) de formación de escarcha y fusión de hielo (IV).

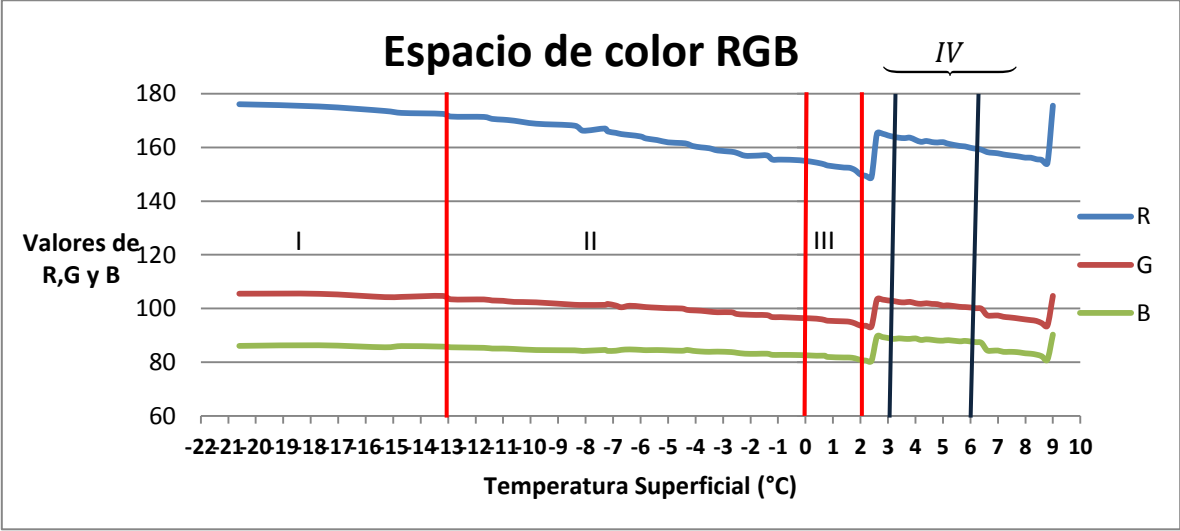


Figura 20. . Comportamiento de los parámetros R, G y B en la superficie de la carne, durante los periodos (I, II, y III) de formación de escarcha y fusión de hielo (IV).

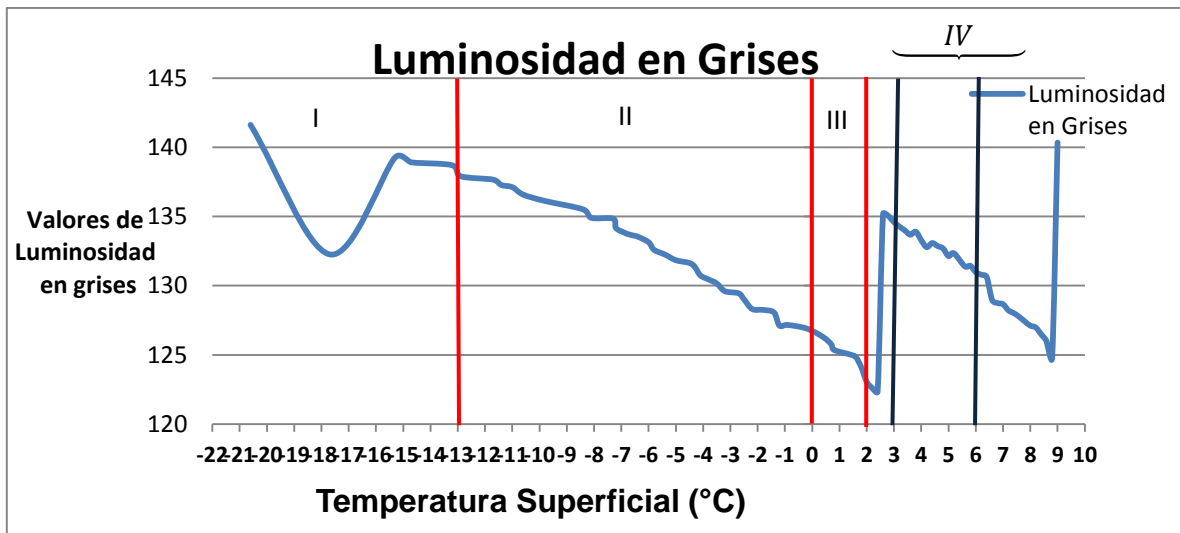


Figura 21. Comportamiento de la Luminosidad en tonos de grises en la superficie de la carne, durante los periodos (I, II, y III) de formación de escarcha y fusión de hielo (IV).

