



UNIVERSIDAD AUTÓNOMA CHAPINGO

**POSGRADO EN INGENIERÍA AGRÍCOLA
Y USO INTEGRAL DEL AGUA**

DETERMINACIÓN DE LA PUREZA VARIETAL DE GRANOS DE CEBADA MEDIANTE VISIÓN POR COMPUTADORA

TESIS

**QUE COMO REQUISITO PARCIAL
PARA OBTENER EL GRADO DE:**

**MAESTRO EN INGENIERÍA AGRÍCOLA
Y USO INTEGRAL DEL AGUA**

PRESENTA:

PABLO HERNÁNDEZ SANTIAGO

Chapingo, Estado de México, Enero de 2017



**DIRECCION GENERAL ACADEMICA
DEPTO. DE SERVICIOS ESCOLARES
ORIGINA DE EXAMENES PROFESIONALES**



**DETERMINACIÓN DE LA PUREZA VARIETAL DE GRANOS DE CEBADA
MEDIANTE VISIÓN POR COMPUTADORA**

Tesis realizada por Pablo Hernández Santiago, bajo la dirección del Comité Asesor indicado, aprobada por el mismo y aceptada como requisito parcial para obtener el grado de:

MAESTRO EN INGENIERÍA AGRÍCOLA Y USO INTEGRAL DEL AGUA

DIRECTOR: _____


Dr. Gilberto de Jesús López Canteñs

ASESOR: _____


Dr. Efrén Fitz Rodríguez

ASESOR: _____


Dr. Noé Velázquez López

AGRADECIMIENTOS

A la Universidad Autónoma Chapingo por ser parte fundamental de mi formación académica y al Posgrado de Ingeniería Agrícola y Uso Integral del Agua por darme la oportunidad de realizar satisfactoriamente mis estudios de maestría.

Al Consejo Nacional de Ciencia y Tecnología (CONACyT) por el apoyo económico brindado para la realización y culminación de mis estudios de maestría.

Al Doctor Gilberto de Jesús López Canteñs por su tiempo y dedicación para que este proyecto se llevara a cabo de forma exitosa.

Al Doctor Efrén Fitz Rodríguez y Noé Velázquez López por su empeño y dedicación cada vez que se necesitó para los avances y realización de este trabajo.

Al Doctor Mauro Zamora Díaz encargado del Programa de Cebada Maltera del Campo Experimental Valle de México, INIFAP; por proporcionar el material de estudio.

A todas aquellas personas que directa o indirectamente hicieron posible la culminación de mis estudios.

DATOS BIOGRÁFICOS

Pablo Hernández Santiago es originario de la Comunidad de Santiago Jocotepec, municipio de Villa de Tututepec de Melchor Ocampo del estado de Oaxaca, nació el 22 de marzo de 1990; realizó sus estudios de Ingeniería en la Universidad Autónoma Chapingo obteniendo el grado de Ingeniero Mecánico Agrícola por mérito académico en el año 2014.

En ese mismo año fue aceptado para cursar los estudios de Maestría en el Posgrado de Ingeniería Agrícola y Uso Integral del Agua de la Universidad Autónoma Chapingo donde su área de investigación se enfocó en la aplicación de visión por computadora y redes neuronales para la clasificación de granos de cebada.

CONTENIDO

ÍNDICE DE CUADROS	vii
ÍNDICE DE FIGURAS	ix
Capítulo 1. INTRODUCCIÓN	1
1.1 Objetivo general.....	2
1.2 Objetivos específicos	2
1.3 Hipótesis	2
Capítulo 2. REVISIÓN DE LITERATURA	3
2.1 Importancia de la cebada.....	3
2.2 Descripción del grano de cebada	5
2.3 Evaluación de la cebada para malteo	7
2.3.1 Norma que rige la calidad de la cebada maltera en México	7
2.3.2 Método para la determinación de impurezas	8
2.4 Métodos para el análisis de muestras en la recepción de granos de cereales	11
2.4.1 Electroforesis de proteínas.....	12
2.4.2 Espectroscopia de infrarrojo cercano (NIR)	13
2.4.3 Visión por computadora	15
Capítulo 3. MATERIALES Y MÉTODOS	23
3.1 Material de estudio	23
3.2 Sistema de adquisición de imágenes	23
3.2.1 Adquisición de imágenes	26
3.2.2 Calibración de la cámara.....	27
3.3 Preprocesamiento de imágenes	31
3.3.1 Segmentación	31
3.3.2 Operaciones morfológicas.....	34

3.3.3 Etiquetado de los granos en la imagen	36
3.4 Extracción de características	38
3.4.1 Características de tamaño	38
3.4.2 Características de forma	40
3.4.3 Características de color.....	44
3.4.4 Características de textura	49
3.5 Selección de características	55
3.6 Clasificación.....	58
3.7 Validación del algoritmo.....	63
Capítulo 4. RESULTADOS Y DISCUSIÓN.....	65
4.1 Características seleccionadas	67
4.2 Arquitectura de las redes neuronales	75
4.3 Rendimientos de clasificación.....	80
4.4 Validación del algoritmo.....	85
Capítulo 5. CONCLUSIONES.....	90
5.1 Recomendaciones	91
Capítulo 6. REFERENCIAS.....	92
ANEXOS	102
Anexo 1.	102
Anexo 2.	111
Anexo 3.	114
Anexo 4.	116

ÍNDICE DE CUADROS

Cuadro 1. Características agronómicas de las variedades estudiadas. -----	4
Cuadro 2. Parámetros y especificaciones de calidad en cebada maltera. -----	8
Cuadro 3. Ajustes por impurezas en el grano. -----	9
Cuadro 4. Aplicaciones de visión por computadora en la clasificación de cereales. -----	18
Cuadro 5. Reglas sugeridas para el número de neuronas en la capa oculta basado en el número de variables de entrada (Ni) y/o nodos de salida (No). ---	63
Cuadro 6. Matriz de confusión y descripción de variables VP, VN, FP y FN. ---	64
Cuadro 7. Características de forma. -----	65
Cuadro 8. Características de color. -----	66
Cuadro 9. Características de textura. -----	67
Cuadro 10. Características seleccionadas del Factor 1. -----	68
Cuadro 11. Características seleccionadas del Factor 2. -----	68
Cuadro 12. Características seleccionadas. -----	75
Cuadro 13. Error cuadrático medio para diferentes arquitecturas entrenadas. -	76
Cuadro 14. Diferentes arquitecturas entrenadas para la RNA2. -----	78
Cuadro 15. Rendimiento de clasificación obtenido por la RNA1 para clasificar granos de cinco variedades de cebada. -----	81
Cuadro 16. Rendimiento de clasificación obtenido mediante análisis discriminante para clasificar granos de cinco variedades de cebada. -----	82
Cuadro 17. Rendimiento de clasificación obtenidos mediante árboles de decisión para clasificar granos de cinco variedades de cebada. -----	82
Cuadro 18. Rendimiento de clasificación obtenido por la RNA2 para clasificar granos de cebada e impurezas. -----	83
Cuadro 19. Rendimiento de clasificación obtenido mediante análisis discriminante para clasificar granos de cebada e impurezas. -----	84
Cuadro 20. Rendimiento de clasificación obtenido mediante árboles de decisión para clasificar granos de cebada e impurezas. -----	84
Cuadro 21. Sensibilidad y especificidad para el clasificador RNA1 en la evaluación del algoritmo. -----	85
Cuadro 22. Sensibilidad y especificidad para el clasificador RNA2 en la evaluación del algoritmo. -----	86

Cuadro 23. Número de granos de cada variedad de cebada presentes en las imágenes. -----	87
Cuadro 24. Número de granos de cada variedad de cebada identificados por el clasificador. -----	87
Cuadro 25. Porcentaje de errores en la clasificación de cada variedad de cebada. -----	88
Cuadro 26. Medidas en píxeles de un milímetro de una regla ubicada en diferentes posiciones dentro del área de la imagen. -----	116
Cuadro 27. Medidas en píxeles de un centímetro de una regla ubicada dentro del área de la imagen. -----	117

ÍNDICE DE FIGURAS

Figura 1. Grano de cebada: a) lado dorsal, b) lado ventral.	5
Figura 2. Esquema de instrumentación de un espectrofotómetro NIR.....	14
Figura 3. Etapas fundamentales de un sistema de visión artificial (adaptado de González y Woods, 2007).....	15
Figura 4. Efectos de sombra en la imagen.	24
Figura 5. Esquema del sistema de adquisición de imágenes.	24
Figura 6. Cajas de luz para la iluminación del área a fotografiar.	25
Figura 7. Proceso para reconocimiento automático de granos de cebada e impurezas.	25
Figura 8. Proceso para la calibración de la cámara.	27
Figura 9. Patrón de calibración.	28
Figura 10. Error medio de reproyección por imagen.....	31
Figura 11. Histograma de niveles de gris para una imagen analizada.....	32
Figura 12. a) Imagen original, b) en escala de grises y c) binarizada.	34
Figura 13. Aplicación de operaciones morfológicas. a) Erosión binaria, b) Dilatación binaria y c) Clausura.	36
Figura 14. Modelo RGB.	46
Figura 15. Modelo HSV.....	47
Figura 16. Modelo CIE 1976 $L^*a^*b^*$	49
Figura 17. Matriz de coocurrencia calculada a partir de otra matriz de 4X5.	50
Figura 18. Topología de la red neuronal para clasificar variedades de cebada.	60
Figura 19. Reconstrucción mediante descriptores elípticos de Fourier sobre una serie de armónicos (N).....	66
Figura 20. Gráfico de sedimentación.	69
Figura 21. Gráfico de componente en espacio rotado.	70
Figura 22. Representación en coordenadas paralelas de las características seleccionadas.	71
Figura 23. Representación en coordenadas paralelas de las características de textura en el componente R.....	72
Figura 24. Representación en coordenadas paralelas de las características de color.	73
Figura 25. Representación en coordenadas paralelas de los descriptores elípticos de Fourier en el coeficiente a para 30 armónicos.	73
Figura 26. Gráfico de componente en espacio rotado.	74

Figura 27. Arquitectura de la RNA1.	77
Figura 28. Curvas de desempeño para el entrenamiento y prueba de la RNA1.	78
Figura 29. Arquitectura de la RNA2.	79
Figura 30. Curvas de desempeño para el entrenamiento y prueba de la RNA2.	80
Figura 31. Interfaz de usuario para determinar la pureza varietal de granos de cebada.	85
Figura 32. Algoritmo para la determinación de la pureza varietal de granos de cebada.	89

DETERMINACIÓN DE LA PUREZA VARIETAL DE GRANOS DE CEBADA MEDIANTE VISIÓN POR COMPUTADORA

DETERMINATION OF VARIETAL PURITY OF BARLEY GRAINS BY COMPUTER VISION

Pablo Hernández Santiago¹ y Gilberto de Jesús López Canteñs²

RESUMEN

Las diversas variedades de cebada cervecera se comportan de manera diferente durante el proceso de malteado, es por esto que se exige una alta calidad en la materia prima, donde surge la necesidad de clasificar los granos de cebada de acuerdo a su variedad.

Por lo tanto, se ha desarrollado un algoritmo de visión por computadora para clasificar cinco variedades de granos de cebada maltera e impurezas presentes en una muestra. La primera etapa consistió en la adquisición, procesamiento de imágenes y la obtención de 171 características de tamaño, forma, textura y color de granos de cebada que se redujeron mediante análisis factorial por el método de componentes principales a 41 parámetros. Para la clasificación de las variedades de cebada e impurezas se implementaron redes neuronales de reconocimiento de patrones, empleando el método de entrenamiento Levenberg-Marquardt con regulación bayesiana. La precisión en la clasificación de las variedades de cebada e impurezas fue de 93.9 y 99.9%, respectivamente, mostrando un error medio cuadrado de 0.011 y 0.0009. En la validación del algoritmo para los clasificadores entrenados se obtuvo una sensibilidad y especificidad promedio de 90.5 y 97.4% clasificando variedades y 99% en ambos parámetros medidos clasificando granos de cebada de impurezas.

PALABRAS CLAVE: *Hordeum vulgare* L., procesamiento de imágenes, Levenberg-Marquardt, Redes neuronales, regulación bayesiana.

ABSTRACT

The different varieties of beer barley behave differently during the malting process, which is why a high quality is required in the raw material, and here arises the need to classify the barley grains according to their variety. Therefore, a computer vision algorithm has been developed to classify five varieties of malting barley grains and impurities present in a sample. The first stage consisted of the acquisition, image processing and the obtaining of 171 characteristics of size, shape, texture and color of barley grains that were reduced by factorial analysis by the principal components method to 41 parameters. For the classification of barley varieties and impurities, neural networks for pattern recognition were implemented, using the Levenberg-Marquardt training method with Bayesian regulation. The accuracy in the classification of barley and impurities was 93.9 and 99.9%, respectively, showing a mean square error of 0.011 and 0.0009. In the validation of the algorithm performed by trained classifiers an average sensitivity and specificity of 90.5 and 97.4% were obtained during the classification of varieties and 99% in both parameters measured, classifying barley grains from impurities.

KEYWORDS: *Hordeum vulgare* L., image processing, Levenberg-Marquardt, Neural networks, Bayesian regulation.

¹Tesista

²Director

Capítulo 1. INTRODUCCIÓN

La cebada es el cuarto cereal cultivado a nivel mundial después del maíz, arroz y trigo (FAO, 2015). La producción de cebada en México para el año 2014 fue de 845 707 t con un rendimiento promedio de 2.7 t ha⁻¹. Se estima que, en México, 82 % del consumo total de cebada se destina a la industria, 11 % al consumo animal y 7 % a semilla para siembra durante el 2016 (SIAP, 2016).

El grano destinado a la industria tiene su principal uso en la fabricación de malta para cerveza; el malteado se hace sobre una base varietal, con condiciones particulares a cada variedad. Las diversas variedades de cebada cervecera se comportan de manera diferente durante el malteado. Es por esto, que es necesario mantener las variedades por separado a medida que se cultivan, cosechan, almacenan, transportan y procesan. Cada variedad producirá malta con un perfil particular de calidad. Los cerveceros especifican qué variedad o variedades se quieren en la malta que utilizan con el fin de obtener las características de calidad que necesitan para tomar sus tipos de cerveza.

