

Indira Guadalupe Rodríguez Cervantes

Caracterización de variables de textura de imagen para  
evaluar su aplicación en la predicción de calidad de carne  
de res

2022



**Universidad Autónoma de Querétaro**

**Facultad de Ingeniería**

Caracterización de variables de textura de imagen para evaluar  
su aplicación en la predicción de calidad de carne de res

**Tesis**

Que como parte de los requisitos para obtener el Grado de  
Maestría en Ingeniería en Calidad y Productividad

**Presenta:**

Q. en A. Indira Guadalupe Rodríguez Cervantes

**Dirigido por:**

Dra. Magdalena Mendoza Sánchez

Querétaro, Qro. a Marzo, 2022



**Universidad Autónoma de Querétaro**

Facultad de Ingeniería

Maestría en Ingeniería en Calidad y Productividad

**Caracterización de variables de textura de imagen para evaluar su aplicación  
en la predicción de calidad de carne de res**

Tesis

Que como parte de los requisitos para obtener el Grado de  
Maestría en Ingeniería en Calidad y Productividad

**Presenta:**

Q. en A. Indira Guadalupe Rodríguez Cervantes

**Dirigido por:**

Dra. Magdalena Mendoza Sánchez

Dra. Magdalena Mendoza Sánchez  
Presidente

Dra. Aurora Femat Díaz  
Secretario

M.I. Javier García Pérez  
Vocal

Dra. Marcela Gaytán Martínez  
Suplente

Dra. Monserrat Escamilla García  
Suplente

Centro Universitario, Querétaro, Qro. México

Fecha 07 de Marzo de 2022

## **DEDICATORIAS**

A mi familia, de quienes he obtenido la inspiración para buscar una mejora constante en todos los aspectos de la vida.

A mi madre, quien siempre me ha inspirado para dar lo mejor de mí y me ha enseñado a no conformarme con los logros obtenidos.

A Sergio, André y Micaela por su apoyo y cariño.

## **AGRADECIMIENTOS**

A la Dra. Magdalena Mendoza Sánchez por guiarme a lo largo de todo el programa y compartirme sus experiencias profesionales y personales que me han servido en mi desarrollo profesional.

A mis profesores y sinodales por su dedicación al compartir su conocimiento.

A la Universidad Autónoma de Querétaro y la Facultad de Ingeniería.

Al Consejo Nacional de Ciencia y Tecnología por apoyar con el financiamiento del programa de posgrado a través del CVU 454953.

## INDICE

|      |  |    |
|------|--|----|
| I.   | INTRODUCCIÓN.....  | 37 |
| II.  | ANTECEDENTES.....  | 40 |
|      | 2.1 LA CARNE, CONSUMO Y PRODUCCIÓN .....                                       | 40 |
|      | 2.2 CALIDAD DE LA CARNE .....  | 42 |
|      | 2.2.1 COLOR .....  | 43 |
|      | 2.2.2 PH.....  | 47 |
|      | 2.2.3 CAPACIDAD DE RETENCIÓN DE AGUA.....                                      | 49 |
|      | 2.2.4 TEXTURA DE LA CARNE.....   | 51 |
|      | 2.3 MÉTODOS NO DESTRUCTIVOS PARA LA EVALUACIÓN DE CALIDAD DE CARNE .....       | 52 |
|      | 2.4 ANÁLISIS DE IMAGEN .....   | 56 |
|      | 2.5 ANÁLISIS DE TEXTURA DE UNA IMAGEN .....                                    | 59 |
|      | 2.6 ALGORITMOS ESTADÍSTICOS PARA LA CONSTRUCCIÓN DE MODELOS DE PREDICCIÓN..... | 65 |
|      | 2.7 PROGRAMAS UTILIZADOS PARA ANÁLISIS DE IMAGEN .....                         | 67 |
|      | 2.8 SISTEMAS DE MEDICIÓN Y CONFIABILIDAD .....                                 | 68 |
| III. | HIPOTESIS.....   | 71 |
| IV.  | OBJETIVOS.....   | 71 |
|      | 4.1 OBJETIVO GENERAL .....   | 71 |
|      | 4.3 OBJETIVOS ESPECÍFICOS .....  | 71 |
| V.   | MATERIALES Y METODOS .....   | 72 |
|      | 5.1 MATERIALES .....   | 72 |
|      | 5.2.1 <i>Condiciones operativas de la metodología</i> .....                    | 72 |
|      | 5.2.2 <i>Preparación de las muestras</i> .....                                 | 73 |
|      | 5.2.3 <i>Descripción del experimento</i> .....                                 | 73 |
|      | 5.2.4 <i>Medición de color</i> .....   | 73 |
|      | 5.2.5 <i>Medición de pH</i> .....  | 74 |

|   |    |
|---|----|
| 5.2.6 Capacidad de retención de agua.....                     | 74 |
| 5.2.7 Análisis de textura a partir de imágenes digitales..... | 74 |
| 5.3 Análisis estadístico .....                                | 76 |
| V. RESULTADOS Y DISCUSIÓN .....                               | 77 |
| VI. CONCLUSIONES.....   | 96 |
| VII. REFERENCIAS .....  | 97 |

## INDICE DE FIGURAS

|   |    |
|---|----|
| <b>Figura 1.</b> Gráfica de producción mundial de carne (Consejo Nacional de la Carne, compendio estadístico, 2021).....  | 6  |
| <b>Figura 2.</b> Diagrama del efecto en el color con las posibles formas de mioglobina de la carne (Imagen adaptada)..... | 10 |
| <b>Figura 3.</b> Espacio de color CIELAB (Braña et al., 2011) .....   | 11 |
| <b>Figura 4.</b> Disminución del pH después del sacrificio (Braña et al., 2011).....                                      | 13 |
| <b>Figura 7.</b> Sistema de visión inicial.....   | 38 |
| <b>Figura 8.</b> Sistema de captura de imágenes final.....  | 39 |
| <b>Figura 9.</b> Gráficas de normalidad de Contraste.....   | 41 |
| <b>Figura 10.</b> Gráfica obtenida del Estudio tipo 1 para el parámetro de L* .....                                       | 44 |

## INDICE DE CUADROS

|  |    |
|--|----|
| <b>Cuadro 1.</b> Métodos para monitoreo de calidad de la carne.....  | 20 |
| <b>Cuadro 2.</b> Resultados de normalidad de los datos .....   | 40 |
| <b>Cuadro 3.</b> Resultados del estudio tipo 1 para los parámetros medidos.....  | 43 |
| <b>Cuadro 4.</b> Resultados de pH y % CRA de muestras mantenidas en refrigeración (4°C) 9 días. ....                                 | 46 |
| <b>Cuadro 5.</b> Resultados de color de muestras mantenidas en refrigeración (4°C) 9 días.....                                       | 47 |
| <b>Cuadro 6.</b> Resultados de textura a partir de matriz de co-ocurrencia muestras mantenidas en refrigeración (4°C) 9 días.....    | 50 |
| <b>Cuadro 7.</b> Resultados del análisis de correlación de variables fisicoquímicas y de textura a partir de imágenes digitales..... | 52 |
| <b>Cuadro 8.</b> Pruebas del modelo completo .....   | 55 |
| <b>Cuadro 9.</b> Resumen de efectos en el ajuste logístico nominal para la predicción del día de refrigeración.....                  | 55 |
| <b>Cuadro 10.</b> Resultados de la matriz de confusión del modelo.....   | 56 |

## RESUMEN

México figura como un importante consumidor y productor de cárnicos. La evaluación de la calidad de la carne es un reto de mayor importancia en la industria cárnica. La necesidad de métodos objetivos, consistentes y eficientes se tomó como impulsor para explorar el análisis de imagen para la evaluación de la calidad de res. Se realizó el análisis fisicoquímico, así como el análisis de textura de imágenes con matriz de coocurrencia (GLCM) a muestras de carne de res. Se examinó la correlación entre las características de textura extraídas de imágenes las cuales fueron segundo momento angular (ASM), contraste, correlación, inversa de la diferencia de momento (IDM) y entropía calculadas con GLCM y las variables de color, pH y capacidad de retención de agua, observando una correlación más fuerte entre las variables  $a^*$ ,  $C^*$ , IDM y ASM. El modelo de predicción generado, utilizando ajuste logístico nominal, mostró que las variables de color  $a^*$ ,  $b^*$ ,  $C^*$  y  $h^*$  en conjunto con las variables de textura de imágenes ASM e IDM son los parámetros significativos en la estimación de la frescura de la carne en este estudio. El estudio muestra un posible potencial del análisis de imagen en combinación con el análisis de color, para la predicción de calidad de la carne de res en términos de su frescura.

**Palabras clave:** carne, calidad de carne, análisis de imagen

## ABSTRACT

Mexico is a major consumer and producer of meat. The assessment of meat quality is a major challenge in the meat industry. The need for objective, consistent and efficient methods was taken as an enhancer to explore image analysis for the assessment of the quality of beef meat. Physicochemical analysis, as well as texture analysis of cooccurrence matrix (GLCM) images was performed on beef samples. The correlation of texture characteristics extracted from images which were second angular moment (ASM), contrast, correlation, inverse of moment (IDM) and entropy obtained with GLCM and the variables of color, pH and capacity of water retention, observing a stronger correlation between the variables  $a^*$ ,  $C^*$ , IDM and ASM. The prediction model, using nominal logistic adjustment, showed that the color variables  $a^*$ ,  $b^*$ ,  $C^*$  and  $h^*$  together with the texture variables of ASM and IDM are significant parameters in the estimation of the freshness of meat in this study. The study shows a possible potential of image analysis in combination with color analysis, for the prediction of beef quality in terms of its freshness.

**Key words:** meat, meat quality, image analysis

## **I. INTRODUCCIÓN**

La población a nivel mundial cubre el 23 % de su requerimiento de alimentación con alimentos de origen animal, conformado especialmente por proteínas de la carne con alto valor nutrimental. Por lo anterior, el consumo de carne tiene una importancia fundamental en la alimentación de las personas. Las carnes mayormente consumidas a nivel global son de pollo, cerdo y res (Consejo Nacional de la Carne, 2021

Aunque en el 2020 el efecto de la pandemia dio como resultado a nivel global un descenso en el consumo de carne, en México se consumieron más de 8.8 millones de toneladas de carne de pollo, cerdo y res en ese mismo año.

México representa el 3.3 % del consumo mundial de carne, lo que lo coloca en el 6° lugar dentro de los consumidores más importantes; además, produjo aproximadamente 7.3 millones de toneladas de cárnicos, colocando al país en la posición 7, aportando el 2.8 % de la producción mundial. (Consejo Nacional de la Carne, compendio estadístico, 2021).

La calidad de la carne es un aspecto multifactorial que define la tendencia de su producción y de su consumo, por lo que, su evaluación, es un reto de importancia en la industria cárnica.

El color es un aspecto de la carne que se ha utilizado como indicador de frescura por parte de los consumidores. A nivel instrumental, la estabilidad del color se puede utilizar para determinar la vida útil de la carne a lo largo del tiempo de

almacenamiento. Este aspecto se evalúa principalmente en carnes rojas, como la carne de res (Albertí et al., 2016).

En un estudio efectuado por Ripoll et al. (2012), se evaluó la relación entre la medición instrumental del color usando las coordenadas del espacio de color  $L^*$ ,  $a^*$ ,  $b^*$ ,  $C^*$  y  $H^*$  y la apreciación visual del color por parte del consumidor (valoración subjetiva), en carne de res durante 6 días. Para encontrar las correlaciones entre ambos métodos de medición se utilizaron métodos estadísticos lineales y no lineales, así como un algoritmo de aprendizaje automático. Los resultados mostraron que los métodos no lineales mostraron una relación aproximada del método instrumental con la valoración de los evaluadores, siendo que fueron más precisos para esta interpretación los valores de luminosidad ( $L^*$ ) y saturación de color ( $C^*$ ); además, se demostró que no se puede interpretar el color de la carne con los parámetros  $a^*$ ,  $b^*$  y  $h^*$  durante el tiempo de almacenamiento (6 días) de forma lineal o usando variables de forma independiente.

Otros métodos instrumentales que se utilizan de forma regular para determinar la calidad de la carne en términos de su frescura, son el pH, la capacidad de retención de agua, la fuerza de corte, entre otros (Zapotoczny et al., 2016).

Como se ha descrito anteriormente, para evaluar la calidad de la carne, de forma general, son utilizados métodos instrumentales, sin embargo, presentan las desventajas de ser: invasivos, destructivos, costosos, laboriosos y tardados.

Con el objetivo de encontrar otros métodos que puedan servir de herramienta en la ciencia y tecnología de la calidad de cárnicos, el análisis de imagen ha sido investigado; y debido a que el enfoque de evaluación, a través del análisis de imagen, se realiza mediante la captura de imágenes y su posterior análisis, este

método, ofrece una alternativa de evaluación de la carne no convencional, al ser: no destructivo, objetivo y consistente (Lillford, 2018).

Por lo anterior, diversos investigadores se han interesado en estudiar la relación de la estructura y las propiedades fisicoquímicas de la carne, con la textura superficial obtenida a partir de imágenes digitales. Ogdhal et al. (2019) analizaron la fuerza de corte y diversos parámetros de textura, usando la matriz de coocurrencia y la transformada de Fourier. Con los resultados que obtuvieron, desarrollaron un modelo estadístico que les permitió clasificar la ternura, un aspecto importante de calidad de la carne.

Por otro lado, Arsalane et al. (2020) evaluaron el cambio de color de muestras de carne almacenadas en refrigeración, durante 9 días, y calcularon parámetros de textura de imágenes usando la matriz de coocurrencia y los momentos estadísticos, con lo que, construyeron un modelo estadístico que fue capaz de clasificar y predecir frescura de la carne.

Los estudios anteriores sugieren que la medición de la calidad de la carne, que se realiza a través de métodos instrumentales de forma cotidiana, pudiera apoyarse con métodos no convencionales como lo es el análisis de imagen.

Por lo anterior, el objetivo de este proyecto es evaluar la calidad de la carne a través de la relación entre las variables fisicoquímicas pH, color, capacidad de retención de agua y los parámetros de textura obtenidos del análisis de imágenes.

## **II. ANTECEDENTES**

### **2.1 La carne, consumo y producción**

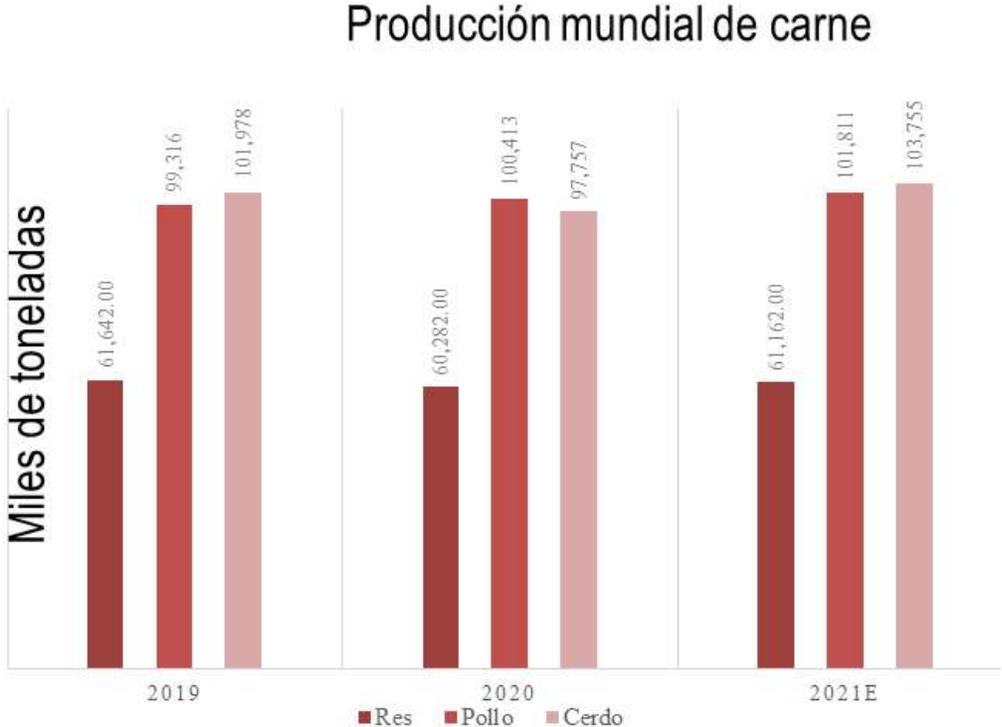
La carne de consumo se define como la estructura estriada esquelética, acompañada o no, de tejido conectivo, hueso, grasa, además de fibras nerviosas, vasos linfáticos y sanguíneos, provenientes de animales utilizados para abasto; que no ha sido sometida a ningún proceso que modifique de modo irreversible sus características sensoriales y fisicoquímicas, salvo la refrigeración, la congelación y el envasado (vacío, atmósfera modificada) (Braña et. al 2012).

En general, la carne está compuesta de agua (72 %), proteína (21 %), grasa (5 %), minerales (1 %) así como una pequeña porción de carbohidratos (1 %) (Fonti-Furnols et al., 2015). Por su contenido nutrimental antes mencionado, la carne ha sido un componente valioso para la alimentación humana; en este sentido, la proteína cárnica es parte importante de una dieta equilibrada, ya que es fuente de aminoácidos, vitaminas y minerales esenciales para el desarrollo humano.

Es por esto que, hoy en día sus consumidores y productores han incrementado la conciencia de su composición y su valor nutritivo, lo que se ve reflejado en su producción y consumo globales (Jung et al., 2016).

En México, al cierre del 2020, el consumo de carne per cápita llegó a 69 Kg/año, posicionando al país en el 6° lugar de consumo global; mientras que, en cuanto a producción, el país se posicionó en el 7° lugar a nivel mundial (Consejo Nacional de la Carne, compendio estadístico, 2021).

Los tres principales tipos de carne que se consumen en el mundo son de: pollo, cerdo y res. En cuanto a la carne de res, en el periodo 2019-2021, su balanza comercial es superavitaria y sus exportaciones incrementaron 9.7 % y en contraparte, las importaciones decrecieron -15.0 %. En la Figura 1 se puede observar que en el año 2020 la producción de carne de res tuvo un crecimiento de 2.6 % (Consejo Nacional de la Carne, 2021).



**Figura 1.** Gráfica de producción mundial de carne (Consejo Nacional de la Carne, 2021).

A nivel Nacional el principal consumo de carne está dirigido a la carne de pollo, seguido de la de cerdo y finalmente la de res.

Por otro lado, la economía del país se ha visto beneficiada por el consumo y producción cárnica; en este sentido, el PIB que generó el sector cárnico incrementó 2.7 % en el último año. De igual forma, el índice de remuneraciones medias reales igualó a la industria manufacturera y superó el de la industria de alimentos. Además, a pesar de la pandemia de la COVID-19, el personal ocupado total que empleó la industria cárnica creció 0.4 % en comparación con el 2019 (Consejo Nacional de la Carne, 2021).

## **2.2 Calidad de la carne**

La definición de calidad en el área de los alimentos, es difícil de establecer, sin embargo, se le relaciona con la aptitud que posee el alimento para ser consumido por el humano y su capacidad para satisfacer ciertas necesidades, es por ello que, el concepto se relaciona de forma muy estrecha con las preferencias del consumidor. A pesar de las dificultades que se tiene para definir la calidad en los alimentos, es un hecho que es un factor crítico en la industria de la carne (Troy & Kerry, 2010).

La calidad de la carne puede ser clasificada con: sus rasgos de calidad de apariencia AQT (Appearance Quality Traits por sus siglas en inglés), sus rasgos de calidad del consumo EAT (Eating Quality Traits por sus siglas en inglés) y sus rasgos de calidad de confianza RQT (Reliance Quality Traits por sus siglas en inglés) (Joo et al., 2013).

Los rasgos de calidad “AQT” se evalúan por su apariencia, que está determinada por el color de la carne, la cantidad y la distribución de la grasa, el color de la grasa, la humedad y la textura de la carne (Becker et al., 2000). Estos

rasgos de calidad influyen fuertemente en la decisión del consumidor al momento de seleccionar una carne en el punto de compra. Además, el consumidor puede determinar la calidad real de la carne en el punto de consumo, con rasgos de calidad de consumo (EQT), como son la ternura, el sabor, la jugosidad y la succulencia (Acebron & Dopico, 2000). También, los consumidores pueden evaluar la calidad de la carne mediante características de calidad de confianza (RQT) como son seguridad, nutrición, bienestar animal, ética en la producción de la carne, precio, presentación de los productos, origen y marca (Troy & Kerry, 2010).

Existe en México una regulación para la clasificación de la calidad de canales y carne, sin embargo, en la producción local de carne bovino, esta es generalmente puesta a la venta sin llevar a cabo la clasificación de calidad visual establecida (Rubio et al., 2007; Secretaría de Economía, 2002).

Es por esto que, es importante saber que las características de calidad y nutrición de la carne se ven afectadas por factores intrínsecos y extrínsecos. A continuación, se describen los parámetros de calidad determinados en la carne fresca.