Después en el intervalo de temperatura de -13 a 0°C que comprende el segundo periodo, donde se va produciendo la capa de escarcha, esto ocasiona que al mismo tiempo se disminuya más rápidamente el valor de los parámetros de color, por consiguiente se observa un cambio en la pendiente en este intervalo de temperatura.

El tercer periodo y último en la formación de escarcha en el que se desarrolla el ciclo de condensación, fusión y congelación hasta llegar al equilibrio térmico de la escarcha, provoca que sigan descendiendo las variables de color y no se pueda definir concretamente a simple vista en ninguna de las figuras 19, 20 y 21 este periodo.

Debido a que la disminución en los valores de los parámetros de color sigue el mismo comportamiento del periodo anterior. Pero por medio de la entropía estadística y la rugosidad de imagen se determinó que este periodo comprende el intervalo de temperatura de 0 a 2°C.

Al empezar a fundirse los cristales de hielo en el intervalo de temperatura de 2 a 3°C se percibe un aumento en los descriptores del color de los espacios CIELab y RGB así como también en la luminosidad de la escala de grises, posteriormente estos empiezan a disminuir a medida que se funden los cristales de hielo hasta alcanzar la temperatura de 9°C donde se considera que se ha fundido todo el hielo

en la superficie de la carne y por consecuencia se aumentan los valores de los parámetros de color. Aparentemente la luminosidad en escala de grises (figura 21) es el parámetro más adecuado para el análisis de la formación de escarcha, al notarse mejor las variaciones generadas por sus tres periodos.

3.3 Resultados de la Actividad 1.2. Determinación del Calor Específico

Después de haber realizado la técnica de calorimetría en el MDCS con el método establecido, por medio del programa Universal Analysis 200 versión 3.5B se identificó el intervalo de temperatura en la que se efectuó la fusión del hielo de la muestra de carne, así mismo se obtuvo los valores del calor específico que se presentan en la tabla 7 los cuales serán utilizados como agente supervisor en la red neuronal artificial, donde se puede apreciar el aumento de este hasta alcanzar un máximo valor de 4.328 (J/g°C) y posteriormente desciende hasta un valor de 2.25 (J/g°C) donde se ha fundido todo el hielo en la carne.

Tabla 7. Valores de Cp obtenidos del calorímetro referente a la temperatura superficial registrada de la carne durante la descongelación.

Cp (J/g°C)	Temperatura (°C)
1.394	-20.6
1.541	-17.7
1.705	-15.3
1.887	-13.2
1.997	-11
2.569	-8.1
2.937	-6
3.433	-3.8
3.554	-1.8
3.862	0.4
4.032	2.6
4.328	2.5
3.577	5.4
2.25	8.6

3.4 Resultados de la Actividad 2. Selección de variables de entrada

Como la red neuronal de propagación del error hacia atrás procesa información no lineal requiere que sus variables de entrada sean independientes entre sí.

Las variables de color (L^* , a^* , b^* , R, G y B), textura estadística (ET y SOS) y luminosidad en tonos de grises (LTG) se seleccionaron por medio de un análisis estadístico de regresión lineal, donde el valor de la R^2 (tabla 8) determino su dependencia. Al tener una R^2 cercana a 1 entre dos variables se deduce que tienen una gran dependencia por lo tanto fueron descartadas para ser variables de entrada de la red.

En la tabla 8 se puede ver que los parámetros de R y G tiene gran dependencia con la luminosidad (L^*) al tener valores de 0.98 y 0.95 respectivamente, por lo cual se descartaron para ser considerados variables de entrada. Así como también el parámetro B que es el único parámetro del espacio RGB, que no tiene una dependencia considerable con las otras variables, pero se decidió descartarlo debido a que el color azul representado por el parámetro B, no es indicado para evaluar carne.

Tabla 8. Valores de R^2 del análisis de regresión lineal de las variables.

Variables	TS	L^*	a^*	b^*	R	G	B	LTG	ETO	SOS
TS	1.00	0.37	0.43	0.80	0.43	0.27	0.01	0.20	0.96	0.54
L^*	0.37	1.00	0.67	0.63	0.98	0.95	0.45	0.26	0.28	0.10
a^*	0.43	0.67	1.00	0.72	0.74	0.51	0.09	0.19	0.40	0.35
b^*	0.80	0.63	0.72	1.00	0.74	0.45	0.01	0.23	0.75	0.60
R	0.43	0.98	0.74	0.74	1.00	0.88	0.34	0.27	0.34	0.18
G	0.27	0.95	0.51	0.45	0.88	1.00	0.62	0.22	0.18	0.02
B	0.01	0.45	0.09	0.01	0.34	0.62	1.00	0.06	0.04	0.19
LTG	0.20	0.26	0.19	0.23	0.27	0.22	0.06	1.00	0.18	0.10
ETO	0.96	0.28	0.40	0.75	0.34	0.18	0.04	0.18	1.00	0.60
SOS	0.54	0.10	0.35	0.60	0.18	0.02	0.19	0.10	0.60	1.00

Con respecto a la entropía estadística (ET) tiene una dependencia considerable con la temperatura superficial (Ts) al tener un valor de R^2 de 0.96 pero no se rechazó como variable de entrada, porque los valores de ET no solo dependen de la temperatura superficial de la carne, sino también de la humedad relativa y temperatura del aire.