El control de calidad es uno de los temas importantes en la industria de la alimentación, ya que, después de la cosecha, los productos alimenticios se ordenan y clasifican en diferentes grados en función de los parámetros de calidad. Hay una necesidad real de los medios con los que precisa una rápida y accesible determinación de la composición varietal de las muestras de cebada. Esto se está convirtiendo en una necesidad cada vez más importante, ya que el número de variedades de cebada registradas prolifera. Tradicionalmente, los malteros se basaron en métodos subjetivos para la adquisición de cebada (Arias, 1991). La identificación de las variedades ya no es adecuada mediante la percepción visual humana.

La tecnología de visión artificial proporciona una alternativa a la inspección manual de muestras de grano (Visen *et al.*, 2004). Este método es una tecnología prometedora para la rápida identificación y automatización en el manejo de

granos. La medición y la extracción de las características de color, textura, forma y tamaño utilizando un sistema de visión artificial ofrecen una solución potencial a considerar.

1.1 Objetivo general

Por lo tanto, se plantea desarrollar un sistema de visión artificial para la determinación de la pureza varietal de granos de cebada.

1.2 Objetivos específicos

- Implementar algoritmos de visión por computadora para el procesamiento de imágenes y extracción de características de los granos de cebada y las impurezas.
- Seleccionar las características necesarias para la correcta identificación de los granos de cinco variedades de cebada maltera.
- Entrenar una red neuronal para clasificar los granos de cebada de acuerdo a su variedad y porcentaje de impurezas.
- Desarrollar una interfaz gráfica donde implementar los algoritmos para la determinación de la pureza varietal en una muestra de granos de cebada.
- Evaluar la eficiencia del algoritmo basado en la sensibilidad y especificidad.

1.3 Hipótesis

El sistema de visión artificial puede ser capaz de determinar la pureza varietal de granos de cebada usando las características morfológicas, texturales y de color de cada grano.

Capítulo 2. REVISIÓN DE LITERATURA

2.1 Importancia de la cebada

En la actualidad, la cebada se produce en casi todo el mundo, destinándola principalmente a dos tipos de mercado: como alimento para ganado y para la producción de malta. La cebada es la principal materia prima para la elaboración de cerveza y su utilización se basa en el hecho de que tiene un alto contenido de almidón y cuenta con buena calidad maltera (capacidad de germinación) y buena calidad cervecera (bajo contenido de proteínas) (Vázquez, 1990; Kunze, 2006).

La cebada pertenece a la familia de las gramíneas, todas las cebadas se integran en el género *Hordeum* dentro del cual se encuentran las especies *Hordeum distichum* o dísticas (cuando únicamente la espiga central es fértil, se describe como de 2 hileras) *Hordeum vulgare* o hexísticas (cuando las tres espigas se encuentran fértiles, se describe la espiga como de 6 hileras) (Ruiz, 2006).

Ambas especies de cebada se emplean para la elaboración de malta cervecera; las variedades *Hordeum distichum* producen granos más gruesos y uniformes, y por ello se utilizan para la elaboración de maltas primordialmente en países de Europa, mientras que las variedades *Hordeum vulgare* poseen un alto potencial enzimático y son preferidas principalmente en cervecerías de México, Canadá y Estados Unidos (Hornsey, 1999).

En México el cultivo de la cebada se orienta a la producción de malta para la elaboración de cerveza, existiendo en menor medida la producción destinada al forraje. La producción en el año 2014 fue de 845 707 t con un rendimiento promedio de 2.7 t ha⁻¹. La producción de cebada se concentra en el centro del país, siendo los estados más importantes Hidalgo, Tlaxcala, Guanajuato, Estado de México y Puebla, que en conjunto aportaron el 92% del volumen y valor

generados en 2013 (SHCP, 2014). Este cereal tiene gran importancia socioeconómica debido a que representa el ingreso de miles de familias que habitan en las zonas productoras del centro del país, así como por su utilización como materia prima para la industria maltera, forrajera y en menor proporción como alimento humano (Zamora *et al.*, 2008).

No cualquier variedad de cebada es apta para elaborar cerveza, solamente las variedades que cumplen con los requisitos de calidad indispensables para el proceso industrial. La producción de grano de cebada que requiere la industria maltera en México se centra principalmente en dos variedades: la variedad Esperanza, para las zonas de riego en el Bajío y la variedad Esmeralda, para las zonas de temporal en el Altiplano. Las variedades Alina y Armida constituyen otra opción para condiciones de riego, mientras que Adabella se recomienda para zonas de temporal con ambientes de buena productividad (Zamora *et al.*, 2008; Solano *et al.*, 2009; Zamora *et al.*, 2010; González *et al.*, 2016).

Las principales características de las variedades antes mencionadas se presentan en el siguiente cuadro.

Cuadro 1. Características agronómicas de las variedades estudiadas.

Variedad	Adabella	Alina	Armida	Esmeralda	Esperanza
Habito de crecimiento	Primavera	Verano	Primavera	Primavera	Primavera
Tamaño de la planta (m)	0.5 – 1.0	0.8 – 1.2	0.74 – 1.2	0.86 – 1.05	0.8
Rendimiento (t ha ⁻¹)	2.9 – 5.4	7.1 -11.3	5.9 – 11.7	3.9	8
Madurez fisiológica (días)	90 - 132	106 - 123	102 - 120	91 - 120	118 - 134
Referencia	Zamora <i>et al.</i> , 2008	Solano y Zamora, 2006	Zamora <i>et al.</i> , 2010	Zamora <i>et al.</i> , 1997	González <i>et al.</i> , 2006

2.2 Descripción del grano de cebada

El grano de cebada no es una semilla, sino un fruto seco indehisciente denominado cariósido (Holopainen-Mantila, 2015). El grano de cebada se divide en tres partes principales, la región germinal, el endospermo y el pericarpio o cubierta. La región germinal contiene el embrión con nudos de crecimiento para la acrospira y las raicillas y se encuentra justamente en la parte dorsal del grano, el endospermo se compone por células estables que contienen principalmente gránulos de almidón y la cubierta es la que protege al pericarpio, al endospermo y al germen, esta cobertura está formada por la lemma que se encuentra en la parte dorsal y la pálea que está ubicada en la parte ventral (Kunze, 2006; Tejada, 2016), como se muestra en la Figura 1.




Figura 1. Grano de cebada: a) lado dorsal, b) lado ventral.

La cubierta o cáscara es la primera capa que protege al grano, y está constituida por celulosa, hemicelulosa y lignina. Se forma durante el desarrollo del grano. Constituye del 6 al 10 por ciento del peso del grano, es gruesa en la región basal o germinal y disminuye su grosor hacia la región distal del grano. La

cáscara de las cebadas de dos hileras es más delgada y se ajusta mejor al grano que en las cebadas hexísticas.

La lemma es la cascarilla que envuelve al grano por su lado dorsal; en ella se distinguen las venas laterales y centrales, la barba, la región basal, y las glumas localizadas en ese mismo lado del grano. La cascarilla de la lemma puede ser gruesa (lisa) o delgada (arrugada), y estar poco o muy adherida al grano.

Por su posición en el nudo del raquis el grano puede ser simétrico (grano central) o asimétrico (granos laterales), y su forma puede ser alargada delgada, alargada ovoidal o rómbica. En la cebada de seis hileras (hexísticas), dos de los tres granos que constituyen la espiguilla son asimétricos y se desarrollan a los costados del grano central, el cual tiene forma simétrica; y en la cebada de dos hileras (díctica) se desarrollan sólo granos anchos y simétricos (Herrera, 2012).

El tamaño del grano depende de la influencia del ambiente y sus dimensiones sin la barba alcanza una longitud máxima de 9.5 mm y una mínima de 6.0 mm; de ancho mide entre 1.5 y 4.0 mm (Figueroa, 1985).

El color del grano está influenciado por el intemperismo o por la coloración de la aleurona, por lo que puede variar desde amarillo claro, amarillo pálido, crema claro, crema pálido, azul verdoso hasta azul (Figueroa, 1985).

Algunas variedades de cebada pueden presentar una coloración negra o roja en las glumas, pero todas las cebadas cerveceras carecen de estas coloraciones. Por eso, suelen usarse como marcadores de cebada forrajera para evitar mezclas con las destinadas a la cervecería. La aleurona puede también tener diversas coloraciones.

2.3 Evaluación de la cebada para malteo

La evaluación de la calidad de cebada maltera se realiza por inspección visual, lo cual requiere de experiencia y muchas veces es decisiva para la aceptación o rechazo de un lote. En esta observación se consideran aspectos de color, olor, homogeneidad, brillo y calidad de la cubierta del grano, además se evalúa la cantidad de granos quebrados y la pureza que es la ausencia de semillas de otros cultivos, de malezas y materia inerte. Los granos con infestación de plagas no se utilizan para malta. Otro factor considerado en la evaluación visual son defectos de los granos que en su mayoría son el resultado de condiciones meteorológicas adversas antes de la cosecha (Castillo, 2012). Muchos factores son los que influyen en la calidad del grano de cebada y por consiguiente en la calidad de la malta.

La cebada es comprada por la industria maltera acorde a estrictas especificaciones. Además de algunos aspectos relacionados al producto durante su cultivo como son infección por hongos, infestación por plagas, olor y manchas; la variedad, humedad, tamaño y contenido de proteína del grano son factores, que tienen relación directa con la calidad de la malta como se establece en la norma mexicana NMX-FF-043-SCFI-2003.

2.3.1 Norma que rige la calidad de la cebada maltera en México

Se puede definir la calidad comercial de cebada cervecera de acuerdo a ciertas normas que establecen las características cualitativas y cuantitativas que deben presentar los granos de cebada destinados a la maltería. Estas normas varían en los diferentes países, reguladas en la mayor parte de los casos por decretos gubernamentales que fijan los tipos, con sus límites y tolerancias para porcentaje de proteína, semillas de malezas, pureza varietal, granos quebrados, brotados, descascarados, porcentaje inferior a la zaranda 2.2 mm (Arias, 1991).

La norma mexicana NMX-FF-043-SCFI-2003, establece las condiciones y características del grano de cebada maltera género *Hordeum* especies *vulgare* L. y *distichum* L. para poder ser objeto de comercialización en territorio nacional. La cebada deberá cumplir con ciertos parámetros y especificaciones de calidad para ser clasificada como “Grado México” que es adecuada para el proceso de malteo, en caso contrario si alguna de las variedades no cumpliera con los requisitos sería llamada “Grado México no clasificado”. Tomándose los siguientes parámetros y especificaciones de la norma para su clasificación (Cuadro 2):

Cuadro 2. Parámetros y especificaciones de calidad en cebada maltera.

Parámetro	Especificaciones
Humedad entre 11.5% y 13.5%	Germinación mínima de 85%
Grano de tamaño para uso maltero 85%	Grano dañado máximo 10%.
Granos desnudos y/o quebrados 5.0%	Mezcla de otras variedades máximo 10%.
Impurezas 2.0%	Peso hectolitrico (mínimo): Cebada de seis hileras: 56 kg/hL Cebada de dos hileras: 58 kg/hL Olor: Característico del grano, sin olores extraños Residuos tóxicos: sin residuos Contaminantes o toxinas: sin contaminación evidentes

Fuente: Norma Mexicana NMX-FF-043-SCFI-2003.

2.3.2 Método para la determinación de impurezas

Las impurezas que normalmente se encuentran en los granos de cebada son fragmentos provenientes de la propia planta, como hojas, trozos de granos, ramas y pajas. Asimismo, existen otras impurezas que no provienen de la propia

planta, a las cuales se les denomina materias extrañas y que generalmente están constituidas por semillas silvestres, parte de otras plantas, además de terrones, arena y piedras. Las impurezas presentes en los productos agrícolas son consecuencia del descuido durante el cultivo, principalmente en el control de malezas, y de los métodos utilizados para la cosecha. Con un poco de cuidado durante la cosecha es posible evitar el corte de partes innecesarias de la planta, lo que disminuye la cantidad de impurezas en el producto cosechado.

Cuando el contenido de impurezas es alto no permite un buen manejo del grano tanto en almacenamiento, como en el germinado; el porcentaje de germinación determina cuánto grano podrá ser convertido en malta esto también, se aplica para el porcentaje de granos dañados, ya que de éstos depende la cantidad de malta obtenida (Hernández, 2005). La norma mexicana presenta una tabla de ajustes para bonificaciones y deducciones por impurezas en las muestras de cebada como se muestra en el Cuadro 3.

Cuadro 3. Ajustes por impurezas en el grano.

BONIFICACIONES		DEDUCCIONES	
%	Kg/ton	%	Kg/ton
0.0	20	2.5	5
0.5	15	3.0	10
1.0	10	3.5	15
1.5	5	4.0	20
2.0	0	4.5	25
		5.0	30
		5.5	35
		6.0	40

Fuente: Norma Mexicana NMX-FF-043-SCFI-2003.

El método establecido por la norma NMX-FF-043-SCFI-2003 para la determinación del contenido de impurezas en cebada consiste en la separación y cuantificación de impurezas que pasan a través de una criba de orificios oblongos de dimensiones 1.79 x 13 mm (4.5/64 x ½ in), así como todo aquel material que no haya atravesado la criba y sea diferente al grano de cebada.

Los instrumentos que se incluyen para realizar esta prueba son: una balanza granataria con precisión de 0.1 g, una balanza con precisión de 0.001 g, una criba con orificios oblongos de 1.79 x 13 mm (4.5/64 x ½ in), y una charola.

Para su determinación se pesan 100 g ($\pm$ 0.1 g) de muestra homogeneizada y luego se criban con un movimiento giratorio y se separan con la mano las impurezas que hayan quedado sobre la criba. Una vez que se termina de cribar el grano, las impurezas y el grano delgado de cebada que pasaron la criba se separan con la mano y, solamente, las impurezas que pasaron la criba se juntan con las impurezas grandes que se separaron anteriormente quedando el grano de cebada libre de todos los materiales extraños (impurezas).

Si no se cuenta con cribas apropiadas, se puede vaciar la muestra sobre una superficie limpia y separar manualmente las impurezas.

Junto con los residuos vegetales y basuras, también se retiran las semillas pequeñas de otros cultivos que pasaron la criba y se recogieron en la bandeja de fondo, además de los terrones que se pueden localizar sobre la malla. Enseguida se pesa todo el material extraño tomando la lectura en gramos, la cual es equivalente al contenido de impurezas en porcentaje, con aproximación de hasta un decimal.