### **2.2.1 Color**

Respecto al color determinado mediante un instrumento, al incidir una luz blanca sobre la superficie de una muestra de carne, ciertas longitudes de onda que componen esa luz blanca serán absorbidas por la muestra de carne; el color de esa muestra de carne está entonces definido por la combinación de aquellas longitudes de onda que no fueron absorbidas por la superficie cárnica. Por otro lado, el color percibido es el conjunto de las longitudes reflejadas que pueden ser percibidas por el ojo humano, y ha sido definido por CIE (Commissión Internationale

de L'Éclairage) como el atributo visual que se compone de una combinación cualquiera de elementos cromáticos y acromáticos (Alberti et al., 2005).

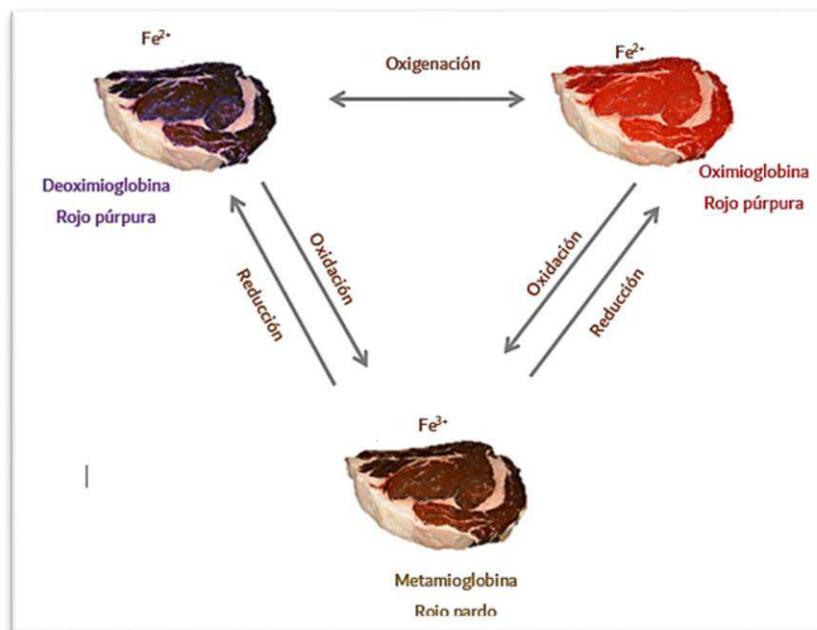
El color de la carne roja es de gran importancia en el mercado, ya que, es el atributo de calidad evaluado de manera inicial por los consumidores, debido a que lo usan como indicador de seguridad y frescura. El color y la estabilidad de este parámetro son las características de calidad más importantes en el punto de venta (Hood & Mead, 1993).

El color de la carne depende de la concentración y el estado químico de los pigmentos de la carne, principalmente de la hemoglobina y la mioglobina. Así mismo, influye sobre este, la proporción de grasa, la cantidad de tejido conjuntivo y otros pigmentos como la catalasa, citocromos, flavinas, vitamina B12, entre otras (Fox, 1987).

La concentración de mioglobina en el músculo se ve afectada por la genética, la edad, la dieta del animal, el ejercicio, además de factores ambientales (Livingston & Brown, 1981). La mioglobina es una proteína sarcoplasmática, transportadora de oxígeno. Contiene una proteína, la globulina, cuyo grupo hemo es el responsable del intenso color rojo-pardo de la carne (Renerre, 1977). La mioglobina puede existir en una de las siguientes tres formas: desoximioglobina, oximioglobina, metamioglobulina (Figura 2) (Kropf, 1993). La desoximioglobina, es frecuentemente conocida como mioglobina reducida, contiene hierro en estado ferroso ( $Fe^{2+}$ ), es la responsable de la coloración rojo púrpura, y se encuentra en el interior de la carne y en carne sometida a vacío, permanece tras el sacrificio por la propia actividad reductora del músculo (Renerre, 1990). La oximioglobina es formada cuando la desoximioglobina se pone en contacto con el oxígeno del aire, el pigmento debe estar en el estado ferroso ( $Fe^{2+}$ ) para que la oxigenación se dé (Livingston & Brown, 1981), en este caso es el pigmento que genera la coloración

rojo cereza, que es la que el consumidor asocia con una adecuada frescura en carnes rojas (Faustman & Cassens, 1990).

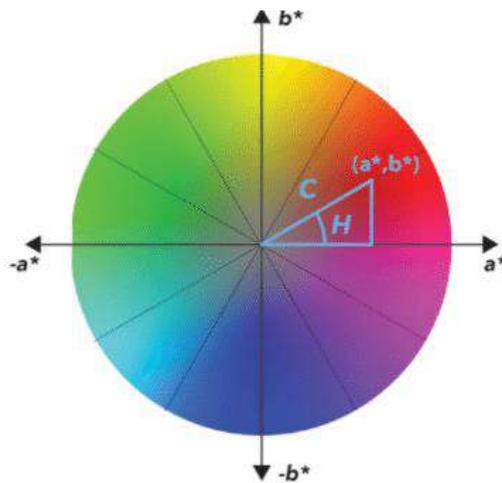
El color de la carne es poco estable y tanto la oximioglobina como la desoximioglobina se oxidan a metamioglobina, con el paso del tiempo, en la cual, el grupo hemo se oxida y pasa al estado férrico ( $Fe^{3+}$ ) y el agua ocupa la sexta posición coordinada. La metabioglobina no se une al oxígeno, por lo que, es fisiológicamente inactiva (Faustman & Cassens, 1990). La metabioglobina otorga a la carne un color café, el cual es asociado con la falta de frescura por el consumidor (Hood & Riodan, 1973)



**Figura 2.** Diagrama del efecto en el color con las posibles formas de mioglobina de la carne (Imagen adaptada).

Para realizar la medición de color se utiliza principalmente el espacio de color CIELAB en el área de alimentos. Este espacio de color es una medición

internacional de color estándar (CIE, 1976). En este espacio, el parámetro  $L^*$  significa luminosidad y su rango de valores va de 0 a 100, mientras que, los parámetros  $a^*$  (verde a rojo) y  $b^*$  (azul a amarillo) son dos componentes cromáticos y su rango de valores es de -120 a 120; el parámetro  $C^*$  es el valor cromático o saturación de color, y  $H^*$  o Hue es el ángulo del color (Imagen 3) (Pedreschi et al., 2004; Papadakis et al., 2000; Mendoza et al., 2004).



**Figura 3.** Espacio de color CIELAB (Braña et al., 2011)

La coloración de la carne se puede ver afectada por diversos factores, como la raza y la edad del ganado, así como las condiciones del animal previas al sacrificio, y las condiciones del producto durante y post sacrificio; donde el desarrollo microbiano, la atmósfera de contacto, así como el pH y la temperatura, influyen la coloración de la carne, y por tanto, su potencial de compra.

### 2.2.2 pH

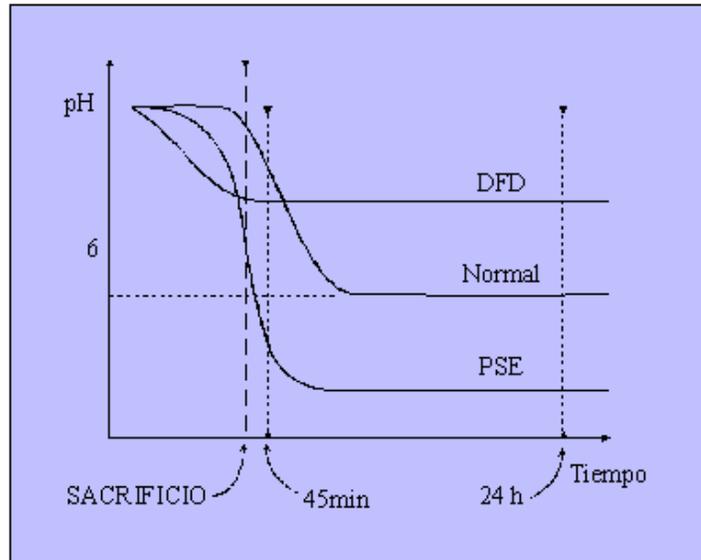
El pH es definido como el logaritmo negativo de la concentración de protones en una solución. Tiene una escala de valores entre 0 y 14. Un valor por debajo de 7 es considerado como ácido, y por encima de 7 se considera alcalino o también denominado básico. El pH es uno de los principales parámetros a considerar para verificar la calidad de la carne, porque afecta varios aspectos: color, capacidad de retención de agua, entre otros.

El pH del músculo de animales sanos y vivos es de alrededor de 7.05 (Johnson, 1994). Este valor disminuye tras la muerte del animal, principalmente, debido a la degradación del glucógeno a ácido láctico, una reacción en la que, el músculo trata de producir energía en ausencia de oxígeno. La acumulación de ácido láctico continúa hasta 24 h posteriores a la muerte. Esta reacción, depende primordialmente de la actividad de una serie de enzimas que son sensibles a la temperatura, por lo que, es relevante considerar la temperatura del músculo al momento de hacer la medición de pH (Lundberg et al., 1986).

La variación del valor de pH, se da por un sinnúmero de factores, algunos de ellos son intrínsecos al animal (genética, metabolismo, susceptibilidad al estrés, entre otros) (López-Bote, 2017), pero normalmente los factores más relevantes tienen que ver con el ambiente en que se manejó el animal y su canal, durante las 24 h previas y posteriores al sacrificio.

Previo al sacrificio, el manejo del animal es un factor clave, ya que un exceso de estrés provocará la sobreproducción de adrenalina, que tiende a promover la degradación de glucógeno y por ende favorece la caída abrupta del pH (acidificación). Luego del sacrificio, una mala refrigeración de la canal, con temperaturas elevadas, promoverá también una rápida caída del pH. Dependiendo

de la velocidad de la disminución del pH post-mortem y del pH final alcanzado de la carne, se distinguen diferentes tipos de carne (Figura 4).



**Figura 4.** Disminución del pH después del sacrificio (Braña et al., 2011).

Una caída lenta del pH post-mortem, es ocasionada cuando las reservas de glucógeno en el animal son escasas, por ejemplo, el estrés por un transporte largo con tiempos de ayuno muy prolongados, lo que se empeora con temperaturas ambientales frías. Esto provoca un menor contenido de ácido láctico, ocasionando un pH final elevado (6.0-6.8) en comparación con una carne normal (5.4-5.9) (Bate-Smith, 1948). La carne con pH alto, se torna oscura, dura y seca, de ahí su denominación como carne DFD (Dark, firm, dry, por sus siglas en inglés). El color oscuro de la carne provoca rechazo por el consumidor, por ser asociada a carnes provenientes de animales viejos. El pH alto de la carne DFD la hace más susceptible a la proliferación de microorganismos, comprometiendo su vida de anaquel (Immonen et al., 2000).

Para el caso en el que la disminución de pH post-mortem sea acelerado y la caída de pH ocurra antes de que la carne pueda ser enfriada eficazmente, la combinación de un bajo pH y alta temperatura (arriba de 32°C) (Thompson et al., 2005), ocasiona una desnaturalización anormal de las proteínas musculares, generando así una carne pálida, suave y exudativa (PSE pale, soft, exudative, por sus siglas en inglés). Mientras más rápido baje el pH del músculo, retendrá menos agua, y así se reducirá el rendimiento de la carne y se afectará el color de la carne. Dando una apariencia pálida (Marsh, 1954).

El pH de las carnes PSE estará normalmente por debajo de 5.5. Sin embargo, la carne puede tener apariencia PSE y tener un pH normal. Esto ocurre cuando la caída de pH es muy abrupta durante la primera hora post-mortem; asociada a estrés inmediatamente antes de la muerte del animal (Braña et al., 2013).

Por lo anterior lo deseado es generar las condiciones adecuadas, pre y post sacrificio, que logren tener la carne en un rango de pH de 5.4 a 5.9 con una coloración rojo cereza y una retención de agua adecuada.

### **2.2.3 Capacidad de retención de agua**

La capacidad de retención de agua (CRA) también influye la aceptación visual de los consumidores. Además, este parámetro determina la pérdida de agua durante el transporte, el almacenamiento, el procesamiento, y el cocinado. La jugosidad es en parte determinada por la CRA y contribuye a la calidad del consumo, jugando un papel importante en la textura de la carne. Por lo tanto, el agua es importante en la estructura de la carne, y por consecuencia, en la calidad de la carne.

La CRA se define como la habilidad de la carne y productos cárnicos para unir agua durante el rebanado, la molienda, la presión, el almacenamiento, el procesado y el cocinado (Hamm, 1986). La pérdida de agua puede ser descrita como goteo, purga, exudado, o pérdida de cocinado, que es inversamente proporcional a la CRA (Warner, 2014). La CRA se refiere al agua ligada a la carne y también al agua añadida durante las operaciones de procesamiento.

Existe una relación directa entre el agua y la grasa contenida, si el porcentaje de grasa incrementa el porcentaje de agua disminuye. Además, cerca del 85 % del volumen del músculo son miofibrillas y la mayoría del agua está asociada con estas. Cerca del 1 % del agua en la carne es clasificada como agua ligada y esta unión se lleva a cabo con las proteínas (Huff-Lonergan & Lonergan, 2005). La cantidad de agua ligada muestra muy poco cambio en el músculo post-mortem. Otra fracción de agua en la carne recibe el nombre de agua "inmovilizada" o "atrapada" (Fennema, 1985), en la cual, el agua es retenida por fuerzas estéricas o de atracción. Esta fracción no se libera de la estructura fácilmente, pero puede ser removida durante el secado y se puede perder en el rigor y por cambios en la estructura de las proteínas, como la degradación de proteínas o por cambios abruptos de pH. Esta fracción constituye el 85 % del total de agua (Pearce et al., 2011). El agua libre es la fracción de agua que fluye sin obstáculos en la estructura cuando se presentan las condiciones para que ocurra (Pearce et al., 2011). Está presente en los fluidos sarcoplasmáticos y es retenida por fuerzas capilares entre (extramiofibrilares) y en (inramiofibrilares) las miofibrillas.

El agua retenida en la carne por capilaridad es similar al agua inmovilizada en una esponja u otro material poroso. La magnitud de la fuerza inmovilizadora es inversamente relacionada a la magnitud del tamaño del poro

(Warner, 2017). Para que el agua sea removida de la carne, una presión externa debe ser aplicada, la cual es mayor que la generada por los capilares (Trout, 1988).

El porcentaje de CRA de la carne fresca es de 75 %, aunque este dependerá del musculo que se analice y su cantidad de grasa (Warner, 2017).

#### **2.2.4 Textura de la carne**

La textura en los alimentos se ha definido como "todo elemento reológico y atributos estructurales (geométricos y de superficie) del producto perceptible por medio de mecánica, táctil y en su caso, receptores visuales y auditivos" (Lawless & Heymann, 1998). Los parámetros de textura son generalmente medidos por técnicas convencionales, como son los métodos sensoriales e instrumentales, que consumen tiempo y son destructivos para el producto. La relación de variables de textura instrumentales con la percepción humana de la textura ha sido un área muy activa de investigación (Lockett et al., 2014).

Se han desarrollado múltiples métodos instrumentales en un intento de evaluar la textura de las carnes, con un enfoque en la "terneza" de los productos de carne muscular entera (Cheny Opara, 2013; Wezemaal et al., 2014). Entre muchos parámetros de calidad, la terneza es considerada como uno de los atributos más importantes que afectan la calidad de consumo de la carne. Se correlaciona positivamente con la jugosidad y el sabor, y tiene una influencia sustancial en la satisfacción general del consumidor conocida como palatabilidad (Rust et al., 2008; Juarez et al., 2012).

Por lo tanto, los factores que determinan la palatabilidad de la carne son la terneza, la jugosidad y el sabor. De estos tres, la terneza es el factor impulsor en términos económicos (Boleman et al., 1997; Savell y Shackelford, 1992). Los

consumidores afirman que la terniza es el atributo más deseado al comer un filete (Huffman et al., 1996).

Hay múltiples factores que influyen en la terniza de la carne, y cada uno de estos factores está respaldado por teorías en el intento de explicar cómo influyen en este parámetro. Por todos los propósitos prácticos, cuatro características generales son consideradas las más importantes: la proteólisis post-mortem, la grasa o marmoleado intramuscular, el tejido conectivo y el estado contráctil del músculo. Estos factores también pueden contribuir a la diferencia de terniza entre diferentes músculos dentro de las mismas canales (Ogdhal et al., 2017).

### **2.3 Métodos no destructivos para la evaluación de calidad de carne**

Tradicionalmente, la medición de parámetros de calidad de la carne es llevada a cabo por análisis sensoriales, mecánicos o instrumentales (Cheng et al., 2017). Estos métodos son laboriosos, invasivos, tardados y poco amigables con el ambiente. Por esto, el estudio de la calidad de la carne ha sido de gran interés y continuamente se han estudiado técnicas alternativas para la eficiente medición y control de calidad (Narsaiah et al., 2020).

La medición y el control de la textura de la carne son importantes para el productor, ya que, determinan el valor del producto el mercado. Razón por la cual, los investigadores se han interesado por estudiar la relación entre la estructura de la carne, la textura y sus propiedades mecánicas (Lillford, 2018). El desarrollo de un método preciso, no invasivo ni destructivo, que pueda predecir calidad de la carne, en términos de su textura, se ha convertido en una necesidad urgente en la industria cárnica (Chen et al., 2020).

La espectroscopia visible y NIR (Infrarrojo cercano) son métodos ya utilizados para medir la composición de la carne. Funcionan con el principio de absorción, reflexión, transmisión y/o la dispersión de la luz a través del alimento, siguiendo la ley de Beer-Lambert (Narsaiah et al., 2020). La absorción o reflectancia de la radiación por la carne en la región NIR es a menudo compleja y normalmente posee amplias bandas de absorción de NIR superpuestas. En esta técnica, frecuentemente se utiliza análisis de datos multivariados para filtrar la gran cantidad de datos espectrales, lo cuales se usan para ser correlacionados con una cierta propiedad con datos espectrales relevantes específicos (Jha & Garg, 2010).

También, la absorción o reflectancia de la luz en un rango conocido de longitud de onda es medido y correlacionado con diferentes parámetros de calidad del alimento (Ghazali et al., 2013). Las imágenes obtenidas con esta técnica se han usado para predecir variables de textura como son masticabilidad, elasticidad, dureza y firmeza (Pérez-Palacios et al., 20019; Alamprese et al., 2016). Así como, para evaluar otras variables de calidad como marmoleo, humedad, frescura, fuerza de corte y pH (Cheng et al., 2015; Ghazali et al., 2016; Neyrinck et al., 2015; Sadeghi-Mehr et al., 2018).

En los últimos años, se ha mejorado la espectroscopia tradicional con la técnica de imágenes hiperspectrales, la cual, consiste en recopilar y procesar información a lo largo de todo el espectro electromagnético. La formación de imágenes divide el espectro en muchas bandas que pueden extenderse más allá de lo visible. Cada imagen representa un rango del espectro, que, al combinarse forman una imagen tridimensional hiperspectral obtenidas a partir de un hipercubo. Esto proporciona una distribución espacial de los parámetros de calidad de una muestra de carne (Narsaiah et al., 2020). Este método se ha

utilizado exitosamente para predecir parámetros de calidad como contenido de humedad (Kamruzzaman et al., 2016), contenido de grasa (Lohumi et al., 2016; Cheng et al., 2015), terneza (Naganathan et al., 2016; Jiang et al., 2018), variables de textura (Wang et al., 2019), pH (Barbin et al., 2012), color (Christiansen et al., 2012; Kamruzzaman et al., 2016; Sharifzadeh et al., 2014), capacidad de retención de agua (Kamruzzaman et al., 2016) y deterioro microbiano (Dissing et al., 2013; Panagou et al., 2014, Tao et al., 2015; Tsakanikas et al., 2015; Tsakanikas et al., 2016).

Adicionalmente, la resonancia magnética nuclear provee información bioquímica de una muestra en análisis (Scheier et al. 2014). Este método se ha utilizado para estudiar la dureza como una variable de textura (Muriel et al., 2004; Romero de Ávila et al., 2014). También se ha propuesto el uso de algoritmos de visión computarizada basado en la distribución radial de las imágenes y estadística de segundo orden (Ávila et al., 2019).

El Cuadro 1 muestra diversos métodos a través de los cuales se ha determinado y monitoreado la calidad de la carne. Estos métodos han hecho uso del análisis de imágenes.