La tabla 9 contiene las variables de entrada para la tabla de entrenamiento (Tabla 6, pág. 47) que se proporcionaran a la red neuronal artificial, las cuales se eligieron por medio del valor de la temperatura superficial con la cual fue determinado el calor específico durante la fusión del hielo

Tabla 9. Variables de entrada para la red neuronal artificial.

Ts (°C)	L*	a*	b*	Luminosidad en grises	ET	SOS	Cp (J/g°C)
-20.6	140.93	163.69	157.06	254.98	7.46	1004.54	1.39
-17.7	140.34	163.38	156.69	132.26	7.44	994.755	1.54
-15.3	139.18	163.21	156.33	139.26	7.73	1143.3	1.70
-13.2	138.66	162.79	155.93	138.7	7.79	1251.39	1.88
-11	137.14	167.59	155.51	137.12	7.76	1213.91	1.99
-8.1	134.97	161.69	154.84	134.9	7.88	1200.88	2.56
-6	133.12	160.72	153.57	133.14	8.10	1311.7	2.93
-3.8	130.46	159.65	152.44	130.45	8.02	1295.8	3.43
-1.8	128.23	159.07	151.71	128.25	8.14	1484.3	3.55
0.4	126.34	158.56	151.69	126.29	8.18	1484.68	3.86
2.6	135.1	160.11	151.53	135.19	8.32	1653.74	4.032
5.4	131.98	159.39	150.71	131.93	8.47	1715.61	3.57
8.6	125.94	160.17	151.05	125.96	8.48	1419.44	2.25

En la tabla 9 se muestran los valores de las variables de entrada y sus valores máximos marcados de color amarillo y mínimos de color azul. Es importante saber el intervalo que comprende cada variable, porque solamente los valores que estén dentro de ese intervalo se podrán utilizar con la red una vez que se entrene.

3.5 Resultados de la Actividad 2.1 Generar y Entrenar a la Red Neuronal Artificial

Se programó y entrenó a dos redes neuronales artificiales de propagación del error hacia atrás en Microsoft Excel Office 2010. Las dos redes se entrenaron con dos diferentes arquitecturas las cuales se muestra en la tabla 10, lo único en lo que difieren es la cantidad de variables de entrada.

Tabla 10. Arquitectura de las redes neuronales entrenadas.

Arquitectura	Red neuronal de 5 variables de entrada (V5) (Ts, L*,a*,b* y LTG)	Red neuronal de 7 variables de entrada (V7) (Ts, , L*,a*,b*, LTG, ET y SOS)
Capa de entrada	1	1
Capa oculta	1	1
Capa de salida	1	1
Neuronas de entrada	5	7
Neuronas ocultas	5	5
Neuronas de salida	1	1
Función de transferencia	Sigmoidal	Sigmoidal

Las dos redes se entrenaron con una tasa de aprendizaje (η) de 0.5, el número de iteraciones (épocas) realizadas por ambas redes fueron de 20,000. Para poder disminuir el error E a un valor aceptable el cual indica que tanto difiere la respuesta de la red entrenada con la deseada (supervisor). Se modificando más de una vez el número de neuronas ocultas hasta que con 5 de ellas se alcanzó a reducir el error E a 0.0082 para la red de 5 variables (V5) y un error E de 0.00079 para la de 7 (V7).

En la figura 22 se muestra la forma en la cual el error E producido por la red al irse entrenando en cada iteración disminuye. Cabe destacar que no se entrenó a las redes realizando más iteraciones de las antes mencionadas, debido a que la red

se podría sobre entrenar provocando que no generalizara correctamente y que el error E no disminuyera.




Figura 22. Representación del descenso del error E durante el entrenamiento.

En la figura 23 se muestra el comportamiento del calor específico el cual se utilizó como agente supervisor y el generado por la red neuronal V7 que es muy parecido al de la red V5. Conforme se realizaban las iteraciones en el entrenamiento de la redes pretendían aprender el comportamiento del calor específico determinado por el calorímetro MDSC. Se puede apreciar que con su entrenamiento la red de V7 alcanzó una gran similitud con el comportamiento del agente supervisor, lo cual se puede corroborar con los valores aceptables del error E . También se observa en la figura 23 que el comportamiento del calor específico tiene forma de un pico donde alcanzó un valor máximo y después de este empezó la fusión del hielo en la carne.