Es evidente que este método consume mucho tiempo, además de que un análisis manual de los granos es propenso a problemas como estar influenciado

por factores humanos y las condiciones de trabajo (Zhang *et al.*, 2005). Por lo tanto, se necesitan métodos alternativos para evaluar la calidad y la variedad de los granos de cebada.

2.4 Métodos para el análisis de muestras en la recepción de granos de cereales

El análisis de los granos de cereales para su recepción se basa en un muestreo al azar de los lotes. Las características físicas, así como la composición química y las propiedades funcionales de los componentes definen la calidad de los granos de cereales. Se tienen diferentes grados de calidad para el caso de los cereales por lo que no siempre se buscarán los mismos atributos de un lote de granos, dado que no siempre se destinarán a un mismo uso. Por lo tanto, se necesita analizar la calidad de un lote que permite especificar algunas características de cada grano en la muestra analizada, así como las condiciones generales de todo el lote. Se analiza el tipo, color, tamaño y forma de cada grano, además se analizan otros aspectos como la presencia de materiales extraños, infestaciones, presencia de sustancias u olores indeseables, el contenido de agua y peso hectolítrico. Todos estos aspectos a analizar se evalúan a partir de una pequeña muestra representativa tomada del lote.

Para realizar el análisis físico de los granos de cereales y su clasificación el procedimiento estándar, en general se inicia con la recepción y registro de la muestra al laboratorio, donde se pesa y se realiza el análisis organoléptico y de infestación del grano observándose sus características visuales, olores posibles y la posible presencia de insectos. Después la muestra se agita para obtener un buen mezclado u homogenización de los granos e impurezas.

La determinación de impurezas de la muestra es la primera prueba que se lleva a cabo, y para realizar el muestreo se utiliza el procedimiento mencionado

en la sección 2.3.2. El grano se separa de las impurezas haciéndolo pasar sobre cribas vibratorias o giratorias o en cribas de gravedad que además clasifican al grano por tamaños. Dependiendo del ancho y espesor del grano se pueden separar con zarandas con perforaciones redondas u oblongas y para la separación por longitud se utilizan cilindros alveolados.

Se determina después el peso hectolitro y humedad del grano de acuerdo a normas establecidas para cada cereal. Con los resultados del análisis se determinará si los granos deberán secarse y qué máquinas se usarán para remover los contaminantes y la secuencia de operaciones que el lote seguirá en la planta.

Otros métodos usados para el análisis y clasificación de granos se muestran a continuación.

2.4.1 Electroforesis de proteínas

La electroforesis es un método en el que se separan biomoléculas, en dependencia entre otros factores de su carga y bajo la acción de un campo eléctrico, fue empleado por primera vez por Tiselius en el año 1937. La electroforesis es la migración de solutos iónicos bajo la influencia de un campo eléctrico; Estas partículas migran hacia el cátodo o ánodo (electrodos - y +), en dependencia de una combinación de su carga, peso molecular y estructura tridimensional (Pérez, 2000).

La electroforesis de proteínas es la tecnología usada para determinar la pureza varietal en trigo en México. Los perfiles de bandas de proteínas del grano (separadas por electroforesis) de una variedad se consideran como las “huellas” o “perfiles de identidad” de una variedad. Los perfiles de identidad permiten saber

si la variedad de trigo analizada corresponde a la variedad declarada y si es pura o está mezclada con dos o más variedades distintas (Peña et. al, 2008).

Las desventajas que presenta este método es claro: el análisis demanda mucho tiempo, es un método destructivo del grano y sólo está disponible en laboratorios especializados.

2.4.2 Espectroscopia de infrarrojo cercano (NIR)

La técnica de espectroscopia de infrarrojo cercano o espectroscopia NIR permite obtener propiedades como la humedad, la cantidad de proteínas y contenido en aceite del grano, detección de carbohidratos complejos y más recientemente la predicción de las propiedades funcionales de los granos. Entre las ventajas que presenta esta técnica frente al análisis químico se encuentra que el tiempo de análisis es menor, brinda una medición no destructiva, no invasiva y no es necesario el uso de técnicas adicionales para obtener los resultados (Sevillano, 2015).

La espectroscopia NIR está basada en la medida de la intensidad de la reflectancia, o de la transmisión, de la radiación de una muestra en la región del infrarrojo cercano del espectro electromagnético (800-2500 nm). Estos parámetros van a depender de la absorbancia de la muestra que, a su vez, dependen principalmente de los enlaces de hidrógeno que ésta presente.

Esta técnica precisa modelos de calibración para poder determinar la composición de la muestra analizada. Para esto se utilizan espectrofotómetros los cuales constan de una fuente luminosa que normalmente es una lámpara de tungsteno, esta luz atraviesa una serie de filtros y rendijas que permiten obtener la longitud de onda deseada. Una vez se tiene la luz con una longitud de onda concreta esta atravesará la muestra, que está colocada en un porta-muestras, y

por último se colocarán los detectores de reflectancia y transmitancia adecuados (Figura 2). Finalmente, para procesar la información obtenida se dispondrá de tarjetas amplificadoras, convertidores analógico-digitales, así como de un computador y un software específico.




Figura 2. Esquema de instrumentación de un espectrofotómetro NIR.

Este tipo de tecnología ya se encuentra en el mercado y se ha utilizado en los almacenes de recepción para analizar granos de trigo, trigo duro, cebada, maíz, avena, centeno, triticale, sorgo/mijo, arroz paddy, semillas oleaginosas y legumbres para medir porcentajes de humedad, proteínas, aceite del grano y peso específico. Los equipos fabricados por Infratec™ son un ejemplo de analizadores de grano.

La desventaja que presenta esta tecnología es que el instrumento debe ser capacitado para reconocer diferentes productos y elementos, para esto un número de muestras son analizadas por métodos químico-analíticos tradicionales para determinar la composición real de las muestras. Cada una de éstas es colocada luego en el instrumento NIR, y se obtienen los valores de reflectancia de las diferentes longitudes de onda.

2.4.3 Visión por computadora

La visión artificial, o también denominada visión por computadora, es considerada una rama de la inteligencia artificial y su principal propósito es que las máquinas sean capaces de interpretar el entorno que las rodea tal y como lo hacen los seres humanos mediante el sentido de la vista (Sevillano, 2015).

Un sistema de visión por computadora actualmente comprende tanto la obtención como la caracterización e interpretación de las imágenes. En un sistema de visión por computadora actual se pueden distinguir seis etapas o fases (Figura 3):




Figura 3. Etapas fundamentales de un sistema de visión artificial (adaptado de González y Woods, 2007).

Adquisición de la imagen: Es el proceso a través del cual se obtiene una imagen. Para ello se necesitan sensores y la capacidad para digitalizar la señal producida por el sensor. Esto se hace por medio de un sensor y si es el caso, un sistema digitalizador. El sensor puede ser una cámara fotográfica o de video. Si la señal producida por la cámara es análoga entonces se utiliza un convertidor análogo digital para digitalizarla y guardarla en la computadora. El sistema de adquisición comprende además de la cámara un equipo de iluminación y un fondo. Para obtener una buena imagen, es necesario poseer una iluminación adecuada. Una iluminación inapropiada conlleva a la alteración de las

características del objeto en la imagen. El fondo permite controlar el ambiente procurando realzar el objeto de interés aislándolo de los otros objetos presentes en el entorno.

Preprocesamiento: El preprocesamiento es el conjunto de técnicas que se aplican a las imágenes digitales con el objetivo de mejorar la calidad informativa de la imagen adquirida, y transformarla para conseguir una manera más adecuada de interpretar la información que en ella se refleja (Vargas, 2010). Incluye técnicas tales como la reducción de ruido y realce de detalles. Los procesos utilizados para el tratamiento de imágenes que pretenden reparar en la imagen desperfectos producidos o no eliminados por el dispositivo de adquisición se describen a continuación (Betancourt, 2014). El primer proceso que se realiza es el cambio de formato y transformación de la imagen a escala de grises, con esto se busca trabajar con una sola matriz de información. Ya que eso resulta mucho más conveniente a la hora de manipular información contenida en la imagen. Otro proceso importante en esta fase es la binarización que transforma la imagen en escala de grises, a una imagen de blanco y negro (unos y ceros) mediante una comparación o umbral. Este umbral define el valor límite del píxel siendo negro si está por debajo de este umbral o blanco si está por encima.

Segmentación: Es el proceso que divide a una imagen de entrada en sus partes constituyentes u objetos. La salida dará como resultado datos del píxel en bruto, que conformarán el contorno de una región o bien todos los puntos de una región determinada. Los bordes de una imagen digital se pueden definir como transiciones entre dos regiones de niveles de gris significativamente distintos. Suministran información importante sobre las fronteras de los objetos y puede ser utilizada para segmentar la imagen. Una vez segmentada la imagen se pueden colocar etiquetas que identifiquen la región en particular, este normalmente se basa en colores, colocando un color diferente a cada región segmentada.

Descripción: Es el proceso mediante el cual se obtienen características convenientes para diferenciar un tipo de objeto de otro, por ejemplo, tamaño y forma. En este proceso se toman los elementos etiquetados y se extraen las características de cada uno. Estas características dependen del número de píxeles conectados y la forma en que están conectados como, forma geométrica, solidez y huecos. Estos valores son cuantificados y pueden ser usados con fines discriminativos.

Reconocimiento: Es el proceso que identifica a los objetos de una escena, es decir, asigna una etiqueta a un objeto basado en la información que proporcionan los descriptores. En esta fase se efectúa el reconocimiento de patrones cuyo objetivo es la clasificación de objetos en un cierto número de categorías o clases (Calot, 2008). El reconocimiento de patrones puede realizarse mediante el análisis de la morfología (forma y tamaño), color, textura (distribución espacial de color), o una combinación de estas características de las imágenes (Jayas *et al.* 2000).

Interpretación: Es el proceso que asocia un significado a un conjunto de objetos reconocidos.

La clasificación de productos agrícolas mediante visión por computadora en combinación con técnicas de reconocimiento de patrones tiene muchas ventajas sobre los dispositivos de clasificación mecánica convencionales como facilitar una valoración, objetiva y no destructiva, de la calidad en los productos con un amplio futuro en la industria alimentaria (Sánchez, 2004).

En el siguiente apartado se mencionan los avances con respecto a la clasificación de cereales utilizando visión por computadora.

2.4.3.1 Visión por computadora en la clasificación de cereales

Los procesos de poscosecha se han beneficiado enormemente de las técnicas de visión artificial, ya que permiten inspeccionar la calidad de los productos de manera individual, estimando automáticamente sus características. Los requerimientos de calidad del cereal difieren con respecto al usuario final, es por esto, que el procedimiento de clasificación visual actual es exigente, incluso para los inspectores capacitados debido a la amplia variación en las características visuales causadas por contraste de clase, variedad y los efectos ambientales (Brosnan y Sun, 2004; Sánchez, 2004).

Dentro de la comercialización, el manejo eficiente, transporte, procesamiento, tratamiento y almacenamiento de los granos de cereales la clasificación es importante. En el Cuadro 4 se presenta un resumen de investigaciones recientes en la clasificación de cereales con visión por computadora.

Cuadro 4. Aplicaciones de visión por computadora en la clasificación de cereales.

Producto	Aplicación	Técnica implementada	Precisión de clasificación	Referencia
Trigo	Clasificación de 17 variedades de trigo.	Análisis de morfometría con visión por computadora y análisis de dureza del grano.	94%	Zayas <i>et al.</i> (1996).
Dos variedades de trigo, cebada, avena y centeno	Clasificación de diferentes granos de cereales, usando 23 características morfológicas.	Visión por computadora	98, 91, 97,100 y 91%, respectivamente.	Majumdar <i>et al.</i> (1997).
Trigo	Clasificación de trigo sano, roto, mohoso y manchado. Se combinaron características	Visión por computadora y algoritmo del vecino más cercano	93, 90, 99 y 99%, respectivamente.	Luo <i>et al.</i> (1999).

	morfológicas y de color.			
Dos variedades de trigo, cebada, avena y centeno	Clasificación de granos. Utilizaron características morfológicas y de color.	Visión por computadora y redes neuronales artificiales.	99.3, 96.7, 98.7, 98.4, y 96.9%, respectivamente.	Visen <i>et al.</i> (2002).
Dos variedades de trigo, cebada, avena y centeno	Clasificación de granos con un total de 230 características. Las redes neuronales superaron al otro clasificador.	Se comparó una red neuronal artificial de retropropagación y un clasificador estadístico no paramétrico	96%	Paliwal <i>et al.</i> (2003).
Dos variedades de trigo, cebada, avena y centeno	Clasificación de granos de cereales. Utilizaron ocho características morfológicas.	Visión por computadora y redes neuronales artificiales.	97, 97, 88, 97 y 88%, respectivamente.	Paliwal <i>et al.</i> (2004).
Dos variedades de trigo, cebada y avena	Clasificación de granos de cereales.	Algoritmo de ajuste de elipse para separar granos que aparecían juntos en la imagen y una red neuronal artificial.	97.3, 96.1, 92.4 y 94.8%, respectivamente.	Zhang <i>et al.</i> (2005).
Dos variedades de trigo, cebada, avena y centeno	Clasificación de granos de cereales. Se utilizaron 51 características morfológicas, 93 de color, 56 de texturales y 135 funciones wavelet.	Clasificador discriminante lineal.	99.4, 89.4, 98.6, 98.5 y 99.3%, respectivamente.	Choudhary <i>et al.</i> (2008).
Trigo duro, trigo y cebada tierna	Clasificación de granos de cereales utilizando características morfológicas, de color y wavelets.	Clasificador estadístico, lógica difusa y redes neuronales artificiales.	Clasificación estadística: 76%. Técnicas de lógica difusa: 85.7%. Redes neuronales artificiales: 98%.	Douik y Abdellaoui (2010).
Trigo	Clasificación de 11 variedades de trigo. Se calcularon 42	Análisis discriminante y redes neuronales artificiales.	100%	Zapotoczny (2011).

	características de textura.			
Arroz	Clasificación de diferentes variedades de arroz en tres clases de granos: grandes medianos y pequeños. Se usó el área y eje mayor del grano.	Redes neuronales artificiales.	100%	Lilhare <i>et al.</i> (2012).
Trigo	Clasificación de nueve variedades de trigo iraní, se evaluaron seis grupos de características texturales.	Análisis discriminante lineal.	98.1%	Pourreza <i>et al.</i> (2012).
Dos variedades de trigo, cebada, avena y centeno	Clasificación de granos de cereales. Se calcularon características morfológicas, de color y descriptores elípticos de Fourier.	Se usó un clasificador de mínimos cuadrados.	100, 99.9, 98.5, 99.9 y 100%, respectivamente.	Mebatsion <i>et al.</i> (2013).
Arroz	Clasificación de nueve variedades de arroz, se extrajeron características morfológicas, texturales y de color.	Se desarrollaron diferentes modelos de redes neuronales artificiales.	92%	Silva y Sonnadara (2013).
Trigo, impurezas y semillas de maleza	Clasificación de trigo e impurezas. Se determinó la pureza de trigo.	Algoritmo imperialista competitivo combinado con redes neuronales artificiales.	96.2, 87.5 y 77.2%, respectivamente.	Ebrahimi <i>et al.</i> (2014).
Arroz	Clasificación de cinco variedades de arroz con muestras de granos a granel, utilizando 36 características de color en RGB, HSI y HSV.	Redes neuronales artificiales.	98.8%	Golpour <i>et al.</i> (2014).