**Cuadro 1.** Métodos para monitoreo de calidad de la carne

| <b>Método</b>                 | <b>Aplicación</b>  | <b>Referencia</b>                              |
|-------------------------------|--|--|
| Imagen de ultrasonido         | Inactivación de microorganismos, aumento de vida de anaquel, mejorar terneza     | Brewer et al., 2012, Alarcon-Rojo et al., 2015 |
| Rayos X, resonancia magnética | Fragmentos de hueso, densidad mineral del hueso, humedad y cambios en estructura | Wells et al., 2013; Hoban et al, 2016          |

|                         |   |   |
|-------------------------|---|---|
| Imagen de fluorescencia | Frescura de la carne,<br>detección de cambios térmicos  | Liu et al., 2019; Sahar et al.,<br>2016                       |
| Imagen hiperspectral    | Humedad, detección de<br>contaminantes, fragmentos de<br>hueso,<br><br>detección de tumores,<br>elasticidad | Chao et al., 2010; Yang et al.,<br>2010; Kandpal et al., 2013 |
| Imágenes térmicas       | Deterioro microbiano,<br>monitoreo de cocción,<br>medición de temperatura de la<br>piel                     | Feng- Sun 2013; Xiong et al.,<br>2017                         |

(Fuente: Elaboración propia).

El método de procesamiento de imágenes en conjunto con métodos ópticos, son una herramienta de evaluación no destructiva, utilizada en los últimos años para determinar la composición química de la carne (Kandpal et al., 2019; Myhan et al., 2016), frescura de la carne (Taheri-Garavand et al., 2019; Asmara et al., 2018) y grado de calidad comercial determinado por el nivel marmoleo, que es una medida de la densidad de distribución de grasa en la región rib-eye (Cernadas et al., 2002; Giaretta et al., 2018; Jackman et al., 2008, 2009).

Como se ha observado en este último método de evaluación descrito, recientemente se ha probado el uso de tecnología de bajo costo y que sea sensible, como lo es el uso de una cámara monocromática en conjunto con un ordinario diodo emisor de luz (LED) como fuente de iluminación, que elimine el complicado diseño y alto costo del equipamiento necesario (Kandpal et al., 2019), en combinación con el análisis de imágenes.

## 2.4 Análisis de imagen

En las últimas décadas, las técnicas de procesamiento de imágenes han tenido un gran avance, debido a su capacidad para caracterizar propiedades físicas como tamaño, forma, color y propiedades de textura en imágenes digitales, razón por la cual, han sido utilizadas en diversas áreas. Las técnicas de procesamiento de imagen en la industria de alimentos han sido utilizadas desde hace tiempo y se han aplicado como un método de evaluación no-destrutivo de la calidad en diversos alimentos (Du & Sun, 2004).

El análisis de procesamiento de imagen generalmente consta de cinco pasos que son: adquisición de imagen, operaciones de pre-procesamiento, segmentación de la imagen y extracción de las características del objeto bajo estudio.

La adquisición de la imagen se refiere a la captura de una imagen a su forma digital y es la primera etapa de las técnicas de procesamiento de imagen. Diversos sensores han sido empleados para la captura de imágenes, las cámaras con dispositivo de carga acoplado (CCD por sus siglas en inglés) son los sensores que más se emplean para la evaluación de la calidad de alimentos, ya que, a través de las imágenes obtenidas por estos sensores se pueden evaluar características como tamaño, forma, color, textura y defectos externos. Sin embargo, este tipo de sensores no permiten evaluar la estructura interna de alimentos, por lo que existen otras tecnologías de adquisición de imágenes como el ultrasonido, la resonancia magnética nuclear y la tomografía computacional y eléctrica, los cuales proporcionan información de los atributos internos de los alimentos (Du & Sun, 2004).

La iluminación es un requisito importante en la adquisición de las imágenes para la evaluación de la calidad de un alimento. La calidad de la imagen capturada puede ser afectada en gran medida por las condiciones de iluminación, ya que, estas influyen directamente sobre las características de textura de la imagen, la cual, está determinada por las escalas de grises de los píxeles que la conforman. Una imagen de alta calidad puede ayudar a reducir el tiempo en el procesamiento, en las siguientes etapas del procesamiento de imagen, y, en consecuencia, a reducir los costos del sistema del análisis de imágenes (Du & Sun, 2004; Pedreschi et al., 2004).

El pre-procesamiento por píxel puede ser entendido como una operación donde los valores de los píxeles son modificados aplicando una función específica de transformación y se emplea para realizar transformaciones en los espacios de color de las imágenes. En el área de alimentos la transformación más común que se realiza es entre el espacio de color RGB y el CIELAB (Du & Sun, 2004). El pre-procesamiento local es un método, por el cual, se calcula un nuevo valor de píxel, basado en el promedio en los valores de brillo de los píxeles cercanos y esta propuesta se utiliza para mejorar los bordes o límites de las formas que se encuentran contenidas en una imagen (Du & Sun, 2004).

El propósito del pre-procesamiento de la imagen es mejorar la información de la misma, en donde se pueden disminuir distorsiones o realzar algunas características de la imagen que son importantes para su futuro procesamiento, y con esto, crear una imagen mejor a la original. Existen dos tipos de propuestas para el pre-procesamiento de imágenes para evaluar la calidad de los alimentos: el pre-procesamiento por píxel y el pre-procesamiento local. Estas dos propuestas se basan en el cambio de los valores de los píxeles que conforman la imagen.

La segmentación de la imagen consiste en identificar regiones de la imagen con el propósito de separar aquellas regiones de interés del fondo. Para la evaluación de calidad de alimentos, existen cuatro propuestas para realizar la segmentación de la imagen, pero sólo dos son las más utilizadas: la segmentación basada en el thresholding y la segmentación basada en regiones. La primera consiste en segmentar objetos sólidos que poseen un contraste diferente del fondo y la segunda en separar regiones o grupos de píxeles que tengan un mismo tono en escala de grises de una sección de la imagen (Du & Sun, 2004; Pedreschi et al., 2004).

Después de detectar aquellas zonas de interés, el siguiente paso es la extracción de las características del objeto bajo estudio que se pueden clasificar en cuatro clases: tamaño, forma, color y textura (Du & Sun, 2004). Comúnmente los parámetros utilizados para medir el tamaño de un objeto son el área, perímetro, longitud y diámetro; pero la medición más conveniente para evaluar esta característica es el área. Por otra parte, el diámetro de un objeto se utiliza para discriminar entre dos objetos de formas diferentes. En la revisión realizada por Du & Sun (2004) se mencionan algunos trabajos como ejemplo: Monnin (1994) diseñó un sistema para un proceso de cocimiento de galletas donde se midió el diámetro, el área y el espesor de las galletas. La longitud y el ancho de un objeto pueden ser usados también para medir el tamaño; por ejemplo, Van Eck et al. (1998) desarrollaron un método exacto para medir la longitud, el ancho y la forma de pepinos. La forma es una de las mediciones más comunes que se realizan en los alimentos, en comparación con las características de textura y color. La medición de la forma es fácil utilizando el procesamiento de imágenes. Frecuentemente los objetos de una clase pueden distinguirse de otros por su forma, ya que estas son mediciones físicas comunes.

A manera de ejemplificar una ventaja del uso de procesamiento de imágenes en la evaluación de aspectos de calidad, la evaluación del color con técnicas instrumentales, como es el uso de colorímetros, permite medir el color de alimentos, pero con la limitante de que son mediciones puntuales (Pedreschi et al., 2004; Papadakis et al., 2004), pero las técnicas de análisis de imagen proveen mediciones del color de imágenes digitales de forma exacta y no invasiva a partir de los valores de los píxeles de la imagen (Du & Sun, 2004).

## **2.5 Análisis de textura de una imagen**

La textura es un atributo representado por el arreglo espacial en niveles de grises de los píxeles de un objeto o región de interés de una imagen, la cual, cuantifica algunas características visuales dentro de la imagen. (Haralick et al., 1973; Du & Sun, 2004).

El análisis de textura de imágenes en los alimentos se ha usado con el propósito de medir de manera cuantitativa los cambios estructurales de alimentos a partir de imágenes (Quevedo et al., 2008). En la carne, se ha aplicado en diversos estudios para evaluar atributos de calidad, composición y otras particularidades importantes como la adulteración.

Basset et al. (2000) analizaron la correlación entre parámetros texturales y mediciones físicas en muestras de carne de res de 26 carcasas de animales diferentes. Para el estudio, utilizaron 8 diferentes metodologías para obtener en total 58 parámetros texturales diferentes (incluyendo GLCM y momentos estadísticos). Además, de cada muestra se midieron los contenidos de materia seca, lípidos, colágeno, así como dos parámetros mecánicos de compresión. Los autores utilizaron el método de K-vecinos más próximos, que clasifica a partir de la distancia del patrón de entrenamiento con un nuevo patrón de base de datos Se

examinó la eficiencia de correlación de los parámetros texturales con las variables fisicoquímicas, obteniendo valores de  $R^2$  entre 0.3 a 0.59, teniendo resultados significativos estadísticamente ( $P < 10^{-4}$ ). Los resultados mostraron que los parámetros de textura más relevantes en los experimentos de clasificación fueron los que dan una descripción global de las intensidades de gris. Solo el 25.4 % de las muestras fueron clasificadas correctamente. Lo que podría ser mejorado si no se consideran demasiados factores en el estudio.

Jackman et al. (2010) evaluaron, en 34 muestras de carne de res, la relación entre variables de color, marmoleo y textura superficial, obtenidos con un sistema de visión computarizado, con evaluaciones de palatabilidad (agrado, terneza, sabor, jugosidad) obtenidas a partir de evaluación sensorial de consumidores. Se calcularon estadísticos de primer orden en las imágenes obtenidas y estos datos fueron relacionados con los resultados del análisis sensorial usando una regresión parcial de mínimos cuadrados (PLSR por sus siglas en inglés). Con los resultados, fue posible modelar la opinión del consumidor con valores de  $R^2$  de 0.86 para agrado, 0.76 para terneza, 0.78 para sabor y 0.69 para jugosidad, lo que permitió sugerir que el método de visión propuesto por estos autores puede correlacionarse significativamente con evaluación sensorial.

Ogdhal et al. (2019) analizaron la terneza de la carne usando la relación entre la evaluación de fuerza de corte, y parámetros de textura de imágenes que se extrajeron usando la GLCM, la transformada de Fourier y el filtro Gabor Wavelet. Todos los datos se usaron para predecir la terneza de la carne de res. usando un modelo de regresión STEPWISE. Los resultados mostraron que se obtuvo un coeficiente de determinación de 0.82, lo que significa que, los

parámetros de textura fueron capaces de explicar el 82 % de la variación de la ternura, determinada por el valor de fuerza de corte.

Otro aspecto de calidad de la carne estudiado a través del análisis de imagen es el color.

Barbri et al., (2014) llevaron a cabo una medición bacteriológica de muestras de carne en paralelo con el análisis de imagen usando un sistema de visión artificial con el que se obtuvo el color de la carne con imágenes en RGB (red, green, blue) y HSI (hue, saturación e intensidad). Para clasificar la carne en función del deterioro SE utilizaron los datos de la cuenta microbiana y los parámetros de imagen, analizando su relación mediante el uso de una arquitectura de red neuronal para el aprendizaje incremental supervisado de analógicos multidimensionales (Fuzzy ARTMAP). Los resultados permitieron clasificar las muestras de carne con base en la cuenta microbiana total y el cambio de color, como carne no deteriorada y deteriorada. Obteniendo 95.24 % de exactitud con el modelo creado en la clasificación.

Asmara et al. (2018) midieron, en dos tipos de muestras de carne, parámetros de estadísticos de primer orden del color de imágenes en RGB y parámetros de textura con GLCM con la finalidad de identificar diferencias en el color de carne de res y cerdo y poder clasificarlas en cuanto a este aspecto. Con los resultados se construyó un modelo de clasificación para la carne de ambas especies, utilizando un algoritmo de retro-propagación. Los resultados mostraron un 79.14 % de éxito en la clasificación para carne de cerdo y 100 % para la carne de res.

Arsalane et al. (2020) midieron el cambio de color en muestras de carne durante 9 días en refrigeración, también midieron momentos estadísticos de las imágenes y parámetros de textura con GLCM. Usando análisis de componentes principales (PCA), redes neuronales probabilístico (PNN) y Máquina de vector de soporte (SVM) construyeron un modelo para clasificar y predecir la frescura de la carne, con una exactitud en el rango de 81.5 % a 98.8 %.

Como se puede observar, han sido desarrollados algunos métodos para analizar la textura de imágenes, y uno de los más empleados es el algoritmo de Matriz de Coocurrencia en Escala de Grises (GLCM por sus siglas en inglés).

El algoritmo de Matriz de Coocurrencia en Escala de Grises se basa en la idea de que una imagen puede ser analizada a través del número de píxeles o cuadros que la forman en dirección horizontal  $N_x$  y en dirección vertical  $N_y$ . Además, cada uno de estos píxeles tiene un valor en tono de gris que es cuantificado hasta  $N_g$  niveles. Por lo tanto, considerando lo anterior, una imagen puede ser representada como una función, la cual asigna diversos tonos de grises para cada píxel o conjunto de píxeles, y a partir de esta información se puede caracterizar la textura de una imagen.

A partir de este algoritmo, se pueden extraer varios parámetros de textura, algunos de los cuales, se relacionan con características como la homogeneidad, contraste y la presencia de estructuras organizadas dentro de la imagen. A continuación, se definen brevemente algunos de los parámetros de textura basados en este algoritmo.

La energía mide la uniformidad textural de la imagen y es un parámetro opuesto a la entropía. El parámetro de energía también es conocido como uniformidad, uniformidad de energía y segundo momento angular.

El contraste es una medida de las variaciones locales de los valores en escala de grises de los píxeles de una imagen. El contraste también es conocido como varianza o inercia.

El parámetro de homogeneidad, también llamado como diferencia de momento inverso es una medida similar a la energía; la cual también representa la homogeneidad local de la imagen.

Por último, la entropía es el parámetro que mide el desorden o aleatoriedad de las imágenes y puede ser usado para caracterizar la textura de la imagen y es un indicativo de la complejidad dentro de la imagen, por lo tanto, imágenes complejas tendrán altos valores de entropía (Haralick et al., 1973; Fernández, Castellero, & Aguilera, 2005; Mendoza et al., 2007).

La GLCM es una tabulación que permite observar que tan frecuente ocurren diferentes combinaciones de niveles de gris en una sección de la imagen. Se calcula en cualquier ángulo (dirección) y distancia.

La homogeneidad se calcula con la ecuación (1), siendo  $P_{i,j}$  la probabilidad de coocurrencia de los valores de gris  $i$  y  $j$ , para una distancia dada (Ec. 1).

$$\sum_{i,j=0}^{N-1} \frac{P_{i,j}}{1 + (i - j)^2} \quad Ec. (1)$$

El contraste es lo opuesto a la homogeneidad, es decir es una medida de la variación local en una imagen. Tiene un valor alto cuando la imagen dentro de la escala de la ventana tiene un alto contraste, (Ec. 2).

$$\sum_{i,j=0}^{N-1} P_{i,j}(i-j)^2 \quad Ec. (2)$$

La ecuación para el cálculo de la entropía (Ec 3). La entropía es alta cuando los elementos de la matriz de coocurrencia tienen relativamente valores iguales. Es baja cuando la imagen es uniforme dentro de la ventana.

$$\sum_{i,j}^{N-1} -P_{i,j} \ln(P_{i,j}) \quad Ec. (3)$$

Si  $P_{i,j}$  es una probabilidad y toma valores entre 0 y 1, entonces el  $\ln(P_{i,j})$  siempre tomará valores de 0 o negativos. Cuanto más pequeño sea el valor  $P_{i,j}$  es decir que la ocurrencia de esa combinación de píxeles es poco común, el valor absoluto de  $\ln(P_{i,j})$  será mayor.

En la correlación se obtiene un resultado entre 1 y -1, puede ser usada en combinación con otra medida textural. Se calcula con la ecuación (4):

$$\sum_{i,j=0}^{N-1} P_{i,j} \left[ \frac{(i - \mu_i)(j - \mu_j)}{\sqrt{(\sigma_i^2)(\sigma_j^2)}} \right] \quad Ec. (4)$$

El segundo momento angular muestra la uniformidad de la distribución de niveles de gris (Ec. 5) (González- Woods, 2007).

$$\sum_{i,j=0}^{N-1} P_{i,j}^2 \quad Ec. (5)$$

## **2.6 Algoritmos estadísticos para la construcción de modelos de predicción**

Un algoritmo predictivo es una representación matemática de un factor que tiene lugar en la realidad y que ayuda a predecir cualquier comportamiento futuro sea de las maquinarias u otros procesos de producción con base en el conocimiento presente. Existen diversas técnicas estadísticas para construir modelos predictivos; a continuación, se describen algunas frecuentemente utilizadas.

Análisis de componentes principales (PCA Por sus siglas en inglés), es una técnica utilizada para describir un conjunto de datos en términos de nuevas variables (componentes) no correlacionadas. Los componentes se ordenan por la cantidad de varianza original que se describen, por lo que la técnica es útil para reducir la dimensionalidad de un conjunto de datos. Busca la proyección según la cual los datos queden mejor representados en términos cuadrados. Esta convierte un conjunto de observaciones de variables posiblemente correlacionadas en un conjunto de valores de variables sin correlación lineal, llamadas componentes principales. Se emplea para el análisis exploratorio de datos y para construir modelos predictivos (Arasalane et al., 2016).

Red neuronal Probabilística (PNN), ejecuta un método no paramétrico para clasificar observaciones con alta confiabilidad. Construye una estimación no paramétrica de cada función de densidad por cada una de las categorías en una posición deseada, con base a observaciones cercanas a esa categoría. La estimación es basada en una ventana de Parzen que pondera observaciones a partir de cada categoría de acuerdo a su distancia de la posición especificada (Barbri et al., 2014).

Máquina de vector de soporte (SVM) es un algoritmo de aprendizaje supervisado. Es un método de regresión y clasificación. Dado un conjunto de muestras de entrenamiento se pueden etiquetar clases y entrenar una SVM para construir un modelo que prediga la clase de una nueva muestra. Es un modelo que representa a los puntos de muestra en el espacio, separando las clases a 2 espacios lo más amplios posibles mediante un hiperplano de separación definido como el vector entre los 2 puntos, de las 2 clases, más cercanos al que se llama vector soporte. Cuando las nuevas muestras se ponen en correspondencia con dicho modelo, en función de los espacios a los que pertenezcan, pueden ser clasificadas a una o la otra clase (Arsalane et al., 2018).

Regresión de mínimos cuadrados (PLRS), consiste en explicar una de las variables en función de la otra a través de un determinado tipo de función (lineal, parabólica, exponencial, entre otras) de forma que la función de regresión se obtiene ajustando las observaciones a la función elegida, mediante el método de mínimos cuadrados. Proporciona una forma de encontrar la mejor estimación suponiendo que los errores, es decir las diferencias con respecto al valor verdadero, sean aleatorias e imparciales (Jackman et al., 2010)

Análisis de trayecto (Path Analysis) en esencia, es un estudio que permite evaluar si una relación entre dos variables es de causa y efecto, o es determinada por la influencia de otra u otras variables. Es un análisis de regresión múltiple más un diagrama de flujo de las interdependencias. Es una aplicación de la inferencia estadística y la teoría de grafos. Primero se determina el orden de las dependencias o prioridades entre variables por una evaluación previa, por un método intuitivo u otro método. Hecha la selección se analiza este material con tablas de contingencia y el análisis medirá los caminos críticos con valores esperados o reales. La principal propiedad es que el modelo es más expresivo que

una tabla, como era de esperar cuando se recurre a un método gráfico para análisis multivariable. Las rutas de trayecto se pueden establecer como ecuaciones estructurales lineales de coeficientes de trayecto (Stage et al., 2004).

La regresión logística múltiple, es una técnica estadística que permite estimar la relación existente entre una variable dependiente no cuantitativa y un conjunto de variables cuantitativas o no cuantitativas. La variable dependiente o respuesta no es continua, sino discreta (generalmente toma valores de 0 a 1). La ecuación del modelo es exponencial. Así pues, el modelo será de utilidad cuando el perfil de variables está formado de caracteres cuantitativos y cualitativos, que se pretenden incluir en una sola ecuación. El modelo puede acercarse a la realidad, ya que muchos fenómenos se asemejan más a una curva que a una recta. La curva exponencial elegida con el mejor ajuste, puede ser transformada logarítmicamente en una ecuación lineal de todas las variables (Montgomery, 2003).

## **2.7 Programas utilizados para análisis de imagen**

Existen muchos sistemas orientados al procesamiento de imágenes. La mayor parte de ellos han sido desarrollados durante años y contienen multitud de clases y procesos. En cualquier caso, es más conveniente utilizar los programas existentes antes que desarrollar un nuevo sistema desde el principio.

ImageJ es un programa de procesamiento de imagen de dominio público programado en Java desarrollado en National Institutes of Health. ImageJ fue diseñado con una arquitectura abierta que proporciona extensibilidad vía Plugins y macros. Puede mostrar, editar, analizar, procesar, guardar e imprimir imágenes de 8, 16 y 32 bits. Puede leer varios formatos de imagen incluyendo TIFF, PNG, JPEG, entre otras. Puede calcular el área y las estadísticas de valor de píxel de

selecciones definidas por el usuario. Puede crear histogramas de densidad y es compatible con las funciones estándar de procesamiento de imágenes tales como operaciones lógicas y aritméticas entre imágenes. Es compatible con cualquier número de imágenes al mismo tiempo, limitado solamente por la memoria disponible (Bailer, 2006).