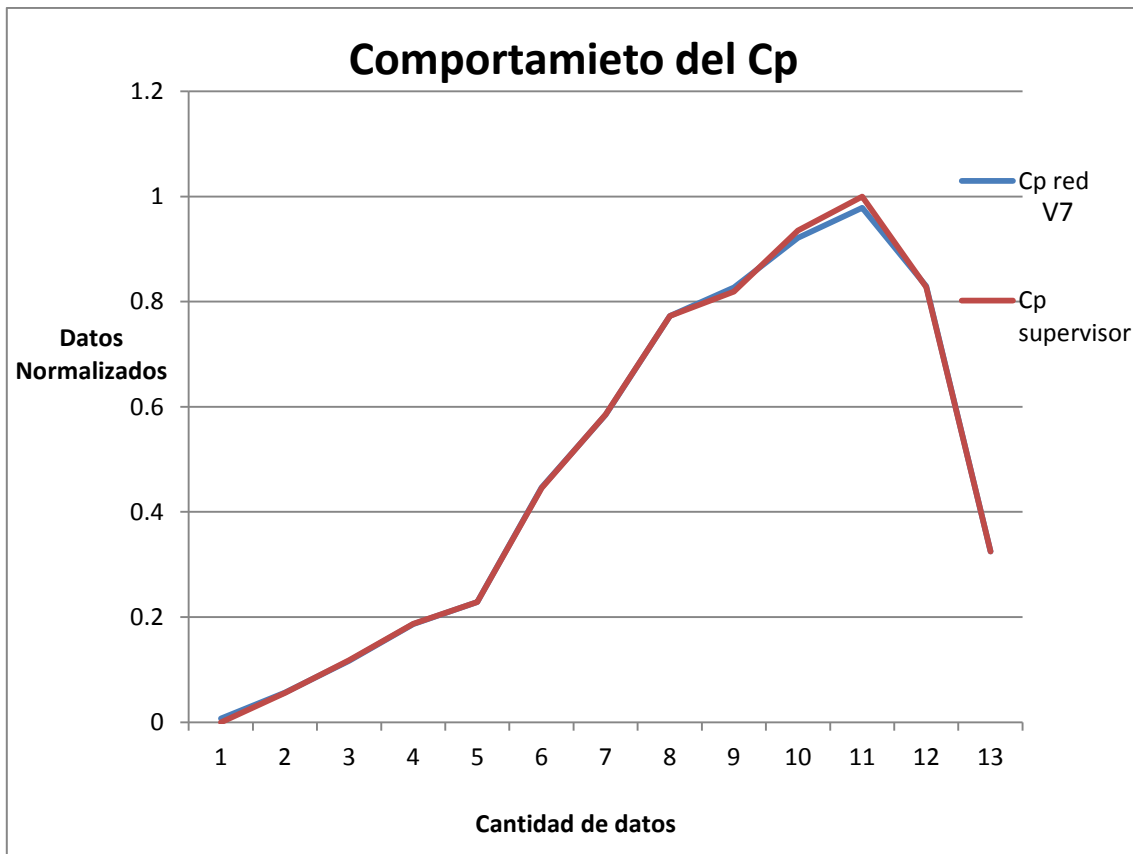


Figura 23. Comportamiento del Cp de agente supervisor y el generado por la red de 7 variables.

3.6 Resultados de la Actividad 2.2. Determinación de la validez de la red

Una vez entrenadas las redes neuronales artificiales de propagación del error hacia atrás, se le suministró una tabla de prueba (tabla 11) con valores de sus respectivas variables de entrada diferentes con las que fueron entrenadas, pero que se encuentran dentro del intervalo comprendido de las variables utilizadas para su entrenamiento.

Tabla 11. Tabla de prueba para la red entrenada.

Ts	L*	a*	b*	LTG	ET	SOS
-14.7	138.9	162.93	155.96	138.91	7.75	1177.89
-12.9	137.86	162.74	155.61	137.91	7.78	1280.21
-10.6	136.64	162.52	155.39	136.58	7.81	1232.23
-7.3	134.86	161.77	154.51	134.84	7.92	1257.82
-6.9	133.9	161.24	154.21	133.84	7.97	1266.4
-4.5	131.65	160	152.89	131.64	8.04	1257.53
-1.2	127.12	158.81	151.36	127.11	8.15	1534.92

Los resultados obtenidos con la tabla de prueba del calor específico en ambas redes se muestran en la tabla 12 donde también se presenta su respectivo valor determinado por el MDSC. Estos valores se utilizaron para comprobar la validez de las redes neuronales artificiales por medio de análisis estadístico

Tabla 12. Valores del calor específico obtenidos por el MDSC y de las redes neuronales V7 y V5.