Maíz	Clasificación de granos buenos y dañados.	Análisis de componentes principales para clasificar.	92%	Valiente-Gonzalez <i>et al.</i> (2014).
Trigo	Clasificación de 40 clases de trigo. Se aplicó el algoritmo de detección de características invariante.	Método de agrupamiento K-means y algoritmos de máquinas de soporte vectorial.	88.3%	Olgun <i>et al.</i> (2016).

2.4.3.2 Visión por computadora en la clasificación de variedades de cebada

Recientemente, varios investigadores han evaluado las capacidades de procesamiento de imágenes y algoritmos de clasificación para la clasificación de variedades de cebada. Zapotoczny *et al.* (2008) clasifican cinco variedades de granos de cebada de Polonia usando análisis discriminante lineal dando una precisión del clasificador de 94.94%. Se seleccionaron 30 características morfológicas de un total de 74 características extraídas de los granos de cebada. Zapotoczny en 2012 clasifica cinco variedades de cebada polaca de dos hileras con muestras a granel usando 270 características texturales, se usó análisis discriminante obteniendo una precisión de clasificación de 99%. En otro estudio Szczypiński y Zapotoczny (2012) presentan un algoritmo que identifica el tamaño de las regiones lisas y arrugas en el lado ventral y dorsal de granos individuales de 11 variedades de granos de cebada. La validación del algoritmo confirmó que es eficiente y robusto permitiendo la descripción precisa de 93% de las muestras de los granos. Szczypiński *et al.* (2015) demostraron que el clasificador con redes neuronales es superior al clasificador lineal. Se analizaron once variedades de cebada. En este estudio se reconoce correctamente el 86% de los granos de cebada en el mejor de los casos y el 67% de los granos en el peor de los casos. Las imágenes digitales de los granos en estos estudios se obtuvieron a partir de un escáner óptico. Sin embargo, ninguno de los estudios citados ha empleado

cebada de seis hileras, que tiene la desventaja que dos de los tres granos que constituyen la espiguilla son asimétricos; en cambio en cebada de dos hileras se desarrollan sólo granos anchos y simétricos. Además, a la fecha no hay datos reportados para identificar granos de cebada de material extraño como impurezas, así como para clasificar variedades de granos de cebada y contabilizar las impurezas de forma simultánea.

La tecnología de visión artificial proporciona una alternativa a la inspección manual de muestras de grano (Visen *et al.*, 2004). Este método es una tecnología prometedora para la rápida identificación y automatización en el manejo de granos. La medición y la extracción de características de color, textura, forma y tamaño de los granos y objetos extraños en una muestra de cebada utilizando un sistema de visión artificial ofrece una solución potencial a considerar.

Capítulo 3. MATERIALES Y MÉTODOS

3.1 Material de estudio

En México la industria maltera se centra principalmente en cinco variedades de granos de cebada maltera (*Hordeum vulgare* L.): Adabella, Alina, Armida, Esmeralda y Esperanza, las cuales fueron utilizadas en esta investigación y fueron producidas durante el ciclo otoño–invierno del 2014 en el Campo Experimental Valle de México, en Chapingo, México; por el Programa de Cebada Maltera. Todas estas variedades cumplen con los requerimientos de calidad maltera aceptados por la industria nacional.

3.2 Sistema de adquisición de imágenes

En el sistema de adquisición de imágenes se usó una cámara web Logitech C920 y una computadora Lenovo 10A2A01100. Esta computadora dispone de un procesador Intel Core™ i5 de 3.33 GHz, 8 GB de memoria RAM con sistema operativo de Windows 10 Pro. Las imágenes se tomaron en un área completamente iluminada con fuentes de luz a su alrededor. Esto se hizo para evitar en las imágenes sombras y brillos. Las sombras aparecían cuando había una ubicación errónea de las fuentes de iluminación (Figura 4a), o también resultaban de una iluminación parcial producida por la insuficiencia de luz (Figura 4b), se presentaban brillos cuando la luz incidente sobre el objeto era muy directa (Figura 4c). También se incluyó una fuente de contraluz para resaltar los contornos de los granos de cebada e impurezas. La zona con iluminación difusa resultante es de 30x30x20 cm y la distancia entre la lente de la cámara y los granos es de 80 mm perpendicular al área de muestra como se observa en la Figura 5. Todas las cajas de luz (Figura 6) llevan en su interior una lámpara

fluorescente de luz blanca de 390 lm y el material para difuminar la luz es papel bond blanco.



Figura 4. Efectos de sombra en la imagen.




Figura 5. Esquema del sistema de adquisición de imágenes.




Figura 6. Cajas de luz para la iluminación del área a fotografiar.

El proceso efectuado para el reconocimiento automático de los granos de cebada e impurezas se ilustra en la Figura 7.



Figura 7. Proceso para reconocimiento automático de granos de cebada e impurezas.

3.2.1 Adquisición de imágenes

Se tomó una muestra aleatoria de 400 granos por variedad y cada muestra se dividió en diez partes iguales de 40 granos de cebada, de las cuales se tomó una imagen cuidando que cada grano estuviera completo y aislado de los demás. No se permitió truncamiento de granos por no estar dentro del área de la imagen, ni traslapes entre ellos. Esto resultó en 10 imágenes por variedad. En la submuestra número seis de cada variedad se capturaron seis imágenes, incluyendo en cada una cinco diferentes impurezas como pedazos de granos de cebada, piedras y semillas de malezas. Estas imágenes se utilizaron para la evaluación del algoritmo. Además, se capturaron ocho imágenes con 40 impurezas en cada una para el entrenamiento del clasificador. Los granos e impurezas se colocaron en cualquier posición y rotación dentro de la imagen. Para evaluar la capacidad del clasificador detectando porcentajes de granos de las cinco variedades en una sola imagen se tomaron siete imágenes, cuyo porcentaje de granos de cada variedad se conoce con anticipación.

Las imágenes tomadas tienen una resolución de 640x480 píxeles, ya que por lo general una cámara web utiliza esta resolución y para guardarlas se usó el formato JPG (Joint Photographic Experts Group).

Las instrucciones fueron implementadas en MATLAB (The MathWorks, Inc., Nattick, MA, USA). Se emplearon las herramientas de adquisición y procesamiento de imágenes y redes neuronales de Matlab. La caja de herramientas de procesamiento de imágenes contiene un conjunto de funciones de los algoritmos más conocidos para trabajar con imágenes binarias, transformaciones geométricas, morfología y manipulación de color que junto con las funciones ya integradas en MATLAB permiten realizar análisis y transformaciones de imágenes. El programa principal se encuentra en el Anexo 1.

3.2.2 Calibración de la cámara

La calibración de la cámara es el proceso de estimación de los parámetros intrínsecos de la misma los cuales modelan la geometría interna de la cámara y las características ópticas del sensor. Los parámetros extrínsecos miden la posición y la orientación de la cámara respecto al sistema de coordenadas establecido para la escena. Estos dan la relación respecto al sistema de coordenadas del usuario en lugar del sistema de coordenadas de la cámara. El proceso de calibración de la cámara, es necesario para poder extraer información métrica a partir de imágenes en 2D del mundo 3D. La calibración se realizó secuencialmente con una serie de pasos (Figura 8). Para su implementación se usó el programa '*Single Camera Calibration*' integrado en la herramienta de visión por computadora de Matlab en cuyo método se utilizó una plantilla para establecer una relación entre las coordenadas conocidas de los puntos en la plantilla y sus correspondientes coordenadas en la imagen.




Figura 8. Proceso para la calibración de la cámara.

Como patrón de calibración se utilizó una plantilla bidimensional con forma de tablero de ajedrez de 5x7 cuadros de 10x10 mm (Figura 9), de modo que se dispone de un total de 48 esquinas internas (los cuadros incompletos de la orilla son excluidos al momento de detectar el patrón).

Se capturaron 17 imágenes del patrón de calibración, el cual se colocó en diferentes posiciones y orientaciones y a la misma distancia de la cámara que las muestras de cebada; lo que se recomienda es utilizar entre 10 y 20 imágenes para la calibración exacta.




Figura 9. Patrón de calibración.

La primera instrucción del programa es cargar el conjunto de imágenes capturadas especificando la dirección de la carpeta donde se guardaron. Después, para cada imagen capturada, el programa localiza de forma automática las esquinas internas del patrón de calibración y genera las coordenadas globales en mm con la esquina superior izquierda del patrón en (0, 0).

Como tercer paso se realiza la calibración de la cámara web obteniendo sus parámetros intrínsecos y extrínsecos. Los parámetros intrínsecos incluyen la distancia focal horizontal (f_x), y vertical (f_y), las coordenadas del centro óptico (u_0, v_0) y las distorsiones de la lente (radial: k y longitudinal: p). Los parámetros extrínsecos hacen referencia a la colocación física de la cámara que viene definida por la posición y orientación de esta respecto al sistema global de coordenadas. Se toma el criterio de que primero ha habido una traslación de la cámara, T , seguida de una rotación, R .

Los parámetros extrínsecos y la proyección de la imagen, U , de un punto en el espacio X , asumiendo que el plano del modelo es bidimensional y por lo

tanto $Z = 0$ en el sistema de coordenadas del mundo real. Entonces se puede representar mediante la expresión matricial:

$$U = PX = K[RT]X$$

$$\begin{pmatrix} u \\ v \\ s \end{pmatrix} = \begin{pmatrix} f_u & 0 & u_o \\ 0 & f_v & v_o \\ 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} r_{00} & r_{01} & r_{02} & t_x \\ r_{10} & r_{11} & r_{12} & t_y \\ r_{20} & r_{21} & r_{22} & 1 \end{pmatrix} \begin{pmatrix} X \\ Y \\ 1 \end{pmatrix} \quad (1)$$

Donde K indica los parámetros intrínsecos de la cámara. R es una matriz de rotación 3×3 ; T es un vector de traslación de la cámara en el sistema coordinado del mundo real; (u, v) son las coordenadas de los píxeles (plano imagen) del punto en el espacio X , y s es un factor de escala arbitrario.

Respecto a la distorsión, se sigue la fórmula (Zhang, 2000):

$$\begin{aligned} x_r &= x_i + x_i(k_1 r^2 + k_2 r^4) + 2p_1 x_i y_i + p_2(r^2 + 2x_i^2) \\ y_r &= y_i + y_i(k_1 r^2 + k_2 r^4) + 2p_2 x_i y_i + p_1(r^2 + 2y_i^2) \end{aligned} \quad (2)$$

Siendo (x_r, y_r) las coordenadas reales de los píxeles, (x_i, y_i) las coordenadas ideales y r la distancia al centro óptico de la cámara.

Para obtener los parámetros intrínsecos y extrínsecos se utilizó el algoritmo de calibración propuesto por Zhang (2000) el cual se obtiene para cada una de las 17 imágenes analizadas una homografía o matriz de proyección H resolviendo la siguiente expresión:

$$\begin{pmatrix} p_i^T & 0 & -u_i q_i^T \\ 0 & p_i^T & -v_i q_i^T \end{pmatrix} h = 0 \quad (3)$$

donde $q_i = (u_i, v_i, h_i)$ representa las coordenadas homogéneas en la imagen de un punto en la escena $p_i = (x_i, y_i)$.

Se calcularon $n = 17$ homografías a partir de 17 imágenes capturadas de la plantilla, se obtiene entonces un sistema de ecuaciones de la forma $V'b=0$, donde

$\mathbf{V}$ es una matriz de dimensiones $2n \times 6$, formada por los elementos de las homografías de la siguiente forma:

$$\mathbf{v}_{ij}^T = [h_{i1}h_{j1} \quad h_{i1}h_{j2} + h_{i2}h_{j1} \quad h_{i2}h_{j2} \quad h_{i3}h_{j1} + h_{i1}h_{j3} \quad h_{i3}h_{j2} + h_{i2}h_{j3} \quad h_{i3}h_{j3}] \quad (4)$$

Si $n \geq 3$ se tiene una solución general con solución única de $\mathbf{b}$ definida con un factor de escala. La solución del vector $\mathbf{b} = [b_{11} \ b_{12} \ b_{22} \ b_{13} \ b_{23} \ b_{33}]^T$ es el vector propio de $\mathbf{V}^T \cdot \mathbf{V}$ asociado al valor propio más pequeño. A partir del vector estimado $\mathbf{b}$ se obtienen los parámetros intrínsecos de la cámara. Una vez conocidos los parámetros intrínsecos se calculan los extrínsecos a partir de cada homografía. Consultar Zhang (2000) y Ricolfe (2006) para más detalles.

Para la implementación del algoritmo de calibración propuesto por Zhang se utilizó la función ‘estimateCameraParameters’ integrada en las herramientas de visión por computadora de MATLAB.

Como cuarto paso se evaluó la precisión de la calibración examinando los errores de reproyección. La precisión de la calibración se indica con un gráfico de barras (Figura 10). Cada barra muestra la media del error de re-proyección de la imagen de calibración correspondiente. Los errores de reproyección son las distancias entre los puntos de las esquinas de los cuadrados detectados en la imagen, y los correspondientes puntos del tablero de ajedrez proyectados en la imagen. Como regla general, los errores de reproyección de menos de un píxel son aceptables (The MathWorks Inc., 2015); en este caso el error medio en general es de 0.49 píxeles. Esto quiere decir que en las mediciones reales se asume una tolerancia de $1 \text{ mm} \pm 0,06 \text{ mm}$ (Anexo 3). Los parámetros de calibración de la cámara fueron guardados en un objeto llamado *cameraParams*. Este objeto contiene los parámetros intrínsecos, extrínsecos y la distorsión de la lente de la cámara.