Octave o GNU Octave es un programa y lenguaje de programación para realizar cálculos numéricos. Es considerado el equivalente libre de MATLAB. Está orientado al análisis numérico. Fue creado con la finalidad de ser utilizado en un curso de diseño de reactores químicos, posteriormente se decidió extenderlo. Octave está escrito en lenguaje C, tiene un intérprete de su propio lenguaje y permite una ejecución interactiva o por lotes. Su lenguaje puede ser extendido con funciones y procedimientos por medio de módulos dinámicos. El lenguaje está pensado para trabajar con matrices. Al ser pública su licencia general de GNU, puede ser utilizado libremente (Eaton, 1998-2021).

## **2.8 Sistemas de medición y confiabilidad**

Las mediciones otorgan la oportunidad de mejora en los procesos, al dar información para la toma de decisiones en el ajuste de algún tipo. Cuando las mediciones o alguna estadística calculada de estos, son comparados con los límites de control estadísticos del proceso. Otro uso de datos de mediciones es para determinar si existe una relación significativa entre dos o más variables. Esa posible relación puede ser estudiada usando un procedimiento estadístico llamado análisis de regresión para comparar las mediciones. Deming llamó *estudios analíticos* a la exploración de tales relaciones. En general, un estudio analítico es aquel que incrementa el conocimiento del sistema de causas que afectan el proceso.

El beneficio de usar un procedimiento basado en datos es ampliamente determinado por la calidad de los datos de medición usados. Si la calidad de los datos es baja, es probable que el beneficio del procedimiento sea bajo. Igualmente, si la calidad de los datos es alta, es probable que también el beneficio sea alto.

La calidad de los datos de medición es definida por las propiedades estadísticas de las múltiples mediciones obtenidas del sistema de medición, operando bajo condiciones estables. Si las mediciones están cerca del valor de referencia de la característica, entonces se dice que la calidad de los datos es alta.

Las propiedades estadísticas más comúnmente usadas para caracterizar la calidad de los datos son el sesgo y varianza del sistema de medición. El sesgo se refiere a la localización de los datos en relación al valor de referencia y la varianza se refiere a la dispersión de los datos. Una de las razones más comunes para datos de baja calidad es demasiada variación. Mucha variación en un conjunto de mediciones, puede ser debida a la interacción entre el sistema de medición y su medio ambiente. Esto hace que la interpretación de datos sea más difícil y consecuentemente el sistema de medición sea menos deseable. Por lo que, se requiere saber cómo los sistemas de medición interactúan con el medio ambiente de forma tal que, se generen solo datos de calidad aceptable.

Un sistema de medición es el conjunto de instrumentos o gages, patrones, operaciones, métodos, dispositivos, software, personal, medio ambiente y supuestos usados para cuantificar una unidad de medida o preparar la evaluación de una característica o propiedad a ser medida.

La obtención de información a través de datos debe ser registrada, clasificada y estudiada para tener un panorama real de lo que origina causas de variación.

Esta es conocida como trazabilidad, la cual, da detalle de cómo, cuándo, dónde y por ende el por qué sucedieron causas que pueden dar lugar a fallas.

A fin de administrar efectivamente la variación de cualquier proceso se requiere tener conocimiento de:

- Lo que el proceso debería estar haciendo.
- Lo que puede estar mal.
- Lo que el proceso está haciendo.

Los requerimientos de especificaciones e ingeniería definen lo que un proceso debería estar haciendo. Se adquiere conocimiento de lo que el proceso está haciendo evaluando los resultados del proceso mismo.

Al recabar datos, es indispensable saber qué medir, cómo medirlo, con qué medirlo y qué tan frecuente se debe medir. Es por ello que, las mediciones deben estar sustentadas por estudios R & R, es decir de repetibilidad y reproducibilidad. Para medir, es imprescindible asegurar que el método de medición es lo suficientemente preciso y exacto a tal grado que los datos reflejen la variación de las muestras y la del método de medición. Tener un método de medición que no sea preciso, creará más variación dentro del sistema, por lo que, será más difícil saber cuáles son las causas raíces de los problemas. Así mismo, es importante asegurarse que los instrumentos de medición son los apropiados y están correctamente calibrados.

Los dos términos de repetibilidad y reproducibilidad están enfocados en distinguir la capacidad del método de medición, es decir, obtener la misma lectura cada vez que se realiza la medición. La repetibilidad se refiere a la variación

inherente de los métodos de medición y la reproducibilidad a la habilidad para que diferentes personas produzcan resultados consistentes (Gutierrez et al., 2010).

### **III. HIPOTESIS**

La calidad de la carne de res se predice a través del uso de métodos estadísticos para obtener parámetros de textura a partir de imágenes que se relacionan con variables fisicoquímicas, con un coeficiente de correlación estadísticamente significativo, usando un 95 % de nivel de confianza.

### **IV. OBJETIVOS**

#### **4.1 Objetivo general**

Desarrollar un método de predicción que permita estimar la calidad de la carne a través de estadísticos que prueben la relación de variables fisicoquímicas con parámetros de textura, obtenidos a partir de imágenes digitales.

#### **4.3 Objetivos específicos**

- Examinar y documentar la relación de parámetros de textura obtenidos a partir de imágenes digitales con las características fisicoquímicas evaluadas.
- Probar la habilidad del método de medición propuesto con la variación dentro del sistema.
- Proponer un método de predicción para estimar la calidad de carne de res en términos de su frescura.

## **V. MATERIALES Y METODOS**

### **5.1 Materiales**

A continuación, se muestran una lista de los principales materiales utilizados.

#### *Material biológico*

- Bola de res

#### *Equipos*

- Potenciómetro para carne HANNA HI 99163
- Colorímetro Minolta
- Balanza Analítica Mettler Toledo XS204
- Refrigerador Torrey
- Papel filtro Watman 541
- Espátula metálica
- Vaso de precipitado 100, 500 mL

#### **5.2.1 Condiciones operativas de la metodología**

Se utilizaron muestras de carne de res del músculo correspondiente a la bola, ubicado en la parte alta de la pierna del bovino, adquiridas en una carnicería local, que hace uso del servicio que presta el Rastro Municipal TIF 412 del estado de Querétaro, por lo cual, se pudo monitorear el momento del sacrificio del animal del que provenían las muestras, además de conocer las condiciones en las que se llevó a cabo el sacrificio.

De inicio, se realizaron experimentos preliminares para determinar las condiciones operativas como son: forma de la muestra, dimensión, y procedimientos para manipular las muestras.

### **5.2.2 Preparación de las muestras**

Se utilizaron 10 muestras de músculo, libres de hueso, cortados en forma perpendicular a la dirección de las fibras musculares, y de aproximadamente 10 cm x 10 cm de área y 2.5 cm de espesor.

Las muestras fueron almacenadas a 4 °C en refrigeración hasta el momento de su análisis.

### **5.2.3 Descripción del experimento**

El experimento tuvo una duración de 9 días. Durante los cuales, se realizaron mediciones fisicoquímicas de color, pH, CRA y análisis de textura a partir de imágenes digitales para obtener contraste, entropía, segundo momento angular (ASM), inversa de la diferencia de momento (IDM) y correlación. Partiendo del periodo de maduración de la carne, que corresponde a 48 h después del sacrificio; las muestras se analizaron los días 0, 2, 4, 6, y 9. Cada determinación se realizó nueve veces. Durante toda la experimentación, las muestras se mantuvieron en condiciones de oscuridad, a una temperatura de 4°C en una cámara de enfriamiento.

A continuación, se describe cómo se llevó acabo cada medición.

### **5.2.4 Medición de color**

Para la medición de color, las muestras se expusieron 30 minutos al oxígeno del aire a una temperatura de 4 °C, para oxigenar la mioglobina. Posteriormente, se colocaron en una base blanca para realizar la medición; para lo

cual, se seleccionó un área de medición donde no existiera alta concentración de grasa intramuscular. La medición de color se realizó con un colorímetro Minolta, evitando cualquier presión que distorsionara la dirección de las fibras musculares. Se registraron los valores L\*, a\*, b\* C\* y h\*. Las mediciones se hicieron nueve veces sobre cada muestra (AMSA, 1992).

### **5.2.5 Medición de pH**

Previo a la medición de pH, se calibró el potenciómetro con buffer pH 4 y pH 7. La medición en las muestras se realizó con un potenciómetro para carne HANNA HI 99163; para llevarla a cabo, se hizo una perforación en la muestra de carne con un cuchillo; el electrodo se insertó directamente en el músculo, de manera perpendicular a la masa muscular y a unos 2 cm de profundidad. Después de cada medición, el electrodo se limpió correctamente y se volvió a introducir en otra parte del mismo músculo, para las subsiguientes lecturas. En total, se tomaron nueve lecturas de cada muestra (Honikel, 1998).

### **5.2.6 Capacidad de retención de agua**

Se pesaron muestras de 0.3 g y cada muestra se colocó entre dos hojas de papel filtro, las cuales se sometieron a un peso de 2.5 Kg durante 5 minutos. Las muestras se pesaron nuevamente y se determinó la capacidad de retención de agua (WHC) con la ecuación siguiente:

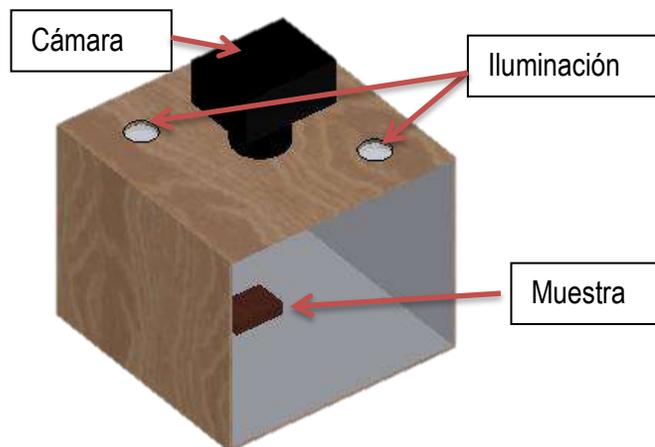
$$WHC = 100 - \left( \frac{i - f}{i} \times 100 \right)$$

Donde i es el peso inicial y f es el peso final (Soares et al., 2002).

La determinación fue realizada 9 veces para cada muestra.

### **5.2.7 Análisis de textura a partir de imágenes digitales**

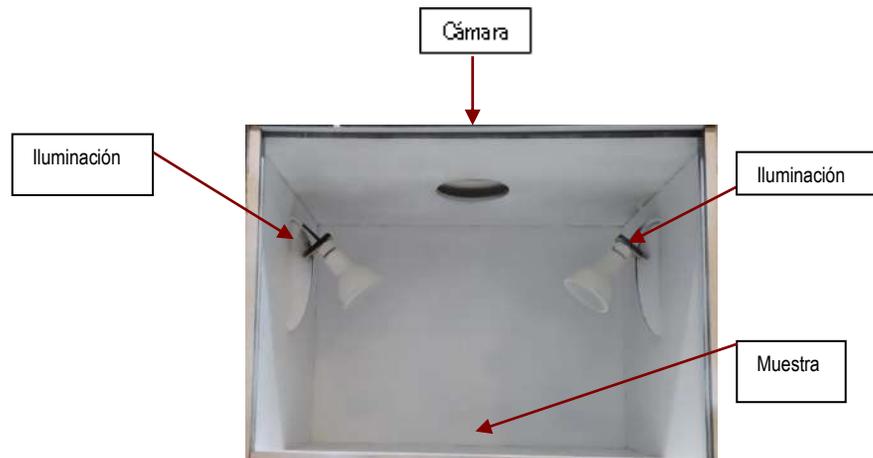
Un aspecto importante en la adquisición de datos, es tener un sistema estable de iluminación, para disminuir los posibles ruidos. Por esta razón, se diseñó un sistema que permitiera la iluminación adecuada. La Figura 7 muestra el diseño del sistema de visión, el cual, se construyó a partir de una caja de madera de 35 cm por lado, con las paredes internas de color blanco. Se colocaron dos lámparas de halógeno de 3000 K (Adesi pro, 35 W/120 V, China) en la parte superior para la iluminación al momento de las capturas de imagen.



**Figura 7.** Sistema de visión inicial.

Se observó que el sistema de visión presentaba fallas en la iluminación de la muestra, por lo que se mejoró el sistema de captura de imágenes. Las mejoras se hicieron disminuyendo las dimensiones de la caja y utilizando una luz blanca en posición angular que pudiera dirigirse al centro de la caja donde se colocaría la muestra. La Figura 8 muestra el diseño del sistema de visión, el cual, se construyó a partir de una caja de madera de 25 cm por lado, con las paredes internas de color blanco. Se colocaron dos lámparas LED de 6000 K (Voltech, LED-207E 05-

19, China) en paredes laterales para la iluminación al momento de las capturas de imagen.



**Figura 8.** Sistema de captura de imágenes final.

Para el análisis, se tomaron 9 imágenes de cada muestra, las cuales fueron convertidas a 8 bits (768 x 504 píxeles, formato TIFF) usando el programa Image J 1.52a (Maryland, EUA), y procesadas con el programa OCTAVE (GNU versión 6.2, 2021), obteniendo los parámetros de contraste, correlación, entropía, segundo momento angular e inversa de momento angular.

### **5.3 Análisis estadístico**

Se realizó un análisis de normalidad en los datos obtenidos para comprobar si presentaban un comportamiento normal. Posteriormente, se hizo un análisis de estadística descriptiva.

A continuación, se evaluó la repetibilidad de las mediciones fisicoquímicas de color, pH y CRA, así como de los resultados de textura de imágenes obtenidos con el sistema de visión propuesto.

También, se evaluó la significancia estadística entre las medias con una prueba de ANOVA y Tukey con un 95 % de nivel de confianza. El valor de P de 0.05 se usó para verificar la significancia de todas las pruebas. Además, se realizó un análisis de correlación con el método de Pearson ( $P < 0.05$  y  $P < 0.01$ ).

Consecutivamente, se realizó un análisis de regresión logarítmica múltiple nominal con la finalidad de crear un modelo de predicción ( $P < 0.05$ ).

## **V. RESULTADOS Y DISCUSIÓN**

### **5.1 Confiabilidad de las mediciones del estudio**

Una vez que se obtuvieron todos los datos del experimento completo, se analizó la normalidad de los mismos para las determinaciones fisicoquímicas y de textura a partir de imágenes.

En los resultados de normalidad se observó que los datos se acercan a la línea de ajuste y el valor de P es mayor al nivel de significancia ( $P > 0.05$ ), por lo que, los datos de las mediciones fisicoquímicas y de textura obtenidos de imágenes digitales tienen un comportamiento normal (Cuadro 2). En la Figura 9, se presenta como ejemplo, una gráfica obtenida de normalidad de una de las determinaciones (contraste), las gráficas de las otras determinaciones se incluyen en la sección de anexos.

## Cuadro 2. Resultados de normalidad de los datos

| Factor medido | P value |
|---------------|---------|
| ASM           | > 0.100 |
| Contraste     | > 0.100 |
| Correlación   | > 0.100 |
| IDM           | 0.098   |
| Entropía      | > 0.100 |
| pH            | > 0.100 |
| L*            | > 0.100 |
| a             | > 0.100 |
| b*            | > 0.100 |
| C*            | > 0.100 |
| h*            | > 0.100 |

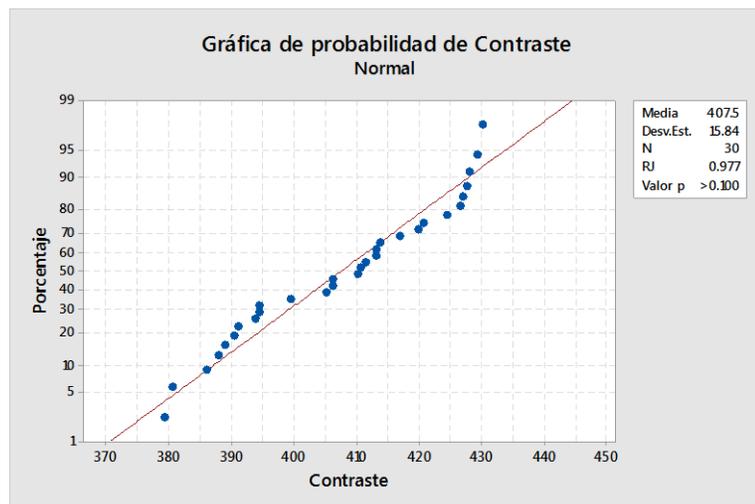


Figura 9. Gráficas de normalidad de contraste.

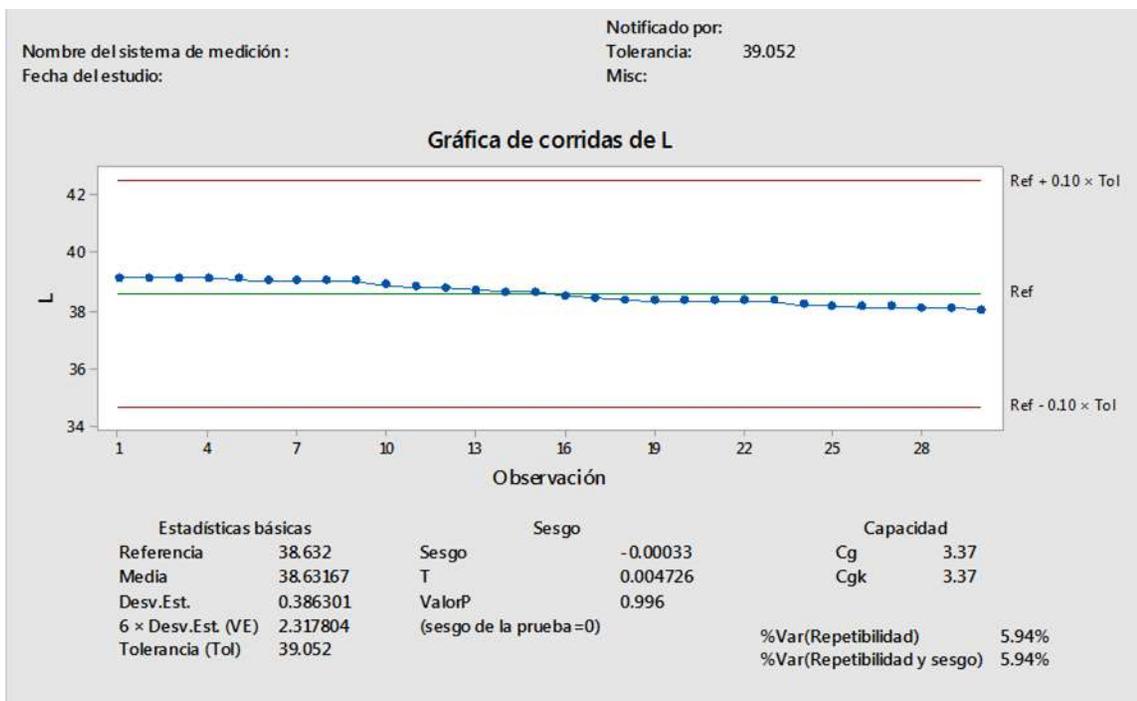
A partir de observar un comportamiento normal en los datos medidos, se procedió a efectuar un análisis de estadística descriptiva. Para el estudio tipo 1 de repetibilidad. Se utilizó el promedio de los datos como el valor de referencia, y el valor correspondiente al cuartil 3, para la tolerancia.

El estudio de repetibilidad se refiere a la variación inherente de los métodos de medición y distingue la capacidad del método de medición, con el uso de instrumentos de medición precisos y calibrados. En los resultados del estudio tipo 1, se observó que los porcentajes de variación se encontraron en el rango de una buena medición, lo cual, de acuerdo a lo reportado, debe estar entre 10 % y 20 % (Montgomery, 2005). De este estudio también se obtuvieron los índices de capacidad  $C_g$  y  $C_{gk}$ , los cuales, deben ser mayores a 1.33 para indicar que la medición es capaz. Los valores de estos indicadores obtenidos fueron igual o mayor a 1.33. Excepto en las mediciones del valor  $b^*$  del color y la variable inversa de la diferencia de momento obtenida en el análisis de imagen; por lo que estas mediciones no presentan una buena repetibilidad. Otro valor importante que se evaluó en los resultados del estudio tipo 1, es el valor de P. El cual, debe ser mayor a 0.05 para indicar que el sistema de medición no presenta un sesgo estadístico significativo. El valor de P obtenido en todas las mediciones fue mayor a 0.05. Los resultados del estudio tipo 1 de repetibilidad se pueden observar en el Cuadro 14 y en la Figura 10, en la cual, se presenta como ejemplo una gráfica obtenida de repetibilidad de uno de los parámetros medidos (valor  $L^*$ ), las gráficas de los otros parámetros medidos se incluyen en anexos.