Temperatura (°C)	Cp (J/g°C)		
	MDSC	Red V7	Red V5
-15.41	1.7576	1.7556	1.7758
-12.99	1.9060	1.9362	1.9892
-10.59	2.1895	2.1580	2.2456
-8.23	2.6977	2.7853	2.6640
-5.94	2.7716	2.8834	2.7516
-3.74	3.2749	3.2349	3.3039
-1.69	3.5882	3.5765	3.4839

Los resultados del análisis estadístico de varianza de dos vías para la validez de las redes entrenadas se pueden analizar con la figura 24. Donde se observa un comportamiento similar entre el valor del MDSC y las dos redes neuronales entrenadas de 7 variables de entrada (V7) y 5 (V5). También en la figura 24 se puede observar de igual forma que no existe una diferencia estadística entre el comportamiento de C_p obtenido por el MDSC y el de las redes neuronales entrenadas.

Por otra parte la figura 24 muestra que existe una diferencia significativa en los valores de C_p a ciertas temperaturas entre los valores obtenidos por el MDSC y las redes entrenadas (5 V y V7). En el intervalo de temperatura de -12.9 a -10.6°C existe una diferencia de 0.13 en donde los valores de la red de 5 variables de entrada (5V) son mayores con respecto a los del MDSC y la red de 7 variables de entrada. En cambio en el intervalo de temperatura de -7.3 a -6.9°C los valores que difieren con los demás son los de la red V7 al ser mayor por una diferencia de 0.19 , en la temperatura -4.5 el valor del C_p de la red V5 es mayor por 0.02 y el de la red V7 es menor con una diferencia de 0.03 conforme al valor de C_p del MDSC.

Por último en la temperatura el valor el C_p de la red V5 es menor con respecto a los otros dos por una diferencia de 0.1 por consiguiente se observa una ligera inclinación más pronunciada hacia el lado derecho en el intervalo de -4.5 a -1.2 . Las diferencias entre los valores del calor específico (C_p) obtenidos por el MDSC y las redes neuronales entrenadas (V5y V7) a diferentes temperaturas son producto del error E alcanzado durante su entrenamiento por ambas redes.

Los resultados de la prueba de Tukey de los datos anteriores se representan en la tabla 13 donde el valor de F es de 0 por consiguiente no hay una diferencia significativa entre los valores del calor específico determinados por el MDSC y las dos redes neuronales entrenadas. Lo cual se puede verificar por las medias resultantes de los valores del MDSC y las dos redes donde los intervalos de estas se sobreponen entre sí, demostrando que no existe una diferencia con respecto al valor del calor específico obtenido de las redes entrenadas (V5 y V7) con respecto al MDSC.




Figura 24. Representación del comportamiento y diferencias entre los diferentes valores del calor específico obtenidos del MDSC y las redes neuronales entrenadas artificiales V5 y V7.

Tabla 13. ANOVA unidireccional: Cp MDSC, Cp Red V7 y Cp Red V5.

Fuente	GL	SC	MC	F	P
Factor	2	0.002	0.001	0.00	0.998
Error	18	8.130	0.452		
Total	20	8.132			

S = 0.6721 R-cuad. = 0.02% R-cuad. (ajustado) = 0.00%

ICs de 95% individuales para la media basados en Desv.Est. agrupada

Nivel	N	Media	Desv.Est.
Cp MDSC	7	2.5979	0.6869
Cp Red V7	7	2.6186	0.6853
Cp Red V5	7	2.6020	0.6431

2.10 2.40 2.70 3.00

Desv.Est. agrupada = 0.6721

4. Conclusiones

Las redes neuronales artificiales de propagación del error hacia atrás V5 y V7 generadas para la determinación del calor específico durante la descongelación de la carne de cerdo, pueden ser utilizadas debido a que su validez estadísticamente es aceptable al mostrar el mismo comportamiento de C_p generado por el MDSC. El error E que representa la diferencia entre el valor del calor específico de las redes neuronales artificiales con respecto al MDSC, se redujo a un valor mínimo considerable para su utilización.

Para la utilización de las redes neurales, es necesario que los valores de las variables de entrada se encuentren dentro del intervalo con el cual se entrenaron. La textura estadística y la luminosidad en escala de grises son las variables que mejor se adecuaron para la descripción de la formación de escarcha durante la descongelación de la carne. Para un valor más preciso de la predicción del C_p , es conveniente tener en cuenta las diferencias del C_p generado entre las redes neuronales artificiales V5 y V7 en ciertas temperaturas.