Figura 10. Error medio de reproyección por imagen.

3.3 Preprocesamiento de imágenes

La primera adecuación realizada a las imágenes fue la eliminación de los efectos de distorsión de la lente. Aplicando los parámetros intrínsecos, extrínsecos y las distorsiones de la lente de la cámara se implementó la función '*undistortImage*' que corrigió la distorsión en la imagen.

3.3.1 Segmentación

Como siguiente paso se separaron los objetos de interés (granos de cebada) insertados en la escena capturada. Para lograr la separación se convirtieron las imágenes RGB a escala de grises (Figura 12a y 12b). En la imagen a escala de grises es más evidente el alto contraste entre el fondo y el grano por lo que después se empleó el algoritmo de umbralización, puesto que hay una clara diferencia entre los objetos a extraer respecto del fondo de la escena.

En este caso los objetos son oscuros respecto del fondo por lo que se aplicó (García, 2008):

$$g(x, y) = \begin{cases} 0 & f(x, y) \leq T \\ 1 & f(x, y) > T \end{cases} \quad (5)$$

donde $f(x, y)$ es la función que define el nivel de gris del píxel (x, y) . $g(x, y)$ es la imagen binarizada y T es el umbral definido.

Se utilizó la técnica de umbralización fija ya que existe una clara diferencia entre los objetos a extraer respecto del fondo de la escena como lo muestra el histograma bimodal (Figura 11), que representa el número de píxeles que tienen el mismo brillo en función de la luminosidad. Por lo tanto, muestra dos máximos, uno en relación con las regiones de los granos de cebada y el otro relacionado con el fondo más brillante, con un mínimo en el medio, el cuál es el umbral.




Figura 11. Histograma de niveles de gris para una imagen analizada.

Para escoger un umbral óptimo se empleó el método propuesto por Otsu (1979) que es un algoritmo de elección de un umbral automático para un histograma bimodal. La descripción de este método para un umbral óptimo se detalla a continuación.

El número de píxeles con nivel de gris “ i ” se denota como “ f_i ”, y la probabilidad de ocurrencia del nivel de gris “ i ” en la imagen está dada por:

$$P_i = \frac{f_i}{N*M} \quad (6)$$

Donde $N*M$ es la cuenta total de píxeles correspondientes a las filas y columnas de la imagen.

Para la umbralización en dos niveles de la imagen, los píxeles son divididos en dos clases: $C1$ (granos de cebada), con niveles de gris $[1, \dots, T]$; y $C2$ (fondo de la imagen), con niveles de gris $[T+1, \dots, L]$, donde $L=255$. Entonces la distribución de probabilidad de los niveles de gris para las dos clases es:

$$C_1 = \frac{P_1}{w_1(T)}, \dots, \frac{P_T}{w_1(T)} \quad (7)$$

$$C_2 = \frac{P_{T+1}}{w_2(T)}, \frac{P_{T+2}}{w_2(T)}, \dots, \frac{P_L}{w_2(T)} \quad (8)$$

donde:

$$w_1(T) = \sum_{i=1}^T p_i \quad (9)$$

$$w_2(T) = \sum_{i=T+1}^L p_i \quad (10)$$

Y las medias para la clase $C1$ y para la clase $C2$ son:

$$\mu_1 = \sum_{i=1}^T \frac{i * p_i}{w_1(T)} \quad (11)$$

$$\mu_2 = \sum_{i=T+1}^L \frac{i * p_i}{w_2(T)} \quad (12)$$

Otsu (1979) definió la varianza entre clases de una imagen umbralizada como:

$$\sigma_B^2 = \varpi_1(\mu_1 - \mu_T)^2 + \varpi_2(\mu_2 - \mu_T)^2 \quad (13)$$

También verificó que el umbral óptimo T^* se elige de manera que σ_B^2 sea máxima:

$$T^* = \max_T \{\sigma_B^2(T)\} \quad \text{con } 1 \leq T \leq L \quad (14)$$

Se utilizó la función *graythresh(f)* disponible en MATLAB, que incluye el algoritmo descrito, donde f es la imagen en niveles de gris; disponible en MATLAB. Al aplicar un umbral, la imagen de niveles de grises se binarizó; etiquetando con '0' los píxeles correspondientes al objeto y con '1' aquellos que son del fondo (Figura 12c).




Figura 12. a) Imagen original, b) en escala de grises y c) binarizada.

3.3.2 Operaciones morfológicas

Se aplicaron operaciones morfológicas a las imágenes después de la segmentación para eliminar píxeles mal clasificados, bordes imprecisos de los objetos y algunas zonas de los granos donde los píxeles no se conectan de manera uniforme permitiendo espacios en el área del grano. Toda operación morfológica es el resultado de una o más operaciones de conjuntos (unión, intersección o complementación) haciendo intervenir dos conjuntos A, B, ambos subconjuntos de un conjunto espacio Z. De los dos subconjuntos, B recibe el

nombre de elemento estructurante que, para operar con A, se desplazará a través del espacio Z. El elemento estructurante fue de forma circular de radio igual a dos píxeles. Para esto primero se invirtieron los píxeles debido a que en la imagen binarizada se requiere que los objetos a procesar estén en blanco (1) y con fondo negro (0). Después se aplicó erosión binaria que consiste en eliminar los objetos de menor tamaño que el elemento estructurante (Figura 13a), es decir, dada una imagen A (granos de cebada), y un elemento estructurante B, (ambas imágenes binarias con fondo negro), la erosión de una imagen, A, por un elemento estructural, B, es el conjunto de todos los elementos x para los cuales B trasladado por x está contenido en A:

$$A \ominus B = \{x | B_x \subseteq A\} \quad (15)$$

Teniendo en cuenta que, para la condición $B_x \subseteq A$, sólo se consideran los píxeles blancos de A y B.

Sin embargo, esto presenta el inconveniente de que el tamaño de los granos disminuye. Este efecto se corrige con la aplicación de reconstrucción por dilatación, en la cual dada una imagen A y un elemento estructurante B, la dilatación de A por B se define como:

$$A \oplus B = \{x | (B^c)_x \cap A \neq \emptyset\} \quad (16)$$

El efecto conseguido es la preservación de las formas de los objetos que han superado al elemento estructurante (Figura 13b).




Figura 13. Aplicación de operaciones morfológicas. a) Erosión binaria, b) Dilatación binaria y c) Clausura.

Para la eliminación de pequeños agujeros (puntos negros) en el grano se aplicó la operación morfológica “clausura”, la cual se define como:

$$A \bullet B = (A \oplus B) \ominus B \quad (17)$$

Establece que la clausura de A por un elemento estructurante B es la dilatación de A por B, seguido de la erosión del resultado por B. Se observa en la Figura 13c el resultado de esta operación.

3.3.3 Etiquetado de los granos en la imagen

Una vez identificadas las regiones en la imagen que representan granos de cebada o impurezas, se etiquetaron para identificarlas de forma individual. Para identificar los píxeles que pertenecen a cada una de las regiones se obtuvieron los componentes conexos presentes en la imagen. La definición de un componente conexo depende del tipo de adyacencia utilizado, para esta

investigación se utilizó la 8-adyacencia. Esto es si un píxel $P = (x, y)$ de la imagen tiene 2 vecinos horizontales (este y oeste) y 2 verticales (norte y sur). Las coordenadas de estos píxeles son $(x+1, y)$, $(x-1, y)$, $(x, y+1)$ y $(x, y-1)$. Este conjunto de píxeles son los 4-vecinos $\mathcal{N}_4(P)$ de (x, y) . Los 4 vecinos situados en las diagonales $\mathcal{N}_d(P)$ están en las coordenadas $(x-1, y-1)$, $(x-1, y+1)$, $(x+1, y-1)$ y $(x+1, y+1)$. El conjunto $\mathcal{N}_4(P) \cup \mathcal{N}_d(P)$ formado por la unión de los anteriores constituye la 8-vecindad $\mathcal{N}_8(P)$ del píxel (x, y) . Dos píxeles son adyacentes si son vecinos (por ejemplo, $\mathcal{N}_4(P)$, $\mathcal{N}_8(P)$) y si sus valores satisfacen algún criterio específico de similitud, típicamente la igualdad. Sea $\mathcal{V}$ el conjunto de valores de los píxeles usados para definir la similitud: por ejemplo, los píxeles que tras una binarización tienen el valor 1, tienen a 1 como valor de similitud, $\mathcal{V} = \{1\}$. Entonces la 8-adyacencia existe si 2 píxeles $P = (x, y)$ y $Q = (w, z)$ con $l(x, y)$ e $l(w, z) \in \mathcal{V}$, son 8-adyacentes si $P \in \mathcal{N}_8(Q)$ (Kong y Rosenfeld, 1989).

Para realizar el etiquetado se implementó la función '*bwlabel*' la cual utiliza el algoritmo propuesto por Haralick y Shapiro (1993), el cual se describe a continuación:

- a) Analizar y barrer fila por fila la imagen binaria. Al encontrarse el primer píxel-1 asignar un valor nuevo de etiqueta.
- b) Si se encuentran más píxeles-1 en la misma fila, y estos no son 8-adyacentes al píxel al que ya se le asignó un valor de etiqueta, se le asignará una nueva etiqueta, en caso contrario se le asignará el mismo valor de etiqueta del píxel adyacente.
- c) Si se suscitara el caso de que al píxel (A) al que se le asignará un valor de etiqueta es adyacente a dos o más píxeles que ya poseen un valor de etiqueta y éstas son distintas, se le asignará el valor de etiqueta menor a ese píxel dentro de esa vecindad.

- d) Cuando se presenta el paso (c), se guardará dentro de una tabla de equivalencia todas las etiquetas que resultaron ser adyacentes al píxel A; ya que esto representa que todas éstas etiquetas que inicialmente fueron clasificadas como distintas en realidad son la misma clase de etiqueta, en consecuencia, adoptarán el valor de la etiqueta menor dentro de la tabla de equivalencia.
- e) Finalmente se procede a reprocesar la imagen $g(x, y)$ obtenida en (b) actualizando los valores obtenidos de la tabla de equivalencia en (d).

3.4 Extracción de características

Se determinaron varias características de tamaño, forma, color y textura las de cinco variedades de granos de cebada maltera debido a que no se han podido identificar características específicas adecuadas para la clasificación de variedades de cebada (Szczypiński *et al.*, 2015).

3.4.1 Características de tamaño

En un ambiente controlado donde se tenga una cámara única sin movimiento, las medidas del tamaño son parámetros que se pueden utilizar para identificar las diferentes variedades de granos de cebada. Se utilizaron las imágenes con las regiones etiquetadas para obtener un conjunto de cuatro características de tamaño: área, perímetro, longitud y anchura del grano, que se obtienen a partir de los píxeles que componen la región o contorno del grano, el procedimiento y ecuaciones se presentan a continuación.

Área

El área es la suma de los píxeles del objeto que aparecen en la imagen, es decir es el número de píxeles que forma o constituye una región, suponiendo píxeles cuadrados. Se realiza un recorrido por todas las filas F y por todas las columnas C de la imagen y se van sumando los píxeles correspondientes al objeto. Se obtiene con la siguiente ecuación.

$$Area = \sum_{x=0}^F \sum_{y=0}^C B(x, y) \quad (18)$$

dónde: $B(x, y)$ _ Corresponde al valor de intensidad de una imagen binaria. En una imagen binaria $B(x, y) = 0$ cuando el píxel no es parte del objeto y $B(x, y) = 1$ cuando si lo es.

Perímetro

El perímetro (P) se calcula sumando solamente los píxeles del contorno del objeto. Un píxel es de contorno (vecindad $\mathcal{N}_4(P)$), si tiene al menos un píxel de fondo a la izquierda, derecha, arriba o abajo.

$$P = \sum_{x=0}^F \sum_{y=0}^C B(x, y) \quad \forall B(x, y) \text{ con algún píxel de } \mathcal{N}_4(B(x, y)) = 0 \quad (19)$$

Largo y ancho

La anchura y la altura máximas de un objeto se obtienen a partir de los ejes morfológicos. El eje mayor de un contorno es el segmento de recta que une los puntos más separados entre sí. El eje menor es perpendicular al eje mayor. El rectángulo formado con las longitudes de los ejes contiene exactamente al contorno y se denomina rectángulo básico. El eje mayor corresponde a la altura y el eje menor a la anchura.

Se implementó la función *regionprops*(L, properties), donde L es una matriz de etiquetas de componentes conexas y properties es una matriz

conteniendo propiedades de las distintas regiones de la imagen binaria correspondiente a L, en este caso las características de tamaño.

3.4.2 Características de forma

Las características de forma son medidas físicas dimensionales que caracterizan la apariencia de un objeto. Las características morfológicas como rectangularidad, circularidad, compacidad y relación entre largo y ancho han sido ampliamente utilizadas en la clasificación automatizada y detección de objetos en la industria (Jayas *et al.*, 2000).

Se determinaron cuatro características morfológicas, incluyendo rectangularidad, circularidad, compacidad y relación entre largo y ancho. Para calcular estas características se utilizaron las siguientes ecuaciones:

Rectangularidad

La rectangularidad es la relación entre un objeto y el mínimo rectángulo que lo rodea, es decir el rectángulo básico. Se obtiene utilizando la ecuación (20), donde A_o es el área del objeto y A_r es el área del rectángulo.

$$Rectangularidad = \frac{A_o}{A_r} \quad (20)$$

En el caso extremo en que el objeto es un rectángulo, el rectángulo mínimo es el propio objeto y la relación tendrá valor 1. La relación se hará menor a medida que la forma del objeto no se parezca a un rectángulo.

Excentricidad

Un parámetro aproximado para medir la rectangularidad es la relación entre la anchura y la altura máxima del objeto, como se muestra en la ecuación (21), este parámetro se denomina excentricidad del contorno.

$$Excentricidad = \frac{Anchuram\acute{a}x.}{Alturam\acute{a}x.} \quad (21)$$

Compacidad

La compacidad es un parámetro que mide el grado de parecido de un determinado objeto a un círculo. Generalmente se mide como la relación entre el cuadrado del perímetro y el área. La forma más común de medirla es usando la ecuación (22).

$$Compacidad = \frac{P^2}{Area} \quad (22)$$

Circularidad

Otro descriptor de compacidad es la razón de circularidad, definida como la razón de área de un círculo (la forma más compacta) teniendo el mismo perímetro y se calcula como:

$$Circularidad = \frac{4*\pi*Area}{P^2} \quad (23)$$

Estas características se implementaron en la función '*regionprops*' que se incluye en MATLAB.