**Cuadro 3.** Resultados del estudio tipo 1 para los parámetros medidos.

| <b>Factor medido</b> | <b>% Var (Repetibilidad)</b> | <b>Cg</b> | <b>CgK</b> | <b>Valor P</b> |
|----------------------|------------------------------|-----------|------------|----------------|
| L*                   | 5.94                         | 3.37      | 3.37       | 0.996          |
| a*                   | 5.35                         | 3.74      | 2.55       | 0.999          |
| b*                   | 17.34                        | 1.15      | 1.15       | 0.999          |
| C*                   | 5.12                         | 3.91      | 3.91       | 1.000          |
| h*                   | 10.56                        | 1.89      | 1.89       | 0.999          |
| pH                   | 1.86                         | 10.77     | 10.77      | 1.000          |
| CRA                  | 6.29                         | 3.18      | 3.16       | 0.576          |
| ASM                  | *                            | *         | *          | *              |
| Contraste            | 10.45                        | 1.91      | 1.91       | 0.999          |
| Correlacion          | *                            | *         | *          | *              |
| IDM                  | 16.57                        | 1.21      | 1.21       | 0.998          |
| Entropía             | 1.91                         | 10.50     | 10.50      | 1.000          |

\* El sesgo observado es igual a cero, no se puede calcular los parámetros de capacidad



**Figura 10.** Gráfica obtenida del Estudio tipo 1 para el valor de  $L^*$ .

## 5.2 Parámetros fisicoquímicos medidos en la carne de res.

A continuación, se muestran los resultados de la significancia estadística con el ANOVA y la Prueba de Tukey ( $\alpha=0.05$ ) aplicados tanto para los parámetros fisicoquímicos, como para los parámetros de textura de imágenes digitales.

En el Cuadro 15 se muestran los resultados de pH y % CRA. Respecto al pH se puede observar que los valores se encuentran en un rango entre 6.2 y 5.8, valores adecuados para carnes de res con respecto a los días de medición. Es importante mencionar que el pH inicial después del sacrificio (pH 6.0-7.0) irá descendiendo hasta después de 24 h, donde deberá alcanzar su estabilidad en la etapa conocida como post rigor (pH 5.4-5.9) pH's fuera de estos valores indican un proceso de degradación proteolítica en la carne (Ledward, 1970; Hood, 1980).

Los valores de pH obtenidos en las muestras analizadas se encuentran dentro de los valores reportados para carnes comerciales, e indican que no se presentan efectos de proteólisis, incluso después de 9 días de almacenamiento en refrigeración (4°C), después de la obtención de las muestras. Por lo anterior, todas las muestras de carne presentan valores de pH adecuados para considerarse carne fresca durante los días de análisis.

En relación a los valores correspondientes al porcentaje de capacidad de retención de agua, se puede observar que no hay diferencias significativas respecto al tiempo, teniendo un valor promedio de 85.9 % (Cuadro 4). El valor general reportado para CRA es de 75 %, sin embargo, este depende del músculo analizado, ya que es inversamente proporcional al contenido de grasa (Warner, 2014). por lo que se puede decir que la CRA, de las muestras, durante el periodo de evaluación se encuentra dentro de los valores adecuados, y que la carne analizada es baja en grasa (carne magra). Es importante resaltar que, durante los 9 días del experimento no hubo pérdida de agua, por lo que, el valor nutricional de la carne se conserva, debido a que una baja CRA resulta en pérdidas importantes de agua, que acarrearán, proteínas, minerales y vitaminas hidrosolubles; además, estos valores de % CRA pueden favorecer las propiedades sensoriales de la carne como lo son el color y la textura. Por lo anterior, desde el punto de vista industrial, el producto tiene buena eficiencia de rendimiento (Braña et al., 2011).

**Cuadro 4.** Resultados de pH y % CRA de muestras mantenidas en refrigeración (4°C) 9 días.

| Día | pH                       | % CRA                     |
|-----|--------------------------|---------------------------|
| 0   | 6.23 ± 0.03 <sub>a</sub> | 85.81 ± 0.92 <sub>a</sub> |
| 2   | 6.19 ± 0.01 <sub>b</sub> | 85.94 ± 0.92 <sub>b</sub> |
| 4   | 5.95 ± 0.16 <sub>c</sub> | 85.92 ± 0.93 <sub>a</sub> |
| 6   | 5.89 ± 0.09 <sub>d</sub> | 85.98 ± 0.93 <sub>a</sub> |
| 9   | 5.63 ± 0.14 <sub>e</sub> | 85.97 ± 0.89 <sub>a</sub> |

Los datos se expresan como la media ± la desviación estándar. Letras diferentes en la misma columna indican diferencia significativa ( $P \leq 0.05$ ) con la Prueba de Tukey.

Por otro lado, en el Cuadro 5 se muestran los resultados de la medición del color, donde se pueden observar los valores L, a\* y b\* de la escala de Hunter, así como los valores C\* y h\*, durante los días 0, 2, 4, 6 y 9.

El valor L\* se define como la luminosidad y puede tomar valores de 0 (negro) al 100 (blanco) (CIE, 1976). En el Cuadro 5 se pueden apreciar los resultados del valor de L\*, en los cuales, se observan diferencias significativas; en el día 0, las muestras están en un rango de valores entre 36.4 y 39.4, mientras que, en los días 2 y 4 se presentan los valores más altos con un rango entre 40.7 y 42.7. El valor de L\* reportado para carne de res fresca es alrededor de 39.9 (Ripoll et al., 2012), por lo que, se puede decir que en los días 0-6 los valores de luminosidad corresponden con una característica deseada de frescura en la carne, siendo los días 2-4 los que presentan un color más brillante. Por otro lado, los

valores más bajos de luminosidad se encontraron en el día 9, por lo que, en este momento del experimento, la carne se apreciaba sin brillo y fuera del rango de frescura de acuerdo a este parámetro.

El valor  $a^*$  define los colores de tonalidades del verde al rojo (-60 al 60); cuando estos valores son negativos se presenta en las muestras la coloración verde, mientras que, cuando son positivos se observa la coloración roja. En el Cuadro 5 se observan también los resultados del valor  $a^*$ , en los que, se aprecian solo valores positivos, lo que representa a muestras dentro de las tonalidades del color rojo. El valor de  $a^*$  reportado para carne de res fresca es de 15-25 (Ripol et al., 2012), por lo que, dentro del periodo de evaluación todos los valores de  $a^*$  estuvieron dentro de lo reportado, teniendo los valores más altos los días 0-4 lo cual indica un valor de rojo más intenso en estos días, la disminución del valor de  $a^*$  en el día 9 respecto a los días anteriores, puede ser un indicador de pérdida de frescura.

El valor  $b^*$  es conocido como el índice amarillo y varía entre -60 (azul) y el 60 (amarillo). La carne fresca siempre deberá reportar valores positivos de  $b^*$ . En los resultados del valor  $b^*$  se observó que el valor positivo incrementó los días 2 y 4 y posteriormente descendió los días 6 y 9 (Cuadro 5).

El valor  $C^*$  (croma) y  $h^*$  (tono) se calculan a partir de los valores de  $a^*$  y  $b^*$  de la siguiente manera:  $C^* = (a^{*2} + b^{*2})^{0,5}$ , mientras que  $h^* = b^*/a^*$ . El croma está determinado por la cantidad de pigmento del músculo (mioglobina) y varía de rosa pálido a rojo intenso. El tono, indica el estado químico de la mioglobina.

En el Cuadro 5 se puede observar que, el valor  $C^*$  presentó los valores más altos significativos los días 0-4 del análisis, lo que indicaría que la carne presenta una tonalidad rojo intenso esos días (y brillante de acuerdo a su valor obtenido de  $L^*$ ), relacionado con carne fresca, ya que se ha reportado que los valores

deseados para C\* en carne fresca de res son alrededor de 26. Además, de acuerdo a estos resultados, a partir del día 6, la carne podría presentar un deterioro significativo.

Por otro lado, para el valor de h\*, que indica el tono de la carne, se han reportado valores alrededor de 15.5 para carne fresca (Ripol et al., 2012). En el Cuadro 5 se observa que h\*, en todos los días del análisis, tuvo un comportamiento significativo similar al valor de C\*. Lo que puede indicar que, para ambos parámetros en el día 9 la carne presenta un deterioro significativo que comienza a observarse desde el día 6.

**Cuadro 5.** Resultados de color de muestras mantenidas en refrigeración (4°C) 9 días.

| Día | L*                        | a*                       | b*                      | C*                       | h*                       |
|-----|---------------------------|--------------------------|-------------------------|--------------------------|--------------------------|
| 0   | 37.94 ± 1.5 <sub>c</sub>  | 18.97 ± 0.8 <sub>b</sub> | 5.25 ± 1.6 <sub>b</sub> | 19.73 ± 1.2 <sub>b</sub> | 15.3 ± 3.4 <sub>b</sub>  |
| 2   | 41.84 ± 0.9 <sub>a</sub>  | 24.32 ± 1.1 <sub>a</sub> | 9.66 ± 0.7 <sub>a</sub> | 26.17 ± 1.3 <sub>a</sub> | 21.6 ± 0.6 <sub>a</sub>  |
| 4   | 41.85 ± 0.9 <sub>a</sub>  | 24.31 ± 1.1 <sub>a</sub> | 9.65 ± 0.7 <sub>a</sub> | 26.16 ± 1.3 <sub>a</sub> | 21.62 ± 0.6 <sub>a</sub> |
| 6   | 39.73 ± 1.3 <sub>b</sub>  | 17.25 ± 0.6 <sub>c</sub> | 4.98 ± 0.8 <sub>b</sub> | 17.96 ± 1.0 <sub>c</sub> | 16.01 ± 1.8 <sub>b</sub> |
| 9   | 37.23 ± 1.05 <sub>d</sub> | 16.14 ± 1.1 <sub>d</sub> | 3.05 ± 0.6 <sub>c</sub> | 16.66 ± 1.3 <sub>d</sub> | 10.66 ± 2.4 <sub>c</sub> |

Los datos se expresan como la media ± la desviación estándar. Letras diferentes en la misma columna indican diferencia significativa (P≤0.05) con la Prueba de Tukey.

Lo observado en estas muestras de carne durante el experimento es el comportamiento normal del material biológico ante el paso del tiempo, ya que al inicio, cuando la carne se expone al aire, su mioglobina se une al oxígeno atmosférico adquiriendo un color rojo intenso (oximioglobina) (Livingston & Brown, 1981), lo que se observa en los primeros días (0-4), sin embargo, cuando la carne se va estropeando por el paso del tiempo, el pigmento pierde la capacidad de unirse al oxígeno y el color rojo se va poniendo pardo hasta llegar a una coloración

café oscuro (metamioglobina) (Fausman & Cassens, 1990), lo que se comienza a observar desde los días 6-9.

Snyder (1965) observó que en carne de res valores altos de  $C^*$  y  $a^*$  indicaban alta concentración de oximioglobina ( $MbO_2$ ) en la superficie, mientras que, valores bajos de  $C^*$  y  $a^*$  señalaba una alta concentración de Metabioglobina (MetMb). La  $MbO_2$  otorga la pigmentación rojo cereza (Livingston & Brown, 1981). La MetMb es incapaz de unirse al oxígeno por lo que es inactiva fisiológicamente (Fausman & Cassens, 1990) y otorga un color café, y los consumidores lo asocian con la falta de frescura (Hood & Riordan, 1973).

Se pudo observar que las muestras de carne en los días de análisis 2 y 4, presentan valores altos de  $L^*$ ,  $a^*$  y  $b^*$ ,  $C^*$  y  $h^*$ , lo cual es un indicativo de ser carnes que tiene un color rojo intenso y brillante, parámetros que sugieren una adecuada calidad. Mac Dougall (1985) uso la saturación croma ( $C^*$ ) para definir y determinar la vida media de la carne fresca de bovino.

En la formación de MetMb, la saturación ( $C^*$ ) disminuye conforme el tono cambia de rojo brillante a café, y desde aquí, a café verdoso, que fue lo que se observó en las muestras analizadas el día 9, un resultado significativamente menor a comparación de los otros días de análisis.

Según un estudio efectuado por Carpenter et al. (2001) el color de la carne de res es suficiente para que el consumidor la seleccione y compre. En la mente del consumidor promedio, en cuanto a la compra de carne roja, el color es sinónimo de frescura (Renerre & Labas, 1987).

Se ha reportado que, la evolución de las variables de color a través del tiempo no es siempre lineal por lo que existe alguna variación en los valores reportados, (Alberti et al., 2016). Por lo cual, los parámetros que se toman como

referentes de frescura, de forma común y sobre todo las valoraciones subjetivas, no siempre podrían sustentar que se trata de una carne de buena calidad en términos de su frescura.

Lo anterior, justifica la pertinencia de buscar y proponer métodos adicionales o complementarios que permitan definir las características de la carne de forma acertada.

### **5. 3 Análisis de textura de las imágenes de las muestras de carne de res.**

En el Cuadro 6 se muestran los resultados de textura de las imágenes digitales de las muestras de carne. Las variables obtenidas fueron: contraste, entropía, segundo momento angular (ASM por sus siglas en inglés), inversa de la diferencia de momento (IDM por sus siglas en inglés) y correlación.

ASM es un parámetro que mide la uniformidad de una imagen, las muestras del día 0 presentaron un valor significativamente mayor, y posteriormente, este valor fue disminuyendo con el tiempo, hasta encontrar en el día 9 el menor valor; por lo cual, las muestras al inicio tenían una homogeneidad mayor.

Respecto a los valores del contraste, se puede observar que estos van incrementando significativamente conforme avanza el tiempo, por lo que, el mayor valor de contraste se encuentra el día 9. Este comportamiento, solo fue diferente el día 6 de la medición.

La variable de correlación entre píxeles significa que hay una relación lineal predecible entre dos píxeles vecinos dentro de una ventana. Como se puede observar los valores para este parámetro disminuyen significativamente con respecto al tiempo, encontrando el valor más bajo el día 9. Es importante destacar que, todos los valores obtenidos de correlación fueron bajos, lo que significa una

baja predicción de la relación de los píxeles vecinos de las imágenes digitales de las muestras de carne.

Adicionalmente IDM es una medida de la homogeneidad de la imagen, similar a ASM. Se puede observar que los valores de este parámetro se mantuvieron similares los días 0, 2, 4 y 6 para disminuir significativamente el último día de medición. Por lo cual, podría relacionarse la disminución de homogeneidad de las imágenes con la pérdida de frescura de las muestras de carne de esta investigación. Adicionalmente, este parámetro está inversamente relacionado con el contraste. Si el valor de IDM es pequeño usualmente el contraste es alto, lo que se puede comprobar en los resultados obtenidos en el día 9 de análisis.

Por otro lado, la variable entropía tuvo para casi todos los días de experimentación un incremento significativo en sus valores conforme fue avanzando el periodo de refrigeración, presentando el valor mayor el día 9. De las características evaluadas, la entropía es un valor que representa una medida de la heterogeneidad de las imágenes, mide el desorden o aleatoriedad de las imágenes, puede ser usado para caracterizar la textura de la imagen y es un indicativo de complejidad dentro de la imagen. Además, es un parámetro opuesto a ASM. El aumento del resultado de entropía en las imágenes es indicativo de mayor complejidad en las imágenes de las muestras lo que podría estar dado como resultado de la pérdida de frescura de la carne.

**Cuadro 6.** Resultados de textura a partir de matriz de co-ocurrencia muestras mantenidas en refrigeración (4°C) 9 días.

| Día | ASM                         | Contraste                  | Correlación                 | IDM                         | Entropía                   |
|-----|-----------------------------|----------------------------|-----------------------------|-----------------------------|----------------------------|
| 0   | 0.0135 ± 0.006 <sub>a</sub> | 6.7473 ± 1.3 <sub>b</sub>  | 0.0199 ± 0.019 <sub>a</sub> | 0.6443 ± 0.04 <sub>a</sub>  | 4.8448 ± 0.5 <sub>d</sub>  |
| 2   | 0.0100 ± 0.004 <sub>b</sub> | 9.2367 ± 2.8 <sub>a</sub>  | 0.0128 ± 0.007 <sub>b</sub> | 0.6018 ± 0.03 <sub>ab</sub> | 5.1483 ± 0.4 <sub>b</sub>  |
| 4   | 0.0109 ± 0.002 <sub>b</sub> | 9.0910 ± 1.8 <sub>a</sub>  | 0.0144 ± 0.004 <sub>b</sub> | 0.6233 ± 0.03 <sub>ab</sub> | 4.9582 ± 0.2 <sub>cd</sub> |
| 6   | 0.0076 ± 0.003 <sub>c</sub> | 7.7868 ± 1.5 <sub>c</sub>  | 0.0115 ± 0.006 <sub>c</sub> | 0.6236 ± 0.02 <sub>c</sub>  | 5.0804 ± 0.3 <sub>bc</sub> |
| 9   | 0.0076 ± 0.003 <sub>c</sub> | 12.9654 ± 2.6 <sub>d</sub> | 0.0074 ± 0.074 <sub>c</sub> | 0.4528 ± 0.12 <sub>c</sub>  | 5.8374 ± 0.7 <sub>a</sub>  |

Los datos se expresan como la media ± la desviación estándar. Letras diferentes en la misma columna indican diferencia significativa ( $P \leq 0.05$ ) con la Prueba de Tukey. ASM, segundo momento angular, IDM, Inversa del momento angular.

#### 5.4 Correlación de parámetros fisicoquímicos con los parámetros de textura de las imágenes.

El análisis de correlación de Pearson entre las características de textura de las imágenes digitales y los parámetros fisicoquímicos se hizo con el fin de conocer la relación lineal entre cada par de variables. En el Cuadro 18 se muestran los resultados de correlaciones ( $P \leq 0.05$  y  $P \leq 0.01$ ).

De acuerdo con los resultados para valores de  $P \leq 0.05$ , el pH, y los valores del parámetro del color  $a^*$ ,  $b^*$  y  $h^*$  están correlacionados con los parámetros de las imágenes ASM, correlación e IDM, de forma positiva, mientras que, con el contraste y la entropía se correlacionan de forma negativa.

Por otro lado, el valor de  $C^*$  presentó correlación positiva con los parámetros de las imágenes ASM, contraste e IDM, mientras que, presentó correlación negativa con los parámetros correlación y entropía.

En cuanto al porcentaje de CRA y  $L^*$  no se observó correlación con los parámetros de textura medidos.

Se pudo notar que, todas las variables fisicoquímicas medidas tienen una correlación lineal negativa con el parámetro de entropía, es decir que, cuando esta última aumenta las variables fisicoquímicas disminuyen.

Los resultados de correlación de Pearson con  $p=0.01$ , mostraron una correlación mayor para las variables  $a^*$ ,  $C^*$  y  $L^*$  con las variables de textura IDM y ASM. Las variables de pH, CRA y  $b^*$  presentaron una correlación prácticamente nula con las variables de textura. En cuanto a  $h^*$  no se observó diferencia en la relación con ambos valores de probabilidad utilizados para la prueba de correlación lineal de Pearson.