Los objetivos de este proyecto se concluyeron de manera satisfactoria de igual forma que los resultados obtenidos para el problema planteado. Al crear dos redes neuronales artificiales de propagación del error hacia atrás capaces de poder determinar el calor específico de la carne de cerdo por medio de microfotografías de la descongelación a cada temperatura superficial para obtener la textura estadística, así como la variación de parámetros de color permitieron la predicción aceptable. Estas variables de entrada no tienen una relación directa con el calor específico por lo cual no son requeridas para la determinación aplicando otros métodos y ecuaciones empíricas existentes. Con este proyecto se ha mostrado una alternativa para el procesamiento de información no lineal por medio del uso de un modelo de red neuronal artificial, el cual fue alimentado con variables de entrada novedosas partiendo de la aplicación de imágenes de descongelación para la determinación del C_p . Las redes neuronales artificiales se proponen para la ingeniería en alimentos como una herramienta eficaz al procesamiento de información no lineal la cual existe en un gran número de procesos en la transformación de alimentos.

5. Referencias

1. Abdallah, M. B., Marchello, J. A., & Ahmad, H. A. (1999). Effect of freezing and microbial growth on myoglobin derivatives of beef. *Journal of Agricultural and Food Chemistry*, *47*, 4093–4099.
2. Agatonovic, K. & Beresford, R. (1999). Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research. *Journal of Pharmaceutical and Biomedical Analysis*, *22*, 717–727.
3. Anon. (1990). IEEE standard 610.4-1990. In IEEE standard glossary of image processing and pattern recognition terminology. New York, USA: IEEE Press
4. Añón, M. C., & Cavelo, A. (1980). Freezing rate effects on the drip loss of frozen beef. *Meat Science*, *4*, 1–14.
5. Balaban, M. O., & Odabasi, A. Z. (2006). Measuring color with machine vision. *Food Technology*, *60*, 32 - 36.
6. Biliaderis, C.G. Differential scanning calorimetry in food research—a review. *Food Chemistry*, *10*, 239–265, 1983.
7. Boller, A., Schick, C., & Wunderlich, B. Modulated differential scanning calorimetry in the glass transition region. *Thermochimica Acta*, *266*, 97–111, 1995.
8. Calvelo, R. J. (1981). Recent studies on meat freezing. In R. Lawrie (Ed.), *Developments in meat science—2* (pp. 125–158). London: Elsevier Applied Science Publishers.
9. Charm, S. (1978). *The Fundamentals of Food Engineering*, 3-th ed. AVI Publ. Co., Westport, Connecticut.
10. Chen, k. & Shaw, Y. (2009). Applying back propagation network to cold chain temperature monitoring. *Advanced Engineering Informatics*. *25*, 11–22.
11. Cheng, J. & Da-Wen, S. (2004). Recent developments in the applications of image processing techniques for food quality evaluation. *Trends in Food Science & Technology*. *15*, 230–249

12. Choi, Y., Okos, M. (1986). Effects of temperature and composition on the thermal properties of food. In: Le Maguer, M., Jelen, P. (Eds.), *Food Engineering and Process Applications*, Vol. 1. "Transport Phenomena". Elsevier Applied Science Publishers, London, pp. 93-101.
13. Costa, C., Antonucci, F., Pallottino, F., Aguzzi, J., Sun, D. W., & Menesatti, P. (2011). Shape analysis of agricultural products: a review of recent research advances and potential application to computer vision. *Food and Bioprocess Technology*, 4, 673 e 692.
14. Cui, J., Li, W. & Jiang, Z. (2010). A new time- and space-dependent model for predicting frost formation. *Applied Thermal Engineering*. 31, 247-257.
15. Duno, P. (1996). *Formulario del Frio*. Tomo I, España: Marcombo, pp 161.
16. Farouk, M. M., & Swan, J. E. (1998). Effect of muscle condition before freezing and simulated chemical changes during frozen storage on the pH and colour of beef. *Meat Science*, 50, 245–256.
17. Fennema, O. R. (1975). Reaction kinetic in partially frozen aqueous systems. In R. B. Duckworth (Ed.), *Water relations in foods* (pp. 440–455). London: Academic Press.
18. Fernandez, L. Castellero, C. Aguilera, J. M., (2003). An application analysis to dehydration of Apple disc. *Jornal Food Engineering*. 67, 185-193.
19. Flores, R., & Fernandez, J. (2008). *Redes Neuronales Artificiales Fundamentos Teóricos y Aplicaciones Prácticas*. Tomo I. España: Netbiblio. pp 35.
20. Fossa, M. & Tanda, G. (2010). Frost formation in vertical channels under natural convection. *International Journal of Multiphase Flow*, 36, 210-220.
21. Gunasekaran, S. (1996). Computer vision technology for food quality assurance. *Trends in Food Science & Technology*, 7, 245–256.
22. Hanrahan, G. (2009). *Artificial Neural Networks in Biological and Environmental Analysis*. Tomo I. E.U.A, pp. 35-47.
23. Haralick, R. M., Shanmugam, K., & Dinstein, I. (1973). Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, 6, 610–621.