Otros descriptores de la forma son los momentos estadísticos. El concepto de momentos como características invariantes de la imagen fue introducido por Hu (1962). Mediante los momentos invariantes de Hu, se consigue una descripción independiente a las posiciones, tamaños y ángulos del grano. Los momentos deben ser invariantes (valores similares para objetos del mismo tipo) a las transformaciones geométricas (traslación, rotación y escalamiento) que pueden sufrir los objetos y al mismo tiempo deben ser discriminantes (valores distintos para objetos de diferente tipo). La extracción de momentos invariantes

ya se ha realizado para clasificar trigo en Shouche (2001) y para clasificar arroz en Chaugule y Mali (2014).

Los momentos de Hu (1962) son un conjunto de siete descriptores invariantes que cuantifican la forma de un objeto, donde los dos primeros momentos se calculan como:

$$\phi_1 = \eta_{20} + \eta_{02} \quad (24)$$

$$\phi_2 = (\eta_{20} - \eta_{02})^2 + 4\eta_{11}^2 \quad (25)$$

donde los momentos centrales normalizados de segundo orden se calculan como:

$$\mu_{20} = m_{20} - \frac{m_{10}^2}{m_{00}} \quad (26)$$

$$\mu_{02} = m_{02} - \frac{m_{01}^2}{m_{00}} \quad (27)$$

$$\mu_{11} = m_{11} - \frac{m_{10}m_{01}}{m_{00}} \quad (28)$$

y los momentos geométricos de orden $p + q$ se calculan como:

$$m_{pq} = \sum_{x=0}^{N-1} \sum_{y=0}^{N-1} x^p y^q f(x, y); \quad p, q = 0, 1, 2 \dots \quad (29)$$

donde $f(x, y)$ es un píxel del objeto con coordenadas (x, y) .

Se implementó en Matlab la función 'hu' en la que se calculan los momentos centrales de segundo orden y los siete momentos de Hu (1962) extraída de Barranco (2012).

También se caracterizó el contorno con los descriptores elípticos de Fourier (DEF), propuestos por Kuhl y Giardina (1982). Los descriptores elípticos de Fourier pueden delinear cualquier tipo de forma con un contorno cerrado bidimensional y ya han sido aplicados al análisis de varias formas biológicas,

como por ejemplo en la descripción de la forma de los huevos de las aves (Avila, 2014).

El análisis de los contornos se basa en la digitalización de la silueta de un objeto, que expresada como una secuencia de coordenadas (x, y) pueden ser manipuladas matemáticamente y ajustadas a una ecuación derivada de las funciones de Fourier.

El método se desarrolla tomando los incrementos en X y Y entre puntos, para definir la función periódica (Kuhl & Giardina, 1982). Si el contorno de una forma digitalizada se representa como una secuencia de puntos (p) ordenados y registrados en el sentido de las manecillas del reloj comenzando por un punto arbitrario, y las distancias entre puntos son lineales, entonces el segmento entre (i-1) y el punto p es:

$$\Delta t_p = \sum_{i=1}^p \Delta t_i \quad (30)$$

y la sumatoria de todos estos incrementos sería el perímetro del contorno. Entonces, la expansión elíptica de Fourier de la secuencia de coordenadas X es:

$$x_p = x_{cen} + \sum_{n=1}^{\infty} (a_n \cos \frac{2n\pi t_p}{T} + b_n \sen \frac{2n\pi t_p}{T}) \quad (31)$$

Donde:

$$a_n = \frac{T}{2n^2\pi^2} \sum_{p=1}^K \frac{\Delta x_p}{\Delta t_p} (\cos \frac{2n\pi t_p}{T} - \cos \frac{2n\pi t_{p-1}}{T}) \quad (32)$$

y

$$b_n = \frac{T}{2n^2\pi^2} \sum_{p=1}^K \frac{\Delta x_p}{\Delta t_p} (\sen \frac{2n\pi t_p}{T} - \sen \frac{2n\pi t_{p-1}}{T}) \quad (33)$$

En estas ecuaciones, x_{cen} es el coeficiente del punto central, n es el número total de armónicos necesarios para generar una aproximación precisa de la frontera, k es el número total de pasos alrededor del contorno, Δx_p es el

desplazamiento a lo largo del eje x entre el punto p y $p + 1$, Δt_p es la longitud del paso entre el punto p y $p + 1$, t_p es la longitud acumulada de los segmentos de paso en el punto P , T es el período o pasos necesarios para atravesar todo el contorno. Los coeficientes armónicos para las coordenadas $Y(c_n \text{ y } d_n)$ se calculan de la misma forma. Estos coeficientes deben ser normalizados para hacerlos invariantes al tamaño, a la rotación y al punto inicial, de acuerdo al tamaño y orientación del eje mayor, del radio mayor o normalizando los radios.

Se calcularon los Coeficientes Elípticos de Fourier (a , b , c y d) por cada armónico utilizando la función '*ellipticFourierDescriptor*' extraída de Pohlen (2016). El número adecuado de armónicos es una cuestión que se ve afectada y necesita ser comprobada en función de las características de la forma. En (Gamarra *et al.*, 2011) se menciona que alrededor de 20 a 30 armónicos son suficientes para definir formas complejas. En este caso fueron necesarios 30 armónicos para una correcta representación de la forma del grano.

3.4.3 Características de color

Dado que la información de color exterior refleja algunas de las características principales de las semillas, estos parámetros se utilizan como una de las evidencias en la identificación de los granos (Ebrahimi *et al.*, 2014). Luo *et. al* (1999) clasificaron trigo sano, roto, mohoso y manchado demostrando que las características de color combinadas con características morfológicas son eficientes durante la clasificación. En Visen *et al.* (2004) se clasificaron dos variedades de trigo, cebada, avena y centeno utilizando características de color combinadas con características morfológicas y texturales concluyendo que las características de color desempeñan un papel importante en el proceso de clasificación de granos. En una muestra de cebada para comercializar o para mejoramiento lo primero que se considera es el aspecto general, especialmente el color, que debe ser amarillo pajizo con un cierto brillo. Esto indica buenas

condiciones sanitarias de maduración y cosecha (Arias, 1991). Dentro de las características de color se utilizó el modelo de color *RGB* (*Red, Green, Blue*), *HSB* (*Hue, Saturation, Brightness*) y el CIE 1976 $L^*a^*b^*$.

Modelo RGB

Los colores primarios de este modelo son el rojo (R), el verde (G) y el azul (B) y el resto de colores se forman por la síntesis aditiva de ellos. La representación de los colores es mediante tres cifras cuyos valores se encuentran entre el 0 y el 255 y hacen referencia a la cantidad que hay de cada color primario. En el modelo RGB se obtienen tres imágenes independientes (Figura 14) una por cada componente (R, G, B). Estas tres imágenes se combinan para producir una imagen de color compuesta.

Modelo HSV

Los atributos como el matiz (H, del inglés hue), saturación (S), luminosidad (L), valor (V) o brillo (B) son espacios cuyos parámetros están basados en la interpretación humana del color. Esta familia de modelos denominada genéricamente HSI (Hue, Saturation and Intensity; matiz, saturación e intensidad), es una derivación mediante transformaciones de coordenadas del espacio de color RGB.

Estas tres magnitudes pueden tener los siguientes valores:

H (color en concreto). Valores de 0-360°. La gama cromática se representa en una rueda circular y este valor expresa su posición.

S (Saturación). Valores de 0-100%. De menos a más cantidad de color.

B (Brillo). Valores de 0-100%. De totalmente oscuro a la máxima luminosidad.

La información de color está representada por los valores de H y S, mientras que la intensidad (B), que describe el brillo de la imagen, está determinada por la cantidad de luz.

La conversión de imágenes RGB al espacio de color HSV se lleva a cabo considerando las siguientes ecuaciones (Gil *et al.*, 2004):

$$H = \begin{cases} \frac{G-B}{MAX-MIN}, & \text{si } R = MAX \\ \frac{B-R}{MAX-MIN} + 2, & \text{si } G = MAX \\ \frac{R-G}{MAX-MIN} + 4, & \text{si } B = MAX \end{cases} \quad (34)$$

$$S = \frac{MAX-MIN}{MAX} \quad (35)$$

$$V = MAX \quad (36)$$

donde MAX es el valor máximo de los componentes (R, G, B), y MIN el valor mínimo de esos mismos valores.

La función de MATLAB implementada para cambiar el modelo RGB al modelo HSV fue '*rgb2hsv*'. Esta función toma como entrada una imagen RGB compuesta de tres planos (Figura 14) y convierte la imagen al modelo HSV, compuesta a su vez de tres planos, correspondientes al H, S y V (Figura 15).




Figura 14. Modelo RGB.




Figura 15. Modelo HSV.

Modelo CIE L*a*b*

El CIE L*a*b* es el modelo cromático usado normalmente para describir todos los colores que puede percibir el ojo humano. Fue desarrollado específicamente con este propósito por la Commission Internationale d'Eclairage (Comisión Internacional de la Iluminación), razón por la cual se abrevia CIE. Los asteriscos (*) que siguen a cada letra forman parte del nombre, ya que representan L*, a* y b*, de L, a y b. Los tres parámetros en el modelo representan la luminosidad de color:

- L* indica valor de luminosidad de negro a blanco, L*=0 rendimientos negro y L*=100 blanco.
- a* indica valor de luminosidad de verde a rojo; valores negativos indican verde mientras valores positivos indican rojo.
- b* indica valor de luminosidad de azul a amarillo; valores negativos indican azul y valores positivos indican amarillo.

Para convertir la imagen RGB a CIE 1976 $L^*a^*b^*$ se usó la función de MATLAB '*rgb2lab*', cambia la imagen al modelo CIE 1976 $L^*a^*b^*$, compuesta a su vez de tres planos, correspondientes al L^* , a^* y b^* (Figura 16). Las siguientes ecuaciones permiten transformar una imagen en un espacio de color RGB a uno CIE 1976 $L^*a^*b^*$ (Baldevbhai y Anand, 2012):

$$L^* = 116f\left(\frac{Y}{Y_n}\right) - 16 \quad (37)$$

$$a^* = 500\left[f\left(\frac{X}{X_n}\right) - f\left(\frac{Y}{Y_n}\right)\right] \quad (38)$$

$$b^* = 200\left[f\left(\frac{Y}{Y_n}\right) - f\left(\frac{Z}{Z_n}\right)\right] \quad (39)$$

Donde:

$$f(t) = \begin{cases} t^{\frac{1}{3}}, & \text{si } t > \left(\frac{6}{29}\right)^3 \\ \frac{1}{3}\left(\frac{29}{6}\right)^2 t + \frac{4}{29}, & \text{de otra manera} \end{cases} \quad (40)$$

donde X_n , Y_n y Z_n son los valores tristimulus CIE XYZ del punto blanco de referencia (el subíndice n sugiere "normalizado"). El término tristimulus proviene del hecho de que la percepción del color resulta de la retina del ojo que responde a tres tipos de estímulos.

Para extraer los componentes de cada modelo fue necesario dividir la imagen original en tres imágenes simples, que representan a cada banda a la cual se le aplicó la función de MATLAB '*MeanIntensity*', la cual devuelve un escalar que especifica la media de todos los valores de intensidad en la región.




Figura 16. Modelo CIE 1976 $L^*a^*b^*$.

3.4.4 Características de textura

Una textura está definida por la uniformidad, densidad, grosor, rugosidad, regularidad, intensidad y direccionalidad de medidas discretas del tono en los píxeles y de sus relaciones espaciales. Para caracterizar las texturas existen básicamente tres formas de procesar la imagen y extraer su información: descriptores en frecuencia, descriptores estructurales y descriptores probabilísticos (Gonzales y Woods, 2007). En un estudio presentado por Callejo *et al.* (2016) se muestra que el descriptor de frecuencia basado en el análisis del espectro de Fourier da buenos resultados para imágenes de textura homogénea (el grano de cebada tiene textura heterogénea) y el análisis con la transformada Wavelet permite el análisis multirresolución, es decir, analiza la frecuencia de una imagen en función de la escala. Esta propiedad no tiene mucha importancia en esta investigación dado que la captura se realizó en un ambiente controlado donde la cámara está estática manteniendo los parámetros de zoom y foco fijos.

Los descriptores estructurales necesitan texturas que tengan elementos que se repitan y en el caso del grano de cebada no presenta esta característica. Los descriptores probabilísticos son unos de los métodos más simples y se apoyan principalmente en estadísticos del histograma de niveles de gris de una imagen. Estos estadísticos pueden ser de primer, segundo o de tercer orden. Las medidas estadísticas de segundo orden calculadas a partir de la matriz de coocurrencia de niveles de gris GLCM (Grey Level Co-occurrence Matrix) tienen información de la distribución de las intensidades y las posiciones de los píxeles que tienen iguales, o casi iguales valores de intensidad.

Haralick y Shanmugam (1973) definieron la GLCM, en la cual, cada elemento (i, j) de la misma, es la probabilidad que un píxel separado por un desplazamiento fijo $\delta = (d, \theta)$ de un píxel con nivel de gris i , tenga un nivel de gris j . En la Figura 17 se muestra como los valores representados en la matriz GLCM corresponden a la imagen donde un píxel tiene un mismo valor de forma horizontal y adyacente. En GLCM el elemento $(1,1)$ tiene valor 1 ya que en la imagen existe solo una instancia en la que el píxel tiene valor 1 y 1. En GLCM el elemento $(1,2)$ tiene valor 2 ya que existen dos instancias en la que el píxel tiene valor 1 y 2 (Barroso, 2013).




Figura 17. Matriz de coocurrencia calculada a partir de otra matriz de 4X5.

En este trabajo se utilizan las medidas estadísticas de segundo orden calculadas de la matriz de coocurrencias (Haralick y Shanmugam, 1973). Utilizar la matriz de coocurrencia de niveles de gris GLCM (Grey Level Co-occurrence Matrix) es el método más apropiado para analizar la textura de los granos de cebada según el estudio comparativo de distintos métodos de caracterización de textura mencionado por Callejo *et al.* (2016), ya que tiene la ventaja de que puede ser aplicada a texturas de origen aleatorio o que no respondan a un patrón o serie de patrones determinados (Barroso, 2013).