**Cuadro 7.** Resultados del análisis de correlación de variables fisicoquímicas y de textura a partir de imágenes digitales.

|             | ASM      | Contraste | Correlación | IDM      | Entropía | pH     | L*       | a*     | b* | C* | h* | CRA |
|-------------|----------|-----------|-------------|----------|----------|--------|----------|--------|----|----|----|-----|
| ASM         | 1        |           |             |          |          |        |          |        |    |    |    |     |
| Contraste   | - 0.523* | 1         |             |          |          |        |          |        |    |    |    |     |
|             | - 0.777* |           |             |          |          |        |          |        |    |    |    |     |
| Correlación | - 0.995* | - 0.519*  | 1           |          |          |        |          |        |    |    |    |     |
|             | - 0.940* | - 0.743*  |             |          |          |        |          |        |    |    |    |     |
| IDM         | 0.622*   | - 0.612*  | 0.517*      | 1        |          |        |          |        |    |    |    |     |
|             | 0.803*   | - 0.849*  | 0.725*      |          |          |        |          |        |    |    |    |     |
| Entropía    | - 0.833* | 0.606*    | - 0.749*    | - 0.891* | 1        |        |          |        |    |    |    |     |
|             | - 0.995* | 0.762*    | 0.871*      | 0.841*   |          |        |          |        |    |    |    |     |
| pH          | 0.332*   | - 0.458*  | 0.355*      | 0.535*   | - 0.453* | 1      |          |        |    |    |    |     |
|             | - 0.005* | 0.068*    | 0.081*      | 0.032*   | 0.008*   |        |          |        |    |    |    |     |
| L           | 0.034*   | - 0.148*  | 0.063*      | 0.277*   | - 0.215* | 0.294* | 1        |        |    |    |    |     |
|             | 0.139*   | - 0.137*  | 0.154*      | 0.050*   | 0.124*   | 0.005* |          |        |    |    |    |     |
| a           | 0.151*   | - 0.178*  | 0.187*      | 0.381*   | - 0.343* | 0.504  | 0.764    | 1      |    |    |    |     |
|             | 0.282*   | - 0.241*  | 0.275*      | 0.267*   | 0.309*   | 0.099* | - 0.013* |        |    |    |    |     |
| b           | 0.107*   | - 0.190*  | 0.145*      | 0.384*   | - 0.323* | 0.467* | 0.808*   | 0.963* | 1  |    |    |     |
|             | - 0.021* | 0.048*    | 0.016*      | 0.061*   | - 0.029* | 0.066* | 0.095*   | 0.713* |    |    |    |     |

|     |                       |                       |                       |                       |                            |                  |                  |                  |                  |                  |                  |   |
|-----|-----------------------|-----------------------|-----------------------|-----------------------|----------------------------|------------------|------------------|------------------|------------------|------------------|------------------|---|
| C   | 0.127*<br>0.240*      | 0.167*<br>-<br>0.202* | -<br>0.168*<br>0.235* | 0.344*<br>0.221*      | -<br>0.308*<br>-<br>0.273* | 0.486*<br>0.097* | 0.780*<br>0.008* | 0.997*<br>0.992* | 0.970*<br>0.795* | 1                |                  |   |
| h   | 0.110*<br>-<br>0.158* | -<br>0.264*<br>0.180* | 0.133*<br>-<br>0.149* | 0.440*<br>-<br>0.202* | -<br>0.346*<br>0.108*      | 0.466*<br>0.038* | 0.754*<br>0.132* | 0.829*<br>0.446* | 0.923*<br>0.945* | 0.839*<br>0.554* | 1                |   |
| CRA | -0.030*<br>0.008**    | -<br>0.006*           | -<br>0.003*<br>0.003* | -<br>0.017*<br>0.035* | -0-<br>0.006*              | -0.07*<br>0.029* | 0.060*<br>0.132* | -0.01*<br>0.010* | 0.01*<br>0.082*  | -0.00*<br>0.023* | 0.01*<br>0.105** | 1 |
|     |                       | 0.0<br>56*            |                       |                       | -<br>0.038*                |                  |                  |                  |                  |                  |                  |   |

\* La correlación es significativa con un valor de  $P \leq 0.05$

\*\*La correlación es significativa con un valor de  $P \leq 0.01$

Macini y Hunt (2005) señalaron que  $C^*$  es un buen indicador de la estabilidad de la carne. Además, se ha reportado que el tono ( $h^*$ ) está correlacionado negativamente con el rojo ( $a^*$ ) y positivamente con el amarillo ( $b^*$ ) y a su vez  $C^*$  está relacionado positivamente con el rojo ( $a^*$ ) y negativamente con el tono ( $h^*$ ). En este estudio, la relación entre los parámetros de color  $L^*$ ,  $a^*$ ,  $b^*$ ,  $C^*$  y  $h^*$  es directa y positiva, es decir cuando una variable aumenta también los hace la otra. El valor  $C^*$  de la carne y la cantidad de rojo son en la práctica equivalentes, mientras que el tono es más impredecible ya que está influenciado por el rojo y el amarillo, que actúan en sentidos opuestos (Albertí et al., 2016)

### 5.5. Análisis de regresión múltiple nominal para la predicción de la frescura de la carne de res

A partir de observar las correlaciones entre las variables de textura obtenidas de imágenes digitales con los parámetros fisicoquímicos, se llevó a cabo el análisis de regresión múltiple nominal para crear un modelo de predicción

de frescura de la carne, determinado por los días de refrigeración de las muestras y las variables analizadas.

Los resultados del modelo se presentan en los Cuadros 8 y 9. El coeficiente de determinación del modelo fue de 0.95, lo que significa que, las variables fisicoquímicas y de textura medidas, permiten explicar el 95 % de la variación de la frescura de la carne, indicado por el tiempo de almacenamiento. El error de predicción del modelo es 0.67 %, lo que significa que la exactitud es buena, en esta investigación.

**Cuadro 8.** Resultados del modelo completo

| <b>Detalles del modelo</b> |      |
|----------------------------|------|
| R <sup>2</sup>             | 0.95 |
| % error del modelo         | 0.67 |

Los efectos de cada variable sobre la predicción del día de almacenamiento se muestran el Cuadro 20. Se observa que las variables significativas para la predicción del día de almacenamiento son IDM, ASM, C\*, b\*, a\* y h\*. Las variables L\*, correlación, contraste, entropía, pH y % CRA no son predictores significativos para el día de almacenamiento, en este estudio.

**Cuadro 9.** Resumen de efectos en el ajuste logístico nominal para la predicción del día de refrigeración.

| <b>Variable</b> | <b>Valor P<sup>1</sup></b> |
|-----------------|----------------------------|
| IDM             | 0.00000                    |
| ASM             | 0.00000                    |
| C*              | 0.00000                    |
| b*              | 0.00000                    |
| h*              | 0.00000                    |
| a*              | 0.00000                    |
| CRA             | 0.89306                    |
| pH              | 1.00000                    |
| Correlación     | 1.00000                    |
| Entropía        | 1.00000                    |
| Contraste       | 1.00000                    |
| L*              | 1.00000                    |

(\*Nivel de significancia 0.05)

Por otro lado, en el Cuadro 10 se presentan los resultados de la matriz de confusión. En donde se verifica que el modelo propuesto tuvo un 100% de exactitud de predicción para los días 0, 6 y 9 de almacenamiento.

Sin embargo, aunque la predicción de los días 2 y 4 presentaron una exactitud de 97.8% y 98.9% respectivamente aún se tiene un buen nivel de predicción.

**Cuadro 10.** Resultados de la matriz de confusión del modelo

| <b>Real</b>  | <b>Predicción</b> |              |              |              |              |
|--------------|-------------------|--------------|--------------|--------------|--------------|
|              | <b>Día 0</b>      | <b>Día 2</b> | <b>Día 4</b> | <b>Día 6</b> | <b>Día 9</b> |
| <b>Día 0</b> | 90                | 0            | 0            | 0            | 0            |
| <b>Día 2</b> | 0                 | 88           | 2            | 0            | 0            |

|              |                      |              |              |              |              |
|--------------|----------------------|--------------|--------------|--------------|--------------|
| <b>Día 4</b> | 0                    | 1            | 89           | 0            | 0            |
| <b>Día 6</b> | 0                    | 0            | 0            | 90           | 0            |
| <b>Día 9</b> | 0                    | 0            | 0            | 0            | 90           |
| <b>Real</b>  | <b>Tasa Predicha</b> |              |              |              |              |
| <b>Día</b>   | <b>Día 0</b>         | <b>Día 2</b> | <b>Día 4</b> | <b>Día 6</b> | <b>Día 9</b> |
| <b>Día 0</b> | 100%                 | 0%           | 0%           | 0%           | 0%           |
| <b>Día 2</b> | 0%                   | 97.8%        | 2.2%         | 0%           | 0%           |
| <b>Día 4</b> | 0%                   | 1.1%         | 98.9%        | 0%           | 0%           |
| <b>Día 6</b> | 0%                   | 0%           | 05           | 100%         | 0%           |
| <b>Día 9</b> | 0%                   | 0%           | 0%           | 0%           | 100%         |

## VI. CONCLUSIONES

Los resultados de repetibilidad mostraron que en el estudio se obtuvieron mediciones capaces y repetibles, por lo tanto, los resultados son confiables en este sentido.

En este estudio, la relación más fuerte observada entre los parámetros fisicoquímicos y de textura a partir de imágenes, fue entre las variables  $a^*$ ,  $C^*$ , IDM y ASM; de acuerdo a los resultados de correlación obtenidos. La construcción del modelo de predicción utilizando un ajuste logístico nominal, permitió estimar la frescura de las muestras de carne de res tipo bola, con respecto al día de almacenamiento.

Las variables de color  $a^*$ ,  $b^*$ ,  $C^*$  y  $h^*$  en conjunto con las variables de textura de imágenes ASM e IDM son los parámetros significativos en la estimación de la frescura de la carne en este estudio. Por lo que, la metodología propuesta en este proyecto podría ser una alternativa para la evaluación de calidad de carne en términos de su frescura a través de la obtención de parámetros de textura de imágenes digitales y de color, en conjunto.

Con las variables y parámetros evaluados en este estudio, específicamente en la carne de res del músculo bola, se observó que la variable de color no siempre podría ser un predictor de frescura adecuado; por lo que, se sugiere evaluar, además, parámetros de textura de imágenes que podrían mejorar la predicción.

El estudio muestra un posible potencial del análisis de imagen en combinación con el análisis de color, para la predicción de frescura de la carne de res.

## VII. REFERENCIAS

Acebron, L., & Dopico, D. (2000). The importance of intrinsic and extrinsic cues to expected and experienced quality: An empirical application to beef. *Food Quality and Preference*, 11, 229–238.

Ahmed, I., Lin, H., Zou, L., Brody, A. L., Li, Z., Qazi, I. M., ... & Lv, L. (2017). A comprehensive review on the application of active packaging technologies to muscle foods. *Food control*, 82, 163-178.

Alamprese, C., Fongaro, L., & Casiraghi, E. (2016). Effect of fresh pork meat conditioning on quality characteristics of salami. *Meat science*, 119, 193-198.

Alarcon-Rojo, A. D., Janacua, H., Rodriguez, J. C., Paniwnyk, L., & Mason, T. J. (2015). Power ultrasound in meat processing. *Meat science*, 107, 86-93.

Albertí, P., Ripoll, G., Albertí, C., & Panea, B. (2016). Clasificación objetiva del color de la carne de las denominaciones de venta de vacuno. *Eurocarne: La revista internacional del sector cárnico*, 244, 131-142.

AMSA. Guidelines for meat color evaluation American Meat Science. Chicago IL: Association National Live Stock and Meat Board.1992.

AOAC. Official methods of analysis. Official Method 991.36, Fat (Crude) in Meat and Meat Products. 17th ed. Maryland, USA: Association of Official Analytical Chemists. 2000.

Asmara, R. A., Hasanah, Q., Rahutomo, F., Rohadi, E., Siradjuddin, I., Ronilaya, F., & Handayani, A. N. (2018, June). Chicken Meat Freshness Identification using Colors and Textures Feature. In 2018 Joint 7th International Conference on Informatics, Electronics & Vision (ICIEV) and 2018 2nd International Conference on Imaging, Vision & Pattern Recognition (icIVPR) (pp. 93-98). IEEE.

Arsalane, A., El Barbri, N., Tabyaoui, A., Klilou, A., Rhofir, K., & Halimi, A. (2018). An embedded system based on DSP platform and PCA-SVM algorithms for rapid beef meat freshness prediction and identification. *Computers and Electronics in Agriculture*, 152, 385-392.

Arsalane, A., Klilou, A., El Barbri, N., & Tabyaoui, A. (2020, April). Artificial vision and embedded systems as alternative tools for evaluating beef meat freshness. In 2020 IEEE 6th International Conference on Optimization and Applications (ICOA) (pp. 1-6). IEEE.

Ávila, M. M., Durán, M. L., Caballero, D., Antequera, T., Palacios-Pérez, T., Cernadas, E., & Fernández-Delgado, M. (2019). Magnetic Resonance Imaging, texture analysis and regression techniques to non-destructively predict the quality

characteristics of meat pieces. *Engineering Applications of Artificial Intelligence*, 82, 110-125.

Barbin, D., Elmasry, G., Sun, D. W., & Allen, P. (2012). Near-infrared hyperspectral imaging for grading and classification of pork. *Meat Science*, 90(1), 259-268.

Basset, O., Buquet, B., Abouelkaram, S., Delachartre, P., & Culioli, J. (2000). Application of texture image analysis for the classification of bovine meat. *Food Chemistry*, 69(4), 437-445.

Becker, T., Benner, E., & Glitsch, K. (2000). Consumer perception of fresh meat quality in Germany. *British Food Journal*, 102(3), 246-266.

Braña D., Vélez A., Espinosa J., Moctezuma G., Pérez M., Joalpa J., Martínez G., Esparza A. (2012). *Calidad en puntos de venta de Carne*. Centro Nacional de Investigación Disciplinaria en Fisiología y Mejoramiento Animal. INIFAP. Folleto técnico No. 22. ISBN: 978-607-425-954-4.

Brewer, M. S. (2012). Reducing the fat content in ground beef without sacrificing quality: A review. *Meat Science*, 91(4), 385-395.

Caballero, D., Antequera, T., Caro, A., Ávila, M. D. M., G Rodríguez, P., & Perez-Palacios, T. (2016). Non-destructive analysis of sensory traits of dry-cured loins by MRI-computer vision techniques and data mining. *Journal of the Science of Food and Agriculture*, 97(9), 2942-2952.

Castañeda, D., Lozano, J. M., & Suárez, H. (2016). Microstructural changes and the effect on myofibril proteins in yamu (*Brycon amazonicus*) fish meat during cold storage. *Agronomía Colombiana*, 34(3), 403-414.

Cernadas, E., Durán, M. L., & Antequera, T. (2002). Recognizing marbling in dry-cured Iberian ham by multiscale analysis. *Pattern Recognition Letters*, 23(11), 1311-1321.

Chao, K.L., Yang, C.C., Kim, M.S.,(2010). Spectral line-scan imaging system for high-speed non-destructive wholesomeness inspection of broilers. *Trend. Food Sci. Technol.* 21, 129-137.

Chen, Q., Zhang, Y., Guo, Y., Cheng, Y., Qian, H., Yao, W., & Ozaki, Y. (2020). Non-destructive prediction of texture of frozen/thaw raw beef by Raman spectroscopy. *Journal of Food Engineering*, 266, 109693.

Cheng, W., Cheng, J. H., Sun, D. W., & Pu, H. (2015). Marbling analysis for evaluating meat quality: Methods and techniques. *Comprehensive Reviews in Food Science and Food Safety*, 14(5), 523-535.

Cheng, J. H., Nicolai, B., & Sun, D. W. (2017). Hyperspectral imaging with multivariate analysis for technological parameters prediction and classification of muscle foods: A review. *Meat science*, 123, 182-191.

Cho, S. H., Kim, J., Park, B. Y., Seong, P. N., Kang, G. H., Kim, J. H., Jung, S. G., Im, S. K., & Kim, D. H. (2010). Assessment of meat quality properties and development of a palatability prediction model for Korean Hanwoo steer beef. *Meat Science*, 86, 236–242.

Christiansen, A. N., Carstensen, J. M., Møller, F., & Nielsen, A. A. (2012). Monitoring the change in colour of meat: A comparison of traditional and kernel-based orthogonal transformations. *Journal of spectral Imaging*, 3(1).

Dalvi-Isfahan, M., Hamdami, N., & Le-Bail, A. (2016). Effect of freezing under electrostatic field on the quality of lamb meat. *Innovative food science & emerging technologies*, 37, 68-73.

Damez, J. L., & Clerjon, S. (2008). Meat quality assessment using biophysical methods related to meat structure. *Meat science*, 80(1), 132-149.

Damez, J. L., & Clerjon, S. (2013). Quantifying and predicting meat and meat products quality attributes using electromagnetic waves: An overview. *Meat science*, 95(4), 879-896.

Dissing, B. S., Papadopoulou, O. S., Tassou, C., Ersbøll, B. K., Carstensen, J. M., Panagou, E. Z., & Nychas, G. J. (2013). Using multispectral imaging for spoilage detection of pork meat. *Food and Bioprocess Technology*, 6(9), 2268-2279.

Domínguez, R., Purriños, L., Pérez-Santaescolástica, C., Pateiro, M., Barba, F. J., Tomasevic, I., ... & Lorenzo, J. M. (2019). Characterization of Volatile Compounds of Dry-Cured Meat Products Using HS-SPME-GC/MS Technique. *Food Analytical Methods*, 12(6), 1263-1284.

Eaton, J. (1998-2021). GNU OCTAVE.  
<https://www.gnu.org/software/octave/about.html>

EIMasry, G., Barbin, D. F., Sun, D. W., & Allen, P. (2012). Meat quality evaluation by hyperspectral imaging technique: an overview. *Critical Reviews in Food Science and Nutrition*, 52(8), 689-711.

EIMasry, G., & Nakauchi, S. (2016). Prediction of meat spectral patterns based on optical properties and concentrations of the major constituents. *Food science & nutrition*, 4(2), 269-283.

Font-i-Furnols, M., Candek-Potokar, M., Maltin, C., & Prevolnik Povše, M. (2015). A handbook of reference methods for meat quality assessment. European Cooperation in Science and Technology (COST): Brussels, Belgium.

Gatellier, P., Hamelin, C., Durand, Y., Rennerre, M. (2001). Effect of dietary vitamin E supplementation on colour stability and lipid oxidation of air- and modified atmosphere-packaged beef. *Meat Science*, 59 (2), 133-140.

Giaretta, E., Mordenti, A. L., Canestrari, G., Brogna, N., Palmonari, A., & Formigoni, A. (2018). Assessment of muscle *Longissimus thoracis et lumborum* marbling by image analysis and relationships between meat quality parameters. *PloS one*, 13(8), e0202535.

Gonzalez R. C., Woods R. E., (2008). *Digital Image Processing*, 3rd edition. Pearson

Ghazali, R., Abdul Rahim, H., Shikh Maidin, M. and Sahlan, S. (2013). Prediction of Texture of Raw Poultry Meat by Visible and Near-Infrared. *Journal of Technology*. 64: 59- 62.

Ghazali, R., & Rahim, H. A. (2016). First derivative prediction of raw broiler shear force using visible short wave near infrared spectroscopy. *Jurnal Teknologi*, 78(7-4).

Gravelle, A. J., Marangoni, A. G., & Barbut, S. (2016). Insight into the mechanism of myofibrillar protein gel stability: Influencing texture and microstructure using a model hydrophilic filler. *Food hydrocolloids*, 60, 415-424.

Hoban, J. M., Hopkins, D. L., Kirby, N., Collins, D., Dunshea, F. R., Kerr, M. G., & Ponnampalam, E. N. (2016). Application of small angle X-ray scattering synchrotron technology for measuring ovine meat quality. *Meat science*, 117, 122-129.

Holman, B. W., Coombs, C. E., Morris, S., Kerr, M. J., & Hopkins, D. L. (2017). Effect of long term chilled (up to 5 weeks) then frozen (up to 12 months) storage at two different sub-zero holding temperatures on beef: 1. Meat quality and microbial loads. *Meat science*, 133, 133-142.

Honikel KO. Reference methods for the assessment of physical characteristics of meat. *Meat Sci* 1998; 49:447-457.

Hussain, A., Pu, H., & Sun, D. W. (2018). Innovative nondestructive imaging techniques for ripening and maturity of fruits—a review of recent applications. *Trends in food science & technology*, 72, 144-152.

Jackman, P., Sun, D.-W., Du, C.-J., Allen, P., Downey, G., 2008. Prediction of beef eating quality from colour, marbling and wavelet texture features. *Meat Science* 80 (4), 1273–1281.

Jackman, P., Sun, D.-W., Du, C.-J., Allen, P., 2009. Prediction of beef eating qualities from colour, marbling and wavelet surface texture features using homogenous carcass treatment. *Pattern Recognition* 42 (5), 751–763.

Jensen, J.R. (1996) Introductory Digital Image Processing: A remote sensing perspective. 2nd edition, Prentice Hall, Inc, Upper Saddle River, NJ

Jha, S.N., Garg, R., 2010. Non-destructive prediction of quality of intact apple using near infrared spectroscopy. *J. Food Sci. Technol.* 47 (2), 207\_213.

Jiang, H., Yoon, S. C., Zhuang, H., Wang, W., Lawrence, K. C., & Yang, Y. (2018). Tenderness classification of fresh broiler breast fillets using visible and near-infrared hyperspectral imaging. *Meat science*, 139, 82-90.

Jira, W., Sadeghi-Mehr, A., Brüggemann, D. A., & Schwägele, F. (2017). Production of dry-cured formed ham with different concentrations of microbial transglutaminase: Mass spectrometric analysis and sensory evaluation. *Meat science*, 129, 81-87.

Joo S.T., Kim G.D., Hwang Y.H., Ryu Y.C. (2013). Control of fresh meat quality through manipulation of muscle fiber characteristics. *Meat Science*. 95 (2013) 828–836

Jung, E. Y., Hwang, Y. H., & Joo, S. T. (2016). Muscle profiling to improve the value of retail meat cuts. *Meat science*, 120, 47-53.

Kamruzzaman, M., Barbin, D., ElMasry, G., Sun, D. W., & Allen, P. (2012). Potential of hyperspectral imaging and pattern recognition for categorization and

authentication of red meat. *Innovative Food Science & Emerging Technologies*, 16, 316-325.

Kamruzzaman, M., Makino, Y., & Oshita, S. (2016). Hyperspectral imaging for real-time monitoring of water holding capacity in red meat. *LWT-Food Science and Technology*, 66, 685-691.

Kandpal, L.M., Lee, H., Kim, M.S., Mo, C., Cho, B.K., (2013). Hyperspectral reflectance imaging technique for visualization of moisture distribution in cooked chicken breast. *Sensors* 13 (10), 13289\_13300.