24. Hayashi, K., Aoki, H., Yuhara, J. (1977). Study of frost formation based on a theoretical model of the frost layer, *Heat Transfer - Japanese Research*. Vol 6. 79-94.
25. Heldman, D. & Singh, R. (1981). *Food Process Engineering*, second ed. AVI Publ. Co., Westport, Connecticut.
26. Henseler, J. & P.J. Braspenning (1990). Training complex multi-layer neural networks, *Proceedings of the Latvian Signal Processing International Conference*, Vol. 2, Riga, 301-305.
27. Henseler, J. "Back Propagation" en Braspenning, P.J., F. Tuijman y A.J.M.M. Weijters (Eds.), Springer, 1995, pp. 37-66.
28. Hilera, J. (1995). *Redes Neuronales Artificiales Fundamentos, Modelos y Aplicaciones*. Tomo 1. España: RA-MA.
29. Kaletunc, G. (2007). Prediction of specific heat of cereal flours: A quantitative empirical correlation. *Journal of Food Engineering*. 82, 590-594.
30. Kirckpatrick, S. Gelatt, C. & Torre, T. (1983). Optimization by simulated annealing *Science*, 220, 671-680.
31. Laguerre, O. & Flick, D. (2011). Frost growth and densification in laminar flow over flat surfaces. *Heat and Mass Transfer*. 54, 1719-1731.
32. Lahoz, R. (2004). *Bioinformática simulación, vida artificial e inteligencia artificial*. Tomo 1. Barcelona.
33. Lana, M. M., Tijssens, L. M. M., & van Kooten, O. (2005). Effects of storage temperature and fruit ripening on firmness of fresh cut tomatoes. *Postharvest Biology and Technology*, 35, 87-95.
34. Lawrie, R. (1998). In Anonymous (Ed.), *Lawrie's meat science* (pp. 1-336). (6th ed.). Lancaster, PA: Technomic Publishing Inc.
35. Li, J., Tan, J., & Shatadal, P. (2001). Classification of tough and tender beef by image texture analysis. *Meat Science*, 57, 341-346.
36. Lui, Z., Xiong, Y., & Chen, J. (2010). Protein oxidation enhances hydration but suppresses water-holding capacity in Porcine Longissimus muscle. *Journal of Agricultural and Food Chemistry*, 58, 10697-10704.

37. McCulloch, W.S., W.H. Pitts. 1943. A logical calculus for the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics* 5: 115-113.
38. Melendez-Martinez, A. J., Vicario, I. M., & Heredia, F. J. (2005). Instrumental measurement of orange juice colour: a review. *Journal of the Science of Food and Agriculture*, 85 , 894 e 901.
39. Meng, Y. & Ramaswamy, H (2009). Neural Networks and Genetic Algorithms. In Taylor & Group, F (Eds.), *Optimization in Food Engineering*. 200-218.
40. Mersmann, A. (2001b). *Crystallization technology handbook* .London: CRC Press LLC.
41. Meuter, P., Rahie, H. & Mele, B. (1999). The use of modulated temperature differential scanning calorimetry for the characterisation of food system. *International Journal of Pharmaceutics*, 192, 74-84.
42. Murase, N., Ruike, M., Yoshioka, S., Katagiri, C., and Takahashi, H. Glass transition and ice crystallisation of water in polymer gels, studied by Oscillation DSC, XRD-DSC simultaneous measurements, and Raman spectroscopy, in *Amorphous Food and Pharmaceutical Systems*, H. Levine (ed.), The Royal Society of Chemistry, Cambridge, 2002, pp. 339–346.
43. Myerson, A. S. (2002b). *Handbook of industrial crystallization*, (2nd ed.). Boston/Oxford: Butterworth-Heinemann.
44. Neal, D. & Tree, D. Measurement of frost growth and density in a parallel plate geometry, *ASHRAE Transactions* 90 (1984). pp 278- 290.
45. Owen, J. E., & Lawrie, R. A. (1975). The effect of an artificially induced high pH(hydrogen-ion concentration) on the susceptibility of minced porcine muscle to undergo oxidative rancidity under frozen storage. *Journal of Food Technology*, 10, 169–180.
46. Palm, C. (2004). Colour texture classification by integrative cooccurrence matrices. *Pattern Recognition*, 37, 965–976.
47. Pascale, D. (2003). *A review of RGB color spaces*. Montreal: The Babel Color Company.