Para crear la GLCM de cada grano analizado, se utilizó la función ‘*graycomatrix*’. Una vez que se obtiene la matriz, fue necesario aplicar un proceso de normalización (donde la resultante indica la probabilidad de que una relación exista) mediante la ecuación (Vázquez *et al.*, 2015):

$$P_{i,j} = \frac{V_{i,j}}{\sum_{i=0}^{N-1} \sum_{j=0}^{N-1} V_{i,j}} \quad (41)$$

donde cada elemento de la matriz $V_{i,j}$ es el número de veces que la relación i, j se presenta en la imagen o región de interés.

Se calculó una matriz de coocurrencia para cada una de las direcciones 0, 45, 90 y 135 grados, todos a una distancia fija de un píxel. La matriz final es el promedio de las cuatro matrices calculadas. Para la extracción de las características se utilizó la función ‘*graycoprops*’. Se calcularon ocho variables estadísticas de segundo orden, propuestas por Haralick y Shanmugam (1973) y se evaluaron en cada una de las componentes R, G y B. A continuación, se mencionan los descriptores extraídos de Gonzales y Woods (2007) utilizados para la evaluación de textura en los granos de cebada e impurezas en esta investigación.

Contraste

El contraste de una textura también conocido como varianza o inercia proporciona información acerca de las variaciones bruscas de color en la imagen. Mide las variaciones locales en la matriz de coocurrencia de nivel de gris. Devuelve una medida de la diferencia de intensidad entre un píxel y su vecino en toda la imagen y está dado por la ecuación (42). El contraste es 0 para una imagen constante.

$$\text{Contraste} = \sum_{ij} |i - j|^2 p(i, j) \quad (42)$$

donde $p(i, j)$ es cada elemento de la matriz de coocurrencia y varían desde 0 hasta el número total de niveles de gris.

Correlación

La correlación de la textura es una medida de la probabilidad que mide la relación entre las diferentes intensidades de los colores. Devuelve una medida de la correlación de un píxel y su vecino en toda la imagen. La correlación es 1 o -1 para una imagen perfectamente correlacionada positiva o negativamente. La correlación es inválida para una imagen constante. Matemáticamente la correlación, para la matriz de coocurrencia está definida de la siguiente manera:

$$\text{Correlación} = \sum_{ij} \frac{(i - \mu_i)(j - \mu_j)p(i, j)}{\sigma_i \sigma_j} \quad (43)$$

donde,

$$\mu_i = \sum_{ij} i * p(i, j) \quad (44)$$

$$\mu_j = \sum_{ij} j * p(i, j) \quad (45)$$

$$\sigma_i = \sum_{ij} (i - \mu_i) * p(i, j) \quad (46)$$

$$\sigma_j = \sum_{ij} (j - \mu_j) * p(i, j) \quad (47)$$

Debido al carácter estadístico que posee este descriptor, su valor está ligado al valor de sus medidas estadísticas. El concepto de media y varianza se aplica al histograma de segundo orden, y la combinación de la media en i y en j , es referida a la diagonal principal de la matriz de coocurrencia. En general la media tiene que ver sobre la parte de la diagonal donde se acumulan la mayor cantidad de elementos de la matriz, así como la varianza provee una idea de la dispersión de los elementos alrededor de la media.

Energía

Proporciona la suma de elementos cuadrados en la GLCM. También conocida como la uniformidad o el segundo momento angular. El descriptor de energía de una textura extraído de la matriz de coocurrencia está dado por la siguiente ecuación:

$$Energía = \sum_{ij} p(i,j)^2 \quad (48)$$

De la ecuación 48 se puede decir que cuando todos los valores de $p(i,j)$ son semejantes, (mayor dispersión en la diagonal principal de la matriz), el valor de la energía será menor, por el contrario, si ocurre que en la diagonal principal se dan mayores picos de intensidad el descriptor será mayor. La propiedad de energía da una idea de la suavidad de la textura, y esto se refleja en la ubicación de sus probabilidades en la matriz de coocurrencia.

Entropía

Es una medida de la aleatoriedad contenida en la matriz de coocurrencia, es decir, es una medida de la complejidad de la imagen; a mayor entropía mayor complejidad. Se obtiene con la siguiente ecuación:

$$Entropía = \sum_{ij} p(i,j) \log(p(i,j)) \quad (49)$$

A medida que todos los elementos de la matriz son similares, este descriptor aumenta su valor, siendo máximo en el caso que todos los elementos de la matriz fueran iguales.

Homogeneidad local

El descriptor de homogeneidad local proporciona información sobre la regularidad local de la textura. La descripción matemática de este descriptor está dada por la siguiente ecuación:

$$Homogeneidad\ local = \sum_{ij} \frac{p(i,j)}{1+|i-j|} \quad (50)$$

Este descriptor aumenta cuando la distancia i-j sea mínima. Lo cual indica que mientras los elementos de la matriz de coocurrencia estén más próximos a la diagonal principal mayor será el valor de la homogeneidad local.

Máxima probabilidad

Es la máxima probabilidad de que un píxel con nivel de gris i, tenga un nivel de gris j, es decir suministra información sobre la respuesta más fuerte de un par de píxeles en la matriz de coocurrencia. La descripción matemática es la siguiente:

$$MP = \max_{ij} p(i,j) \quad (51)$$

El valor de este descriptor será mayor cuando en la matriz de coocurrencia se observe un pico de intensidad, el mayor de estos elementos dará el valor máximo de probabilidad. Este descriptor es útil para percibir la mayor ocurrencia o la predominación de un color en la textura.

Tonalidad

Lo primero que se debe calcular es la media de la matriz de coocurrencia, tanto para filas (μ_i) como para columnas (μ_j). Se hace notar la diferencia que existe entre esta GLCM media de la media aritmética de los valores de grises de los píxeles de la ventana. La media en la matriz de coocurrencia no es simplemente el promedio de los valores originales de los niveles de gris en la ventana. El valor del píxel no es ponderado por su frecuencia por sí mismo, sino por la frecuencia de su coocurrencia en combinación de un determinado valor del píxel vecino.

Se define entonces la tonalidad como:

$$Tonalidad = \sum_{i,j} (i - \mu_i + j - \mu_j)^3 * p(i,j) \quad (52)$$

Importancia

Medida similar a la tonalidad y se puede inferir que este descriptor aumentará su valor a medida que las medias de los valores estén más cercanos al valor mínimo. Esta característica tiene la tendencia a oscilar entre valores positivos y negativos, puesto que la influencia de la media no siempre se equipará con el valor de los elementos alejados de ésta, cuya expresión viene dada por:

$$Importancia = \sum_{i,j} (i - M_x + j - M_y)^4 * p(i,j) \quad (53)$$

3.5 Selección de características

El número de características extraídas usualmente es muy grande. Uno de los problemas más comunes en el reconocimiento de patrones es la reducción de la dimensión del espacio característico. Las razones para reducir el número de características es que muchas veces dos características pueden portar

información adecuada para la clasificación cuando se utilizan por separado, pero si son altamente correlacionadas la ganancia es poca al utilizarlas en un mismo vector característico, además de que el cálculo de un gran número de atributos lleva mucho tiempo. Si se logra obtener un conjunto de características adecuado se simplifica el diseño del clasificador lo cual es muy importante para lograr un buen rendimiento de clasificación.

Para la reducción de variables se realizó el análisis factorial por el método de componentes principales (Pérez y Medrano, 2010). El análisis factorial es una técnica de reducción de datos que sirve para encontrar grupos homogéneos de variables a partir de un conjunto numeroso de variables. Esos grupos homogéneos se forman con las variables que correlacionan mucho entre sí y procurando, inicialmente, que unos grupos sean independientes de otros.

El modelo factorial que se usó para estimar las saturaciones de las variables en los factores fue el de componentes principales donde se buscan factores que sean ortogonales. Reducir la matriz de correlaciones a un conjunto menor de componentes principales (factores); diagonalizándola (matriz ortogonal), obteniendo sus autovectores y autovalores. Entonces las cargas factoriales se obtienen multiplicando cada uno de los elementos del autovector por su autovalor. Las cargas indican la importancia del factor en cada variable, y pueden obtenerse correlacionando factores y variables superficiales.

Sean $(X_1, X_2, \dots, X_P)$ las características extraídas ($P=171$) donde se incluyen cuatro características de tamaño, 134 características morfológicas, nueve características de color y 24 características de textura con mediciones para $n=2000$ granos de cebada, tal como se representa en la matriz X .

$$X = \begin{pmatrix} x_{11} & \cdots & x_{1n} \\ \vdots & & \vdots \\ x_{p1} & \cdots & x_{pn} \end{pmatrix} \quad (54)$$

Los factores resultantes extraídos con el método de componentes principales son $\mathbf{F}=\mathbf{U}'\mathbf{X}$, donde $\mathbf{U}$ contiene los vectores propios y al ser $\mathbf{U}$ ortogonal $\mathbf{X}=\mathbf{U}\mathbf{F}$. En la matriz $\mathbf{U}$ cada termino u_{ij} es la proyección del componente j sobre la variable i .

$$\mathbf{U} = \begin{pmatrix} u_{11} & \cdots & u_{1m} \\ \vdots & & \vdots \\ u_{p1} & \cdots & u_{pm} \end{pmatrix} \quad (55)$$

La matriz $\mathbf{F}$ (suponiendo que $m=P$), con el valor que toma cada individuo en cada factor, es del tipo:

$$\mathbf{F} = \begin{pmatrix} F_{11} & \cdots & F_{1n} \\ \vdots & & \vdots \\ F_{m1} & \cdots & F_{mn} \end{pmatrix} \quad (56)$$

Si hay 'P' factores, se interpreta que el instrumento original se puede descomponer en 'P' instrumentos (cada uno compuesto por todas las características), aunque en cada instrumento las características tienen un 'peso específico' distinto según sea su relación con el factor.

Si se encuentra, por ejemplo, tres factores, esto quiere decir que se puede descomponer el instrumento original en tres instrumentos; cada uno está compuesto por todas las características, pero en cada instrumento los parámetros tienen un peso específico distinto según sea su relación con cada factor:

$a_1a + b_1b + c_1c + \cdots = \text{Total en el Factor 1}$; $\mathbf{a}_1$ es el peso específico del parámetro $\mathbf{a}$ en el Factor 1

$a_2a + b_2b + c_2c + \cdots = \text{Total en el Factor 2}$; $\mathbf{a}_2$ es el peso específico del parámetro $\mathbf{a}$ en el Factor 2

.....

$a_pa + b_pb + c_pc + \cdots = \text{Total en el Factor P}$; $\mathbf{a}_p$ es el peso específico del parámetro $\mathbf{a}$ en el Factor P.

Las nuevas puntuaciones son las puntuaciones factoriales.

Los pesos pueden ser grandes o pequeños, positivos o negativos. Generalmente, en cada factor hay características con pesos grandes y otras

próximos a cero; los parámetros que más pesan en cada factor son los que lo definen.

Para realizar el análisis factorial se utilizó el programa IBM SPSS Statistics 22 (IBM Corp., Armonk, Nueva York). Para determinar el número óptimo de factores se utilizó el gráfico de sedimentación originalmente propuesto por Cattell (1966). Teniendo el número de factores se seleccionaron las características estudiando la matriz de correlación de las variables con los factores; seleccionando como representante de cada factor las variables con las correlaciones más elevada en éste. Primero se encontraron las características que sirvieron para clasificar los granos de cebada en variedades formando la matriz MAT0, después de esa matriz se seleccionaron las características para discriminar granos de cebada de otros objetos que no lo eran, es decir impurezas, formando en este caso la matriz MAT1.

3.6 Clasificación

La tarea de clasificación de patrones consiste en relacionar el vector de características con la clase correspondiente, de este modo se puede reconocer a qué clase corresponde cualquier patrón de entrada representado por su vector de características. Para la clasificación de granos de cereales se han probado clasificadores estadísticos, técnicas de lógica difusa y redes neuronales artificiales, obteniendo mejores resultados con los clasificadores de redes neuronales artificiales (Paliwal *et al.* 2003; Douik y Abdellaoui, 2010). Se han utilizado redes neuronales artificiales para identificar y clasificar granos de trigo, cebada, avena y centeno utilizando características morfológicas, texturales y de color y la precisión de clasificación obtenidos para estos cereales fue de más del 98% (Golpour *et al.*, 2014).

La ventaja de usar redes neuronales está en el hecho que se pueden separar regiones no lineales de decisiones tan complicadas como se desee dependiendo del número de neuronas y capas. Por lo tanto, las redes neuronales artificiales sirven para resolver problemas de clasificación de alta complejidad y, además, debido a su constitución y a sus fundamentos presentan un gran número de características semejantes a las del cerebro. Por ejemplo, son capaces de aprender de la experiencia, de generalizar de casos anteriores a nuevos casos y de abstraer características esenciales a partir de entradas que representan información irrelevante. Esto hace que ofrezcan numerosas ventajas y que este tipo de tecnología se esté aplicando en múltiples áreas. Estas ventajas incluyen: aprendizaje adaptativo, auto organización, tolerancia a fallos, operación en tiempo real, fácil inserción dentro de la tecnología existente y numerables aplicaciones (Matich, 2001).

Para la clasificación de las variedades analizadas y las impurezas en muestras de granos de cebada se implementaron redes neuronales artificiales estáticas. Es decir, con esta red se pretende establecer una correspondencia entre un conjunto de entrada y un conjunto de salidas deseadas, de manera que:

$$(x_1, x_2, \dots, x_n) \in R^N \rightarrow (y_1, y_2, y_3, y_4, y_5) \in \text{Cinco variedades de cebada}$$

Para ello se dispone de un conjunto de p patrones de entrenamiento, de manera que se sabe perfectamente que al patrón de entrada $(x_1^k, x_2^k, \dots, x_N^k)$ le corresponde la salida $(y_1^k, y_2^k, y_3^k, y_4^k, y_5^k)$, $k = 1, 2, \dots, p$. Es decir, se conoce dicha correspondencia para p patrones. Así, el conjunto de entrenamiento es:

$$\{(x_1^k, x_2^k, \dots, x_N^k) \rightarrow (y_1^k, y_2^k, y_3^k, y_4^k, y_5^k): k = 1, 2, \dots, p\} \quad (57)$$

El proceso de aprendizaje a través del cual los parámetros de la red se modifican se realizó con el tipo de aprendizaje supervisado y el algoritmo de

aprendizaje de corrección por error que está basado en el modelo supervisado, ya que existe una señal deseada en la salida de la red.