Kandpal, L. M., Lee, J., Bae, J., Lohumi, S., & Cho, B. K. (2019). Development of a Low-Cost Multi-Waveband LED Illumination Imaging Technique for Rapid Evaluation of Fresh Meat Quality. *Applied Sciences*, 9(5), 912.

Kim, Y. H. B., & Jang, A. (2014). In M. Devine, & C. Dikeman (Eds.), *Encyclopedia of meat sciences* (pp. 543–549). (Vol. 1). Waltham, MA: Academic Press.

Lebedova N., Stupka R., Citek J., Okrouhlá M., and Zadinova K.(2019). Effect of feed restriction on muscle fibre characteristics and meat quality traits in pigs. *Agronomy Research*. 17 (1), 176-185.

Lee, S. H., Joo, S. T., & Ryu, Y. C. (2010). Skeletal muscle fiber type and myofibrillar proteins in relation to meat quality. *Meat Science*, 86, 166–170.

Lillford, P. (2018). Texture and breakdown in the mouth: An industrial research approach. *Journal of texture studies*, 49(2), 213-218.

Liu, R., Xing, L., Fu, Q., Zhou, G. H., & Zhang, W. G. (2016). A review of antioxidant peptides derived from meat muscle and by products. *Antioxidants*, 5(3), 32.

Liu, Z., Zhong, Y., Hu, Y., Yuan, L., Luo, R., Chen, D., ... & Li, Y. (2019). Fluorescence strategy for sensitive detection of adenosine triphosphate in terms of evaluating meat freshness. *Food chemistry*, 270, 573-578.

Lohumi, S., Lee, S., Lee, H., Kim, M. S., Lee, W. H., & Cho, B. K. (2016). Application of hyperspectral imaging for characterization of intramuscular fat distribution in beef. *Infrared Physics & Technology*, 74, 1-10.

Ma, J., Sun, D. W., Qu, J. H., & Pu, H. (2017). Prediction of textural changes in grass carp fillets as affected by vacuum freeze drying using hyperspectral imaging based on integrated group wavelengths. *LWT-food Science and Technology*, 82, 377-385.

Malatesta, M. (2018). The contribution of microscopy to food science: State of the art. *Microscopie*, 29(2).

Machini RA, Hunt MC, 2005. Current research in meat color. *Meat Science*, 71 (1):100-121.

Muriel, E., Ruiz, J., Ventanas, J., Petró, M. J., & Antequera, T. (2004). Meat quality characteristics in different lines of Iberian pigs. *Meat Science*, 67(2), 299-307.

Myhan, R., Markowski, M., Daszkiewicz, T., Korpusik, A., & Zapotoczny, P. (2016). Identification of the chemical composition of meat products based on their rheological properties. *Journal of Texture Studies*, 47(6), 504-513.

Naganathan, G. K., Cluff, K., Samal, A., Calkins, C. R., Jones, D. D., Meyer, G. E., & Subbiah, J. (2016). Three dimensional chemometric analyses of hyperspectral images for beef tenderness forecasting. *Journal of food engineering*, 169, 309-320.

Narsaiah, K., Biswas, A. K., & Mandal, P. K. (2020). Nondestructive methods for carcass and meat quality evaluation. In *Meat Quality Analysis* (pp. 37-49). Academic Press.

Nasyiruddin, R. L., Navicha, W. B., Ramadhan, A. H., Yang, F., Jiang, Q., Xu, Y., & Xia, W. (2019). Development of reduced-salt gel of silver carp meat batter using low frequency ultrasound: Effect on color, texture, cooking loss and microstructure. *Tropical Journal of Pharmaceutical Research*, 18(5).

Neyrinck, E., Telleir, D., Fraeye, I., Paelinck, H., & Raes, K. (2015). Impact of tumbling time on protein characteristics during cooked ham production. In Proceedings ICoMST 2015-61th International Congress of Meat Science and Technology (p. 204).

NORMA Oficial Mexicana NOM-087-ECOL-SSA1-2002, Protección ambiental - Salud ambiental - Residuos peligrosos biológico-infecciosos - Clasificación y especificaciones de manejo.

NORMA Oficial Mexicana NOM-017-STPS-2008, Equipo de protección personal-Selección, uso y manejo en los centros de trabajo.

Panagou, E. Z., Papadopoulou, O., Carstensen, J. M., & Nychas, G. J. E. (2014). Potential of multispectral imaging technology for rapid and non-destructive determination of the microbiological quality of beef filets during aerobic storage. *International journal of food microbiology*, 174, 1-11.

Pawlak, K. (2018, October). Competitiveness of the Polish meat industry against selected European Union countries within the framework of transatlantic trade. In *Proceedings of Economics and Finance Conferences* (No. 6910181). International Institute of Social and Economic Sciences.

Perez-Palacios, T., Caballero, D., González-Mohíno, A., Mir-Bel, J., & Antequera, T. (2019). Near Infrared Reflectance spectroscopy to analyse texture

related characteristics of sous vide pork loin. *Journal of Food Engineering*, 263, 417-423.

Pérez-Santaescolástica, C., Fraeye, I., Barba, F. J., Gómez, B., Tomasevic, I., Romero, A., & Lorenzo, J. M. (2019). Application of non-invasive technologies in dry-cured ham: An overview. *Trends in Food Science & Technology*.

Pieniazek, F., & Messina, V. (2016). Scanning electron microscopy combined with image processing technique: Analysis of microstructure, texture and tenderness in Semitendinous and Gluteus Medius bovine muscles. *Scanning*, 38(6), 727-734.

Resconi, V.C. (2007). The effect of diet on vitamin E concentration, colour, shelf life and lipid oxidation during simulated retail display in beef steaks from different production systems. Tesis.

Ripoll, G., Panea, B., & Albertí, P. (2012). *Apreciación visual de la carne bovina y su relación con el espacio de color CIELab ITEA Información Técnica Económica Agraria*, 108(2), 222-232.

Romero de Avila D., M., Isabel Cambero, M., Ordóñez, J. A., de la Hoz, L., & Herrero, A. M. (2014). Rheological behaviour of commercial cooked meat products evaluated by tensile test and texture profile analysis (TPA). *Meat science*.

Sadeghi-Mehr, A., Raudsepp, P., Brüggemann, D. A., Lautenschlaeger, R., & Drusch, S. (2018). Dynamic rheology, microstructure and texture properties of model porcine meat batter as affected by different cold-set binding systems. *Food hydrocolloids*, 77, 937-944.

Sahar, A., Rahman, U., Kondjoyan, A., Portanguen, S., & Dufour, E. (2016). Monitoring of thermal changes in meat by synchronous fluorescence spectroscopy. *Journal of food engineering*, 168, 160-165.

Scheier, R., Bauer, A., & Schmidt, H. (2014). Early postmortem prediction of meat quality traits of porcine semimembranosus muscles using a portable raman system. *Food and bioprocess technology*, 7(9), 2732-2741.

Silva-Buzanello, R. A. D., Schuch, A. F., Gasparin, A. W., Torquato, A. S., Scremin, F. R., Canan, C., & Soares, A. L. (2019). Quality parameters of chicken breast meat affected by carcass scalding conditions. *Asian-Australasian journal of animal sciences*.

Sharifzadeh, S., Clemmensen, L. H., Borggaard, C., Støier, S., & Ersbøll, B. K. (2014). Supervised feature selection for linear and non-linear regression of L\*a\*b\* color from multispectral images of meat. *Engineering Applications of Artificial Intelligence*, 27, 211-227.

Smetana, S., Larki, N. A., Pernutz, C., Franke, K., Bindrich, U., Toepfl, S., & Heinz, V. (2018). Structure design of insect-based meat analogs with high-moisture extrusion. *Journal of Food Engineering*, 229, 83-85.

Soares, A. L., Lara, J. A. F., Ida, E. I., Guarnieri, P. D., Olivo, R., & Shimokomaki, M. (2002, August). Variation in the colour of Brazilian broiler breast fillet. In *Proceedings of International Congress of Meat Science and Technology* (Vol. 48, pp. 540-541).

Taheri-Garavand, A., Fatahi, S., Shahbazi, F., & de la Guardia, M. (2019). A nondestructive intelligent approach to real-time evaluation of chicken meat freshness based on computer vision technique. *Journal of Food Process Engineering*, e13039.

Takei, R., Hayashi, M., Umene, S., Kobayashi, Y., & Masunaga, H. (2016). Texture and microstructure of enzyme-treated chicken breast meat for people with difficulties in mastication. *Journal of Texture Studies*, 47(3), 231-238.

Tan, J., 2004. Meat quality evaluation by computer vision. *Journal of Food Engineering* 61 (1), 27-35.

Tao, F., & Peng, Y. (2015). A nondestructive method for prediction of total viable count in pork meat by hyperspectral scattering imaging. *Food and Bioprocess Technology*, 8(1), 17-30.

Tsakanikas, P., Pavlidis, D., & Nychas, G. J. (2015). High throughput multispectral image processing with applications in food science. *PloS one*, 10(10), e0140122.

Tsakanikas, P., Pavlidis, D., Panagou, E., & Nychas, G. J. (2016). Exploiting multispectral imaging for non-invasive contamination assessment and mapping of meat samples. *Talanta*, 161, 606-614.

Troy, D. J., & Kerry, J. P. (2010). Consumer perception and the role of science in the meat industry. *Meat science*, 86(1), 214-226.

Wang, R., Huang, F., Zhang, L., Liu, Q., Zhang, C., & Zhang, H. (2019). Changes in the texture, microstructures, colour and volatile compounds of pork meat loins during superheated steam cooking. *International Journal of Food Science & Technology*, 54(10), 2821-2830.

Wells, H. C., Edmonds, R. L., Kirby, N., Hawley, A., Mudie, S. T., & Haverkamp, R. G. (2013). Collagen fibril diameter and leather strength. *Journal of agricultural and food chemistry*, 61(47), 11524-11531.

Wu, G., Farouk, M. M., Clerens, S., & Rosenvold, K. (2014). Effect of beef ultimate pH and large structural protein changes with aging on meat tenderness. *Meat Science*, 98(4), 637-645.

Xiaobo, Z., Xiaowei, H., & Povey, M. (2016). Non-invasive sensing for food reassurance. *Analyst*, 141(5), 1587-1610.

Xiong, Z., Sun, D. W., Pu, H., Xie, A., Han, Z., & Luo, M. (2015). Non-destructive prediction of thiobarbituric acid reactive substances (TBARS) value for freshness evaluation of chicken meat using hyperspectral imaging. *Food chemistry*, 179, 175-181.

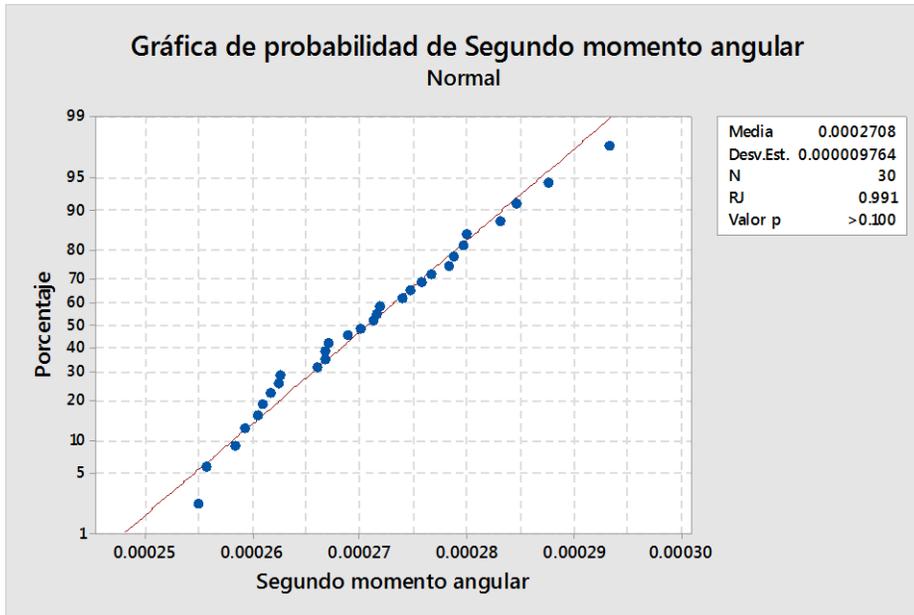
Xiong, Z., Sun, D. W., Pu, H., Gao, W., & Dai, Q. (2017). Applications of emerging imaging techniques for meat quality and safety detection and evaluation: A review. *Critical reviews in food science and nutrition*, 57(4), 755-768.

Yang, C.C., Chao, K., Kim, M.S., Chan, D.E., et al., 2010. Machine vision system for on-line wholesomeness inspection of poultry carcasses. *Poult. Sci.* 89 (6), 1252\_1264.

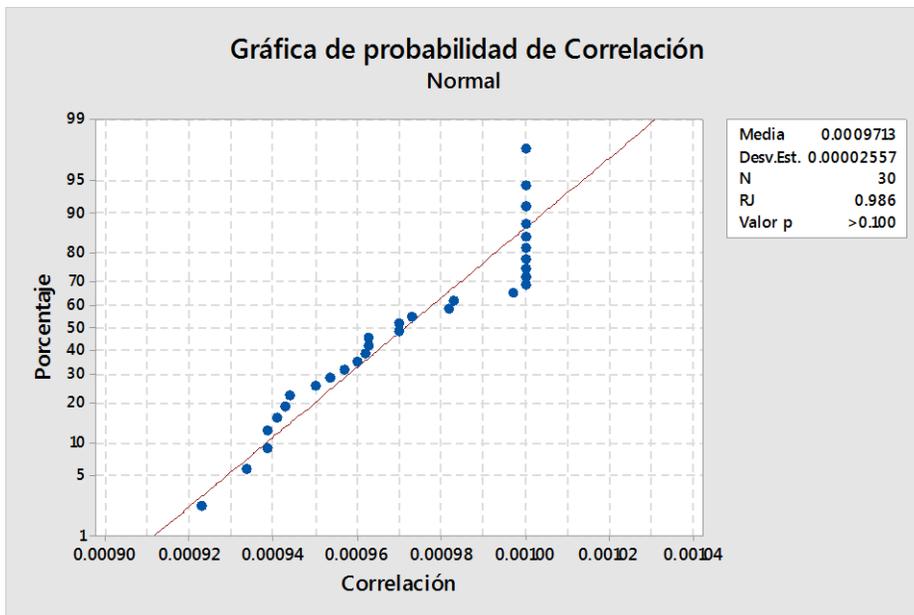
Zhang, W., Naveena, B. M., Jo, C., Sakata, R., Zhou, G., Banerjee, R., & Nishiumi, T. (2017). Technological demands of meat processing—An Asian perspective. *Meat Science*, 132, 35-44.

## ANEXOS

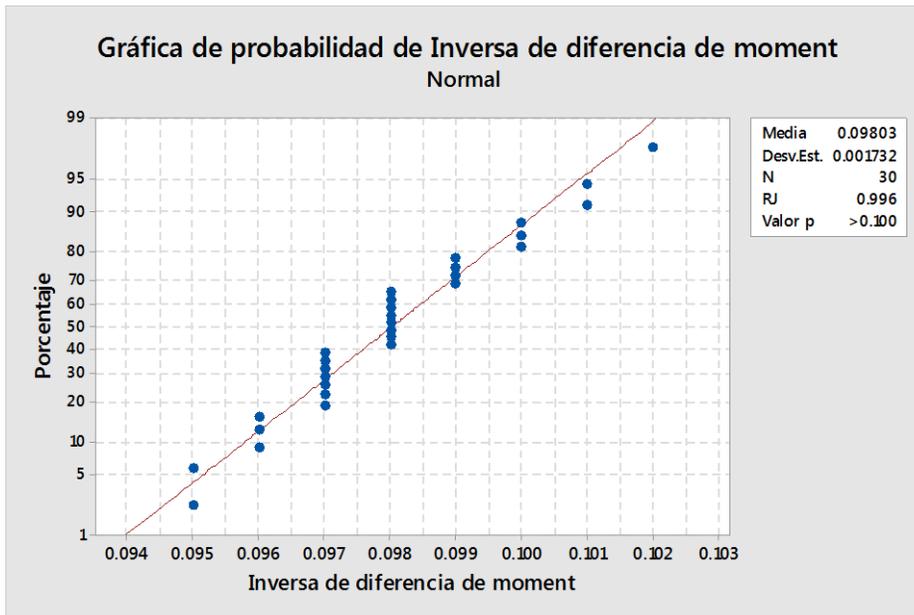
1. Gráficas de resultados de normalidad de segundo momento angular.



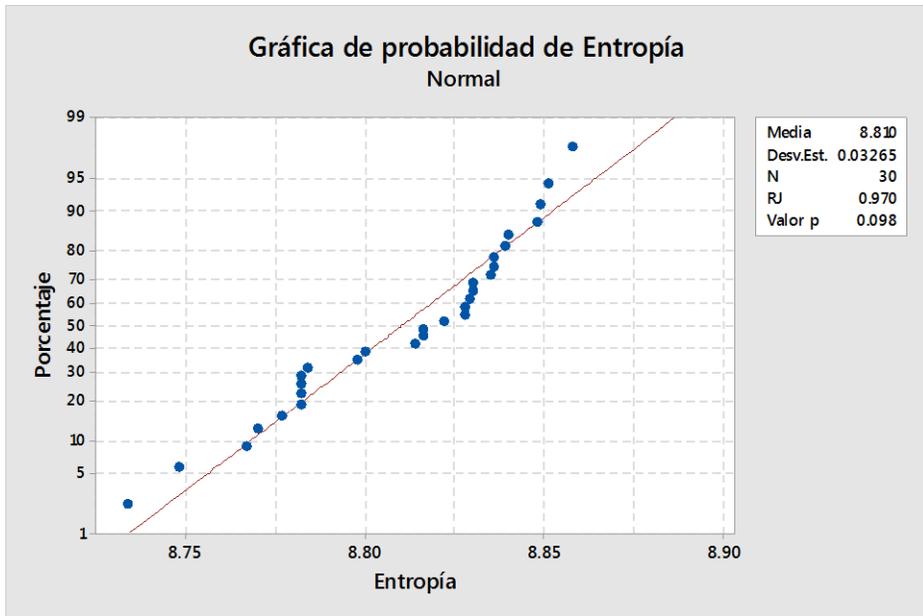
2. Gráfica de resultados de normalidad de correlación.



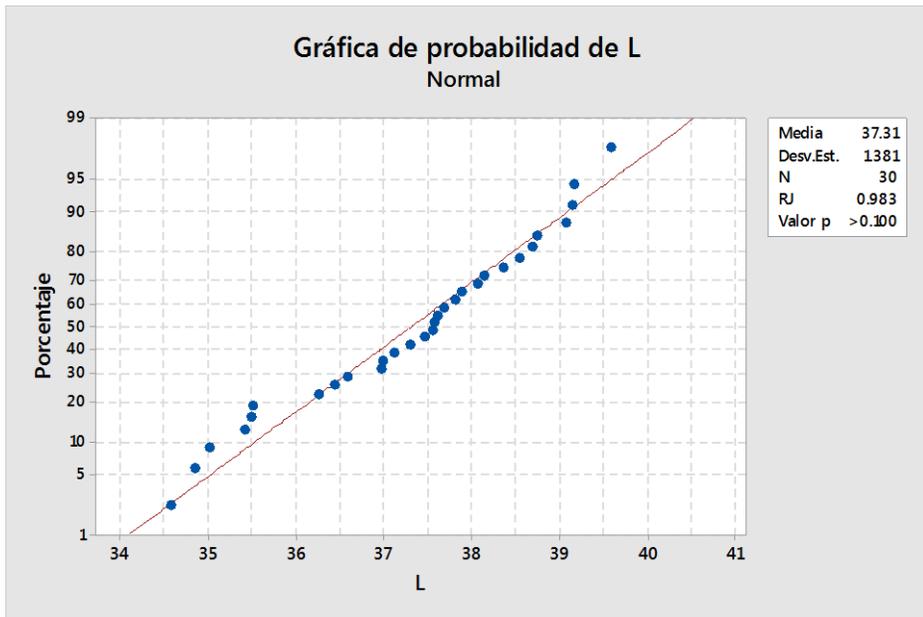
3. Gráficas de resultados de normalidad de inversa de diferencia de momento.