48. Paul, R. & Heldman, R. (2014). Introduction to Food Engineering. Tomo I. USA, pp 265-320.
49. Polley, S. L., Snyder, O.P., & Kotnour, P. (1980). A compilation of thermal properties of foods. *Food Technology*, 11, 76-94.
50. Quevedo, R. & Valencia, E. (2013). Color changes in the Surface of fresh cut meat: A fractal kinetic application. *Food Research International*, 54, 1430-1436.
51. Rao, M. A., & Rizvi, S. S. H. (1986). Engineering properties of foods. Food-analysis. Series: Food science and technology. New York: Marcel Dekker Inc, 54-98.
52. RODRIGUEZ, R., & VICTOR. M. (2008). Bases de la alimentación humana editorial CEDRO, Madrid España, 764.
53. Rosenblatt, F. 1962. Principles of Neurodynamics: Perceptrons and the theory of brain mechanisms. Washington: Spartan Books.
54. Rowe, L. J., Maddock, K. R., O'Lonegan, S. M., & Huff-Lonegan, E. (2004). Influence of early post mortem protein oxidation on beef quality. *Journal of Animal Science*, 82, 785–793.
55. Rumelhart, D.E., Hinton, G.E., and McClelland, J.L.- 1986. Learning internal representations by error propagation. In D.e. Rumelhart and J.L. McClelland (EDS.), *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*. Volume I. MIT Press: Cambridge, MA.
56. Savage, A. W., Warris, P. D., & Jolley, P. D. (1990). The amount and composition of the proteins in drip from stored pig meat. *Meat Science*, 27, 289–303.
57. Schawe, J. (1996). Modulated temperature DSC measurements: The influence of the experimental conditions. *Thermochimica Acta*, 271, 127–140.
58. Shiranita, K., Miyajima, T., & Takiyama, R. (1998). Determination of meat quality by texture analysis. *Pattern Recognition Letters*, 19, 1319–1324.
59. Siebel, J. (1892). Specific heat of various products. *Ice Refrigeration* 2, 256.

60. Silva, F. & Almeida, L. (1990). Acceleration techniques for the Backpropagation algorithm. *Lecture Notes in Computer Science: Neural Networks* 412 (Eds, L.B. Almeida y C.J. Wellekens), 110-119.
61. Sun, D. & Zheng, L. (2006). Innovations in freezing process. In D. W. Sun (Ed.), *Handbook of frozen food processing and packaging*. Boca Raton, Fla./London: CRC/Taylor & Francis.
62. Timmermans, A. J. M. (1998). Computer vision system for on-line sorting of pot plants based on learning techniques. *Acta Horticulturae*, 421, 91–98.
63. Verdonck, E., Schaap, K., & Thomas, L.C. A discussion of the principles and applications of modulated temperature DSC (MTDSC). *International Journal of Pharmaceutics*, 192, 3–20, 1999.
64. Viscarra, R., Miasby, B. & McMratney, A. (2006). Colour space models for soil science. *Geoderma*. 133, 320-337.
65. Wagner, J. R., & Añón, M. C. (1985). Effect of freezing rate on the denaturation of myofibrillar proteins. *International Journal of Food Science and Technology*, 20, 735–744.
66. Weibiao, Z. (2009) *Mathematical Modeling of Food Processing*. In Taylor & Group,
67. Wu, D. & Sun, D. (2013). Colour measurements by computer vision for food quality control- A review. *Trends in Food Science & Technology*. 2, 29, 5-20.
68. Wyszecki, G., Stiles, W.S., (1982). *Color Science: Concepts and Methods, Quantitative Data and Formulae*, Second Edition Wiley, New York.
69. Xanthakis, E., Havet, M. & Chevallier, S. (2013). Effect of static electric field on ice crystal size reduction during freezing of pork meat. *Innovative Food Science and Emerging Technologies*. 20, 115-120.
70. Xiong, Y. L. (2000). Protein oxidation and implications for muscle food quality. In: *Antioxidants in muscle foods* (edited by E. Decker & C. Faustman). pp. 3–23, 85–111, 113–127. Chichester: John Wiley & Sons.
71. Zaritzky, N. (2006). Physical-chemical principles in freezing. In D.-W. Sun (Ed.), *Handbook of frozen food packaging and processing*. Boca Raton, FL: Taylor & Francis.

72. Zheng, C., Dan-Wen, S. & Zheng, L. (2006). Recent applications of image texture for evaluation of food qualities—a review. *Trends in Food Science & Technology*. 17, 113–128.
73. Zueco, J., Alhama, F. & Gonzalez, C. (2004). Inverse determination of the specific heat of foods. *Journal of Food Engineering*, 64, 347-353.

2.1.4 Cuadro Metodológico