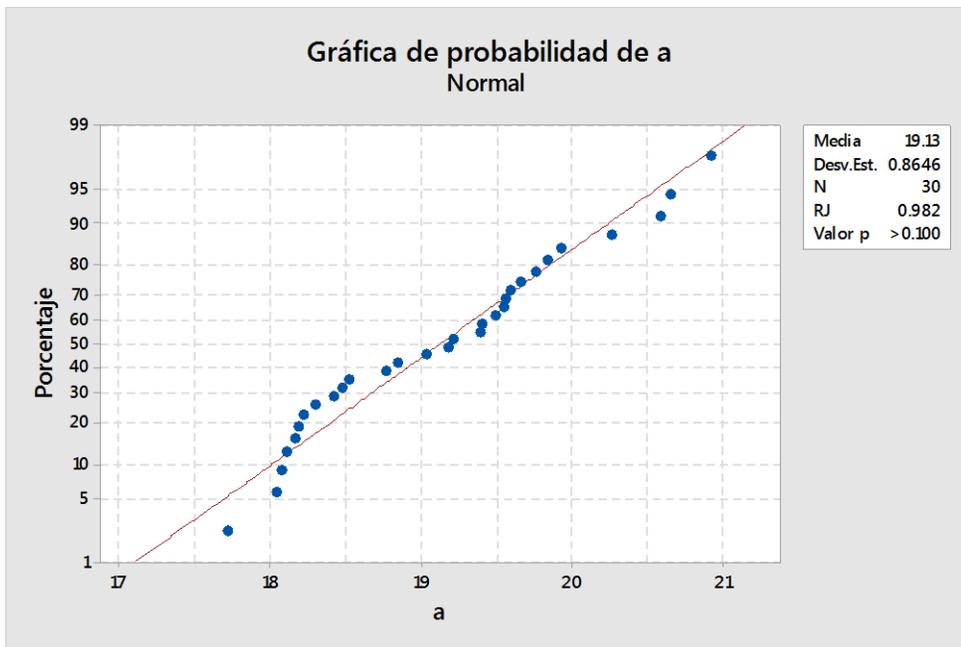
4. Gráficas de resultados de normalidad de entropía.



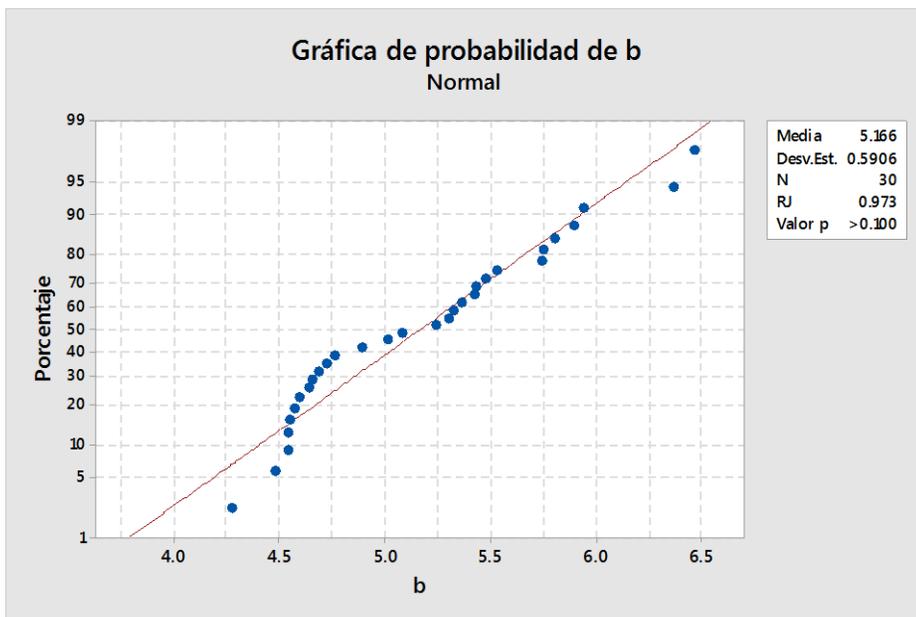
5. Gráficas de resultados de normalidad del valor de  $L^*$ .



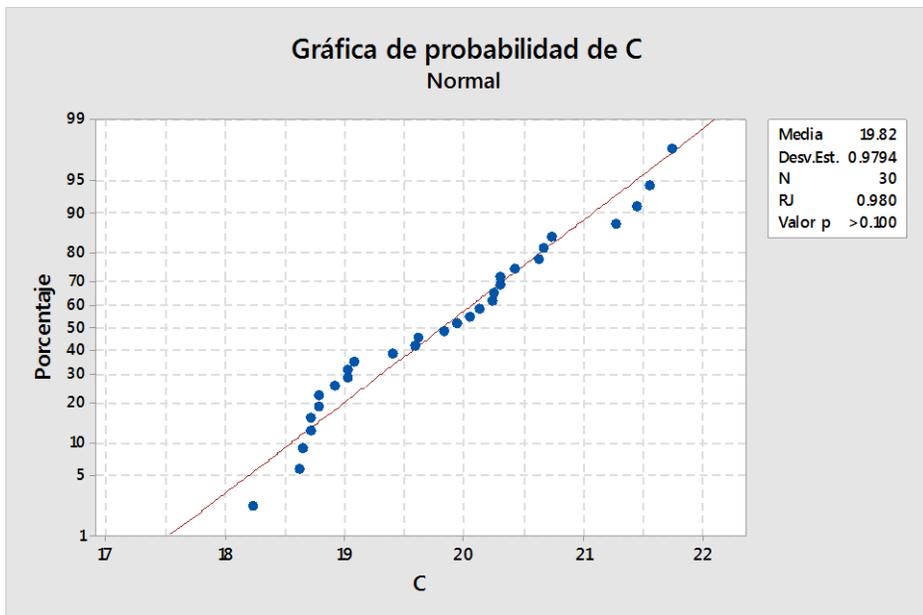
6. Gráficas de resultados de normalidad del valor de  $a^*$ .



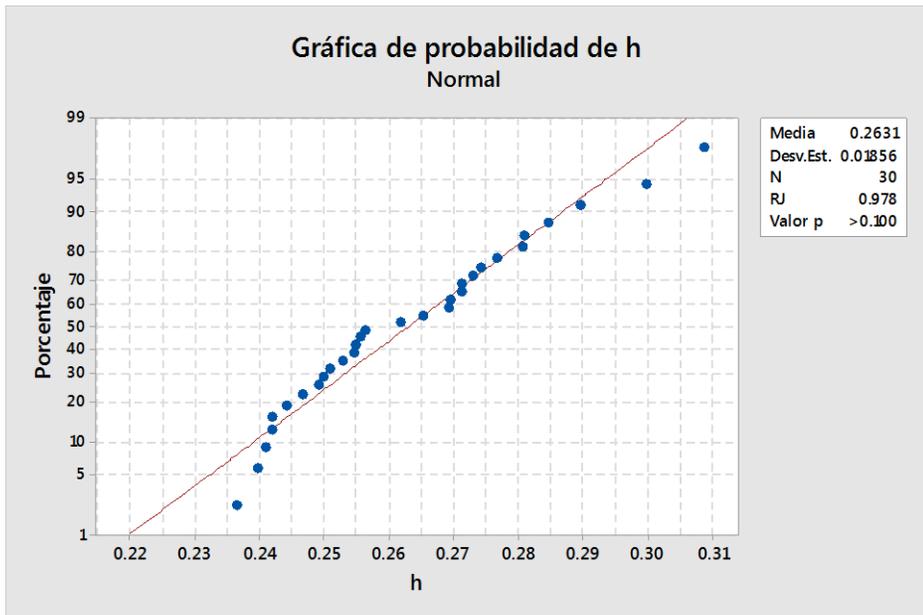
7. Gráficas de resultados de normalidad del valor de  $b^*$ .



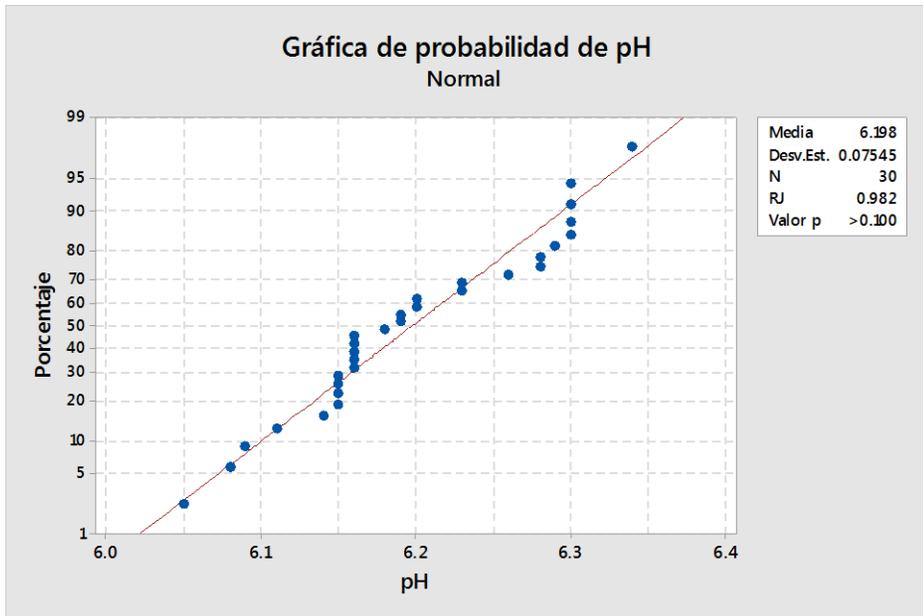
8. Gráficas de resultados de normalidad del valor de  $C^*$ .



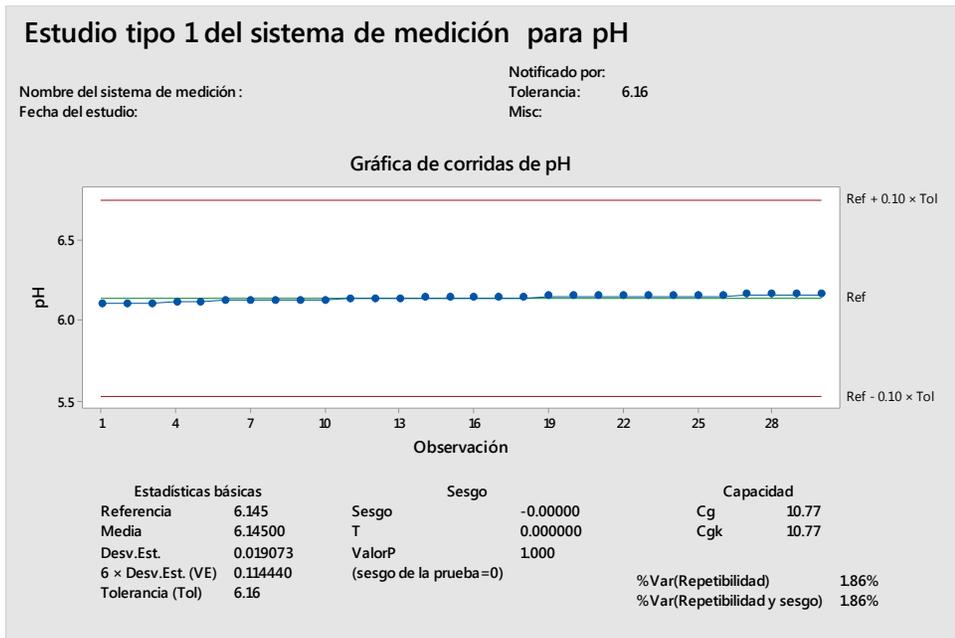
9. Gráficas de resultados de normalidad del valor de  $h^*$ .



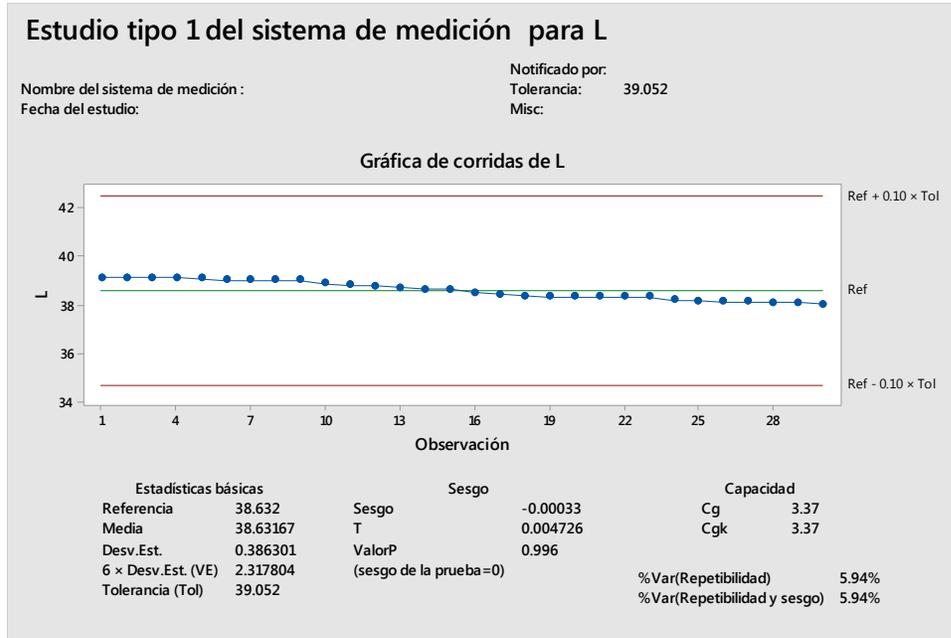
10. Gráficas de resultados de normalidad del pH.



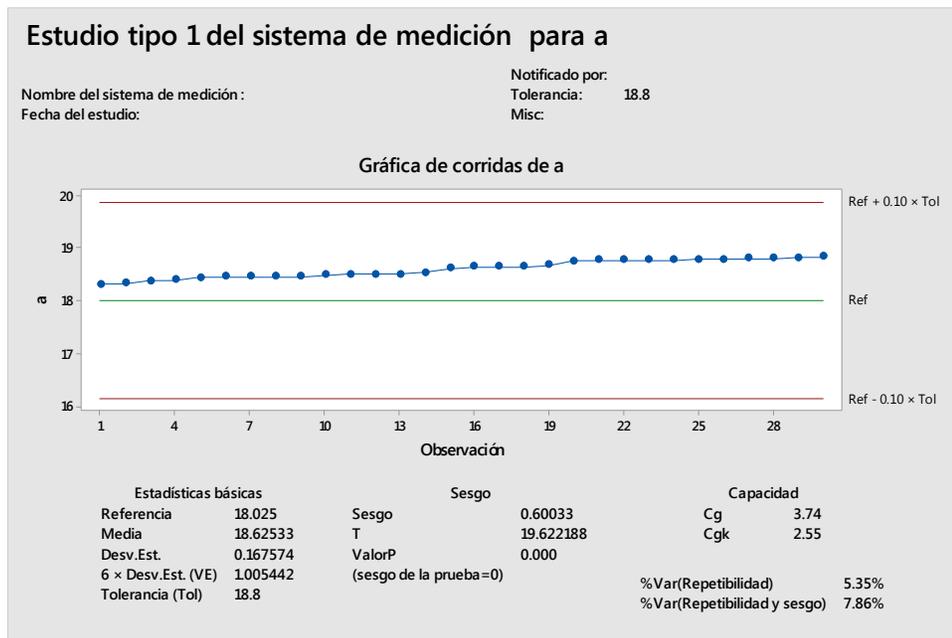
## 11. Resultados de estudio tipo 1 del pH.



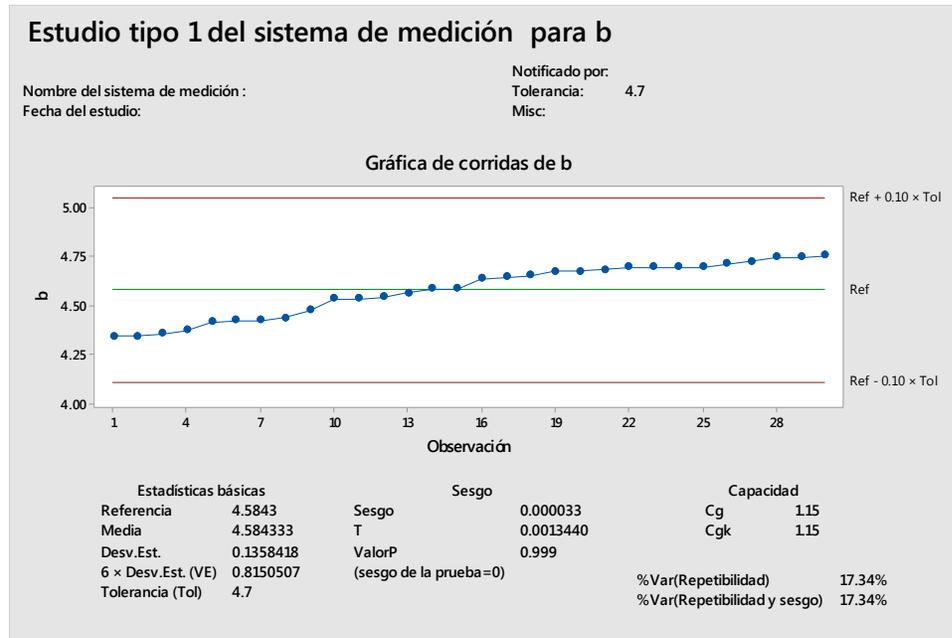
12. Resultados de estudio tipo 1 del valor de L\*.



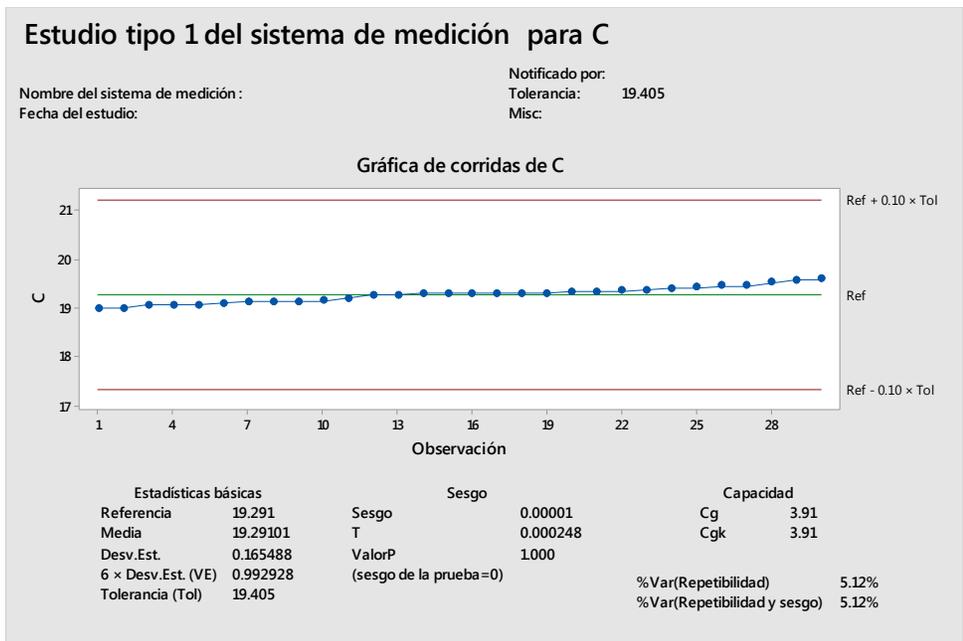
13. Resultados de estudio tipo 1 del valor de a\*.



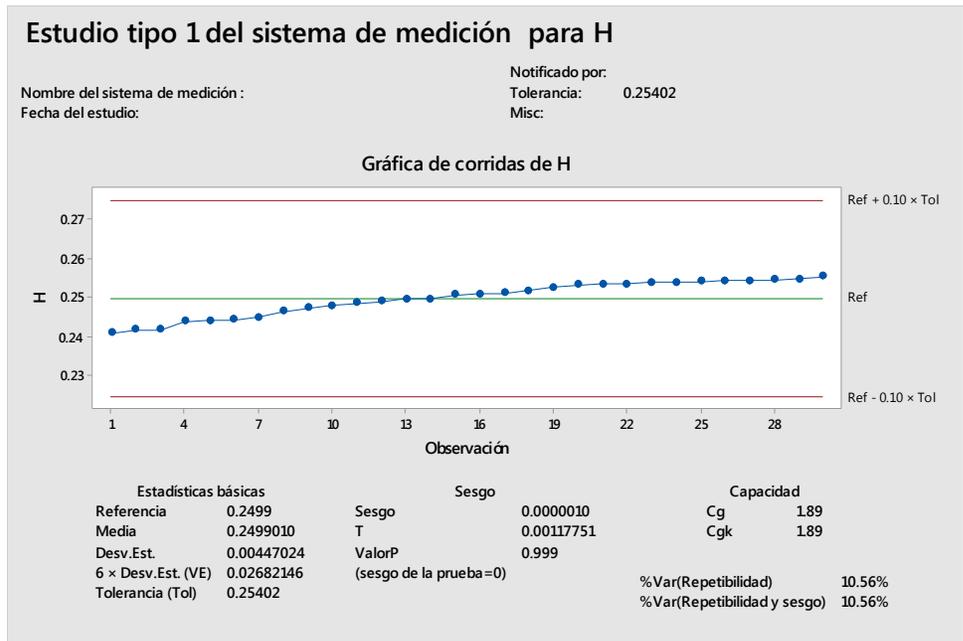
14. Resultados de estudio tipo 1 del valor de  $b^*$ .



15. Resultados de estudio tipo 1 del valor de  $C^*$ .



16. Resultados de estudio tipo 1 del valor de h\*.



17. Resultados de estudio tipo 1 de segundo momento angular.