Se utilizaron redes neuronales de reconocimiento de patrones (*patternnet*) implementadas en MATLAB R2015a (Beale-Hudson *et al.*, 2015). La topología utilizada fue la del Perceptrón multicapa que es una red de alimentación hacia adelante (feedforward) compuesta por una capa de unidades de entrada (sensores), otra capa de unidades de salida y una capa oculta (Figura 18). Las redes multicapa han resultado una herramienta muy poderosa en problemas de reconocimiento de patrones (sistemas estáticos), mientras que las redes recurrentes han sido utilizadas para la identificación y control de sistemas dinámicos, también en la resolución de problemas de optimización. Desde el punto de vista teórico las redes multicapas representan mapeos no lineales estáticos, mientras que las redes recurrentes son representadas por sistemas con retroalimentación dinámica no lineal (Ortiz, 2008).




Figura 18. Topología de la red neuronal para clasificar variedades de cebada.

Las neuronas de la capa de entrada se encargan solamente de recibir las características x_n previamente seccionadas que se propagan a las neuronas de la capa siguiente. La capa de salida proporciona la respuesta de la red para un patrón de entrada dado; se tienen para este problema cinco posibles respuestas atendiendo a las cinco variedades a clasificar y dos posibles respuestas para identificar impurezas, de granos de cebada. Mientras que la capa oculta es la que lleva a cabo el procesamiento de los patrones recibidos. El número de neuronas en la capa oculta no suele ser tan evidente, por lo que se determinó siguiendo las reglas sugeridas por Goethals *et al.* (2007), presentadas en el Cuadro 5 seleccionando la regla que llevara al mínimo error medio cuadrado (MSE por sus siglas en inglés) en la fase de entrenamiento y la mayor precisión de clasificación.

Como las entradas a las unidades de proceso de una capa son las salidas de las unidades de proceso de la capa precedente, el perceptrón multicapa con sólo una capa oculta implementado está formado por la siguiente función:

$$y_i = g_1\left(\sum_{j=1}^L W_{ij}x_n\right) = g_1\left(\sum_{j=1}^L W_{ij}\left(g_2\left(\sum_{r=1}^N t_{jr}x_n\right)\right)\right) \quad (58)$$

donde W_{ij} es el peso sináptico de la conexión entre la unidad de salida i y la unidad de proceso j de la capa oculta; L es el número de unidades de proceso (neuronas) de la capa oculta; g_1 es la función de transferencia de las unidades de salida, que en este caso se aplicó la función de transferencia exponencial normalizada (ecuación 59); t_{jn} es el peso sináptico que conecta la unidad de proceso j de la capa oculta con el sensor de entrada n y g_2 es la función de activación de las unidades de la capa oculta que para este proceso se aplicó la función de activación sigmoideal (ecuación 60).

$$F(x, t, w) = \frac{e^{\sum_{j=1}^L w_{ij}x_n}}{\sum_{m=1}^c e^{\sum_{j=1}^L w_{mj}x_n}} \quad (59)$$

donde $F(x, t, w)$ es la salida del perceptrón multicapa, para $c=5$ que son las unidades de salida. Este es el método softmax que viene a ser una versión suavizada o continua del método “el ganador se lleva todo” (winner-take-all) en el que la salida máxima se transforma a 1 y las demás a 0.

$$\text{Sigmoide: } g_2(.) = \text{sigm}(x) = \frac{1}{1+e^{-x}} \quad (60)$$

La función de desempeño usada para el entrenamiento de la RNA es el error medio cuadrado o suma media del cuadrado de los errores (MSE) que es la media cuadrática de la diferencia entre la salida objetivo y la salida de la red de los datos presentados (ecuación 61). Para el entrenamiento y simulación se empleó el algoritmo de retropropagación Levenberg-Marquardt con regulación bayesiana (*trainbr*) que evita el sobreaprendizaje o pérdida de generalización de la red sin necesidad de utilizar un conjunto de la validación (Burden y Winkler, 2009).

$$MSE = \frac{1}{n} \sum (y_i - \bar{y}_i)^2 \quad (61)$$

donde y_i representa el valor observado y $\bar{y}_i$ el valor predicho por la red.

El conjunto de entrenamiento formado por 1800 granos de cebada se dividió en dos subconjuntos: entrenamiento y prueba. Se separó aleatoriamente en un 95% para el entrenamiento de la red y 5% para la prueba. Los otros 200 de los 2000 granos se utilizaron para la prueba final del algoritmo. Para seleccionar el mejor modelo (se eligió el de menor MSE) y el máximo rendimiento de clasificación. Para clasificar y contabilizar las impurezas presentes en una imagen primero se extrajo la matriz MAT1 que contenía las características seleccionadas para este propósito y se empleó como entrada de la red neuronal RNA2 (código en el Anexo 3) que se encargó de clasificar los granos de cebada y las impurezas. Se utilizaron 360 granos de cada variedad y 360 impurezas para entrenar esta red. Ahora bien, para clasificar las cinco variedades de cebada se

utilizó la red neuronal RNA1 (código en el Anexo 2) empleando como patrón de entrada la matriz MAT0.

Cuadro 5. Reglas sugeridas para el número de neuronas en la capa oculta basado en el número de variables de entrada (Ni) y/o nodos de salida (No).

$$\frac{\frac{\frac{2}{3}(Ni)}{\frac{3}{4}(Ni)}}{\frac{\frac{1}{2}(Ni + No)}{2(Ni) + 1}}$$

Antes de realizar la validación del algoritmo se utilizó el entorno de desarrollo “GUIDE” (Graphical User Interface Development Environment) para crear una interfaz gráfica de usuario.

3.7 Validación del algoritmo

Para validar el algoritmo desarrollado se calculó la sensibilidad y la especificidad. La sensibilidad indica la capacidad del clasificador para dar como casos positivos los casos que realmente corresponden a la variedad de cebada analizada y la especificidad indica la capacidad del clasificador para dar como casos negativos los casos correspondientes a otras variedades. Dichos parámetros se calculan según las ecuaciones 62 y 63, respectivamente.

$$Sensibilidad = \frac{VP}{VP+FN} \quad (62)$$

$$Especificidad = \frac{VN}{VN+FP} \quad (63)$$

Cuando el algoritmo determine que el objeto analizado pertenece a la variedad de cebada analizada y en realidad lo es entonces se habla de un Verdadero Positivo (VP), en caso contrario, sería un Falso Positivo (FP); cuando el algoritmo determine que el objeto pertenece a otra variedad y en realidad lo es

esta afirmación es un Verdadero Negativo (VN), de otro modo sería un Falso Negativo (FN). Se aplicó también para el clasificador de impurezas.

Cuadro 6. Matriz de confusión y descripción de variables VP, VN, FP y FN.

		Pronóstico	
		Cebada	Impurezas
Clase real	Cebada	VP-Verdadero Positivo	FP-Falso Negativo
	Impurezas	FP-Falso Positivo	VN-Verdadero Negativo

Otro parámetro calculado fue el valor predictivo positivo (precisión), que es la probabilidad de que un objeto analizado pertenezca a la clase si se obtiene un resultado positivo en la prueba (Altman, 1994):

$$VPP = \frac{VP}{VP+FP} \quad (64)$$

Capítulo 4. RESULTADOS Y DISCUSIÓN

Se analizaron 2000 granos de cebada maltera, a los cuales se les calculó un total de 171 características. Se obtuvo un conjunto de cuatro características de tamaño: área, perímetro, longitud y anchura del grano. Se calcularon 134 características morfológicas las cuales se enlistan en el Cuadro 7.

Cuadro 7. Características de forma.

Características
Rectangularidad
Circularidad
Compacidad
Excentricidad
10 Momentos centrales de la forma
30 Coeficiente Elíptico de Fourier a
30 Coeficiente Elíptico de Fourier b
30 Coeficiente Elíptico de Fourier c
30 Coeficiente Elíptico de Fourier d

La forma del grano puede ser descrita en detalle con 30 armónicos como se muestra en la Figura 19. Se utilizaron 30 armónicos para una correcta representación de la forma del grano, generando cuatro coeficientes por cada armónico que describen la elipse.




Figura 19. Reconstrucción mediante descriptores elípticos de Fourier sobre una serie de armónicos (N).

Se obtuvieron nueve características de color descritas en el Cuadro 8.

Cuadro 8. Características de color.

Característica	Descripción característica
Componente R	Determina la cantidad de rojo dentro del histograma RGB
Componente G	Determina la cantidad de verde dentro del histograma RGB
Componente B	Determina la cantidad de azul dentro del histograma RGB
Componente H	Valor del matiz en el modelo de color HSB
Componente S	Valor de la saturación en el modelo de color HSB
Componente V	Valor del brillo en el modelo de color HSB
Componente L (L*a*b*)	Valor de luminosidad de negro a blanco
Componente a (L*a*b*)	Valor de luminosidad de verde a rojo
Componente b (L*a*b*)	Valor de luminosidad de azul a amarillo

Se extrajeron ocho descriptores de textura y se evaluaron en cada una de las componentes R, G y B; obteniéndose un total de 24 características. En el Cuadro 9, se presenta la lista de los descriptores de textura calculados.

Cuadro 9. Características de textura.

Característica
Contraste en R, G y B
Correlación en R, G y B
Energía en R, G y B
Entropía en R, G y B
Homogeneidad local en R, G y B
Máxima probabilidad en R, G y B
Tonalidad en R, G y B
Importancia en R, G y B

4.1 Características seleccionadas

Con el análisis factorial por el método de componentes principales se seleccionaron las características que sirvieron para formar la matriz MAT0 para clasificar los granos de cebada en variedades obteniendo que el primer factor reúne una varianza de 97.8%, y la varianza acumulada entre el factor uno y dos es de 99.7%, esto se puede ver en la Figura 20 donde se presenta el gráfico de sedimentación; se visualiza que la selección de los dos primeros factores es adecuada, pues a partir de la tercer factor no es muy pronunciada la pendiente de la representación gráfica de los autovalores.

Se seleccionaron 41 características más representativas de las 171 de los factores uno (Cuadro 10) y dos (Cuadro 11), siendo los pesos o cargas de estas variables las que mejor definen a estos factores.

Cuadro 10. Características seleccionadas del Factor 1.

No.	Factor 1	Peso	No.	Factor 1	Peso
1	Tonalidad R	0.999	17	Importancia	-0.336
2	Tonalidad G	0.941	18	Energía B	-0.333
3	Componente V	0.930	19	Importancia	-0.323
4	Componente R	0.930	20	Importancia	-0.321
5	Componente L*	0.902	21	Entropía R	0.289
6	Componente G	0.884	22	Entropía G	0.289
7	Tonalidad B	0.774	23	Entropía B	0.289
8	Componente B	0.767	24	Correlación	0.288
9	Máxima	0.708	25	Correlación	0.288
10	Máxima	0.676	26	Correlación	0.288
11	Máxima	0.656	27	Área	-0.206
12	Homogeneidad	0.377	28	Compacidad	-0.206
13	Homogeneidad	0.370	29	Anchura	-0.178
14	Energía R	-0.368	30	Longitud	-0.170
15	Energía G	-0.362	31	Perímetro	-0.159
16	Homogeneidad	0.337			

Cuadro 11. Características seleccionadas del Factor 2.

No.	Factor 2	Peso específico	No.	Factor 2	Peso específico
32	Componente a* (L*a*b*)	-0.762	37	Contraste B	0.326
33	Componente S	-0.714	38	Contraste G	0.188
34	7° momento de Hu (MC10)	-0.690	39	5° momento de Hu (MC8)	0.165
35	Componente b* (L*a*b*)	-0.577	40	Rectangularidad	-0.137
36	Componente H	0.535	41	Circularidad	0.105

La representación gráfica se muestra en la Figura 21. Las coordenadas vienen dadas por los respectivos coeficientes de correlación entre la variable y el

factor. Las variables al final de un eje son aquellas que tienen correlaciones altas sólo en ese factor y, en consecuencia, lo describen. Las variables cerca del origen tienen correlaciones reducidas en ambos factores. Las variables que no están cerca de ninguno de los ejes se relacionan con ambos factores. Se eliminaron las características que presentaron correlaciones muy débiles en los componentes retenidos, cuyas correlaciones fueron menores de 0.10 en valor absoluto.




Figura 20. Gráfico de sedimentación.

De los 41 descriptores seleccionados se observa que el conjunto de características de textura y color fueron los atributos que mayor información aportan en la clasificación de los granos de cebada (Figura 21), seguido de los descriptores de forma y tamaño, esto concuerda con Zapotoczny (2008) que encontró que el uso de las características morfológicas se puede emplear con éxito en el análisis de imágenes para una identificación varietal preliminar de granos de cebada.



70

valores. Los valores de los distintos atributos son escalados para que cada eje tenga la misma altura y fueron colocados en orden descendente respecto al peso específico. Cada variedad está representada por una línea que une los distintos ejes de acuerdo a valores del segundo cuartil para esa característica.




Figura 22. Representación en coordenadas paralelas de las características seleccionadas.

En las primeras 13 características se visualiza una diferencia en el comportamiento entre la variedad Adabella y Esperanza o Armida, mientras que entre las variedades Alina y Esmeralda o Armida y Esperanza la diferencia es mínima con estas características, por lo tanto, es necesario utilizar más características para tener una mejor identificación de las variedades al momento de clasificarlas. En general se observa que la variedad Adabella presenta diferencias en el comportamiento de sus características, respecto de las demás variedades.

La representación en coordenadas paralelas para el grupo de las características de textura en el componente rojo del modelo RGB se visualiza en

la Figura 23 donde se observa que la variedad Adabella es la que presenta mayor diferencia en este tipo de características, sin embargo, en la característica de contraste en el componente rojo los valores para las cinco variedades son semejantes, por lo que el análisis factorial no le da mucho peso a este parámetro y no figura entre las 41 características seleccionadas.




Figura 23. Representación en coordenadas paralelas de las características de textura en el componente R.

Para las características de color la representación en coordenadas paralelas se presenta en la Figura 24 donde se observa que la diferencia de valores en el modelo RGB es notable entre la variedad Adabella y las variedades Armida y Esperanza. Con el modelo HSV se observa que difieren las variedades Adabella y Esmeralda y la variedad Alina y Esperanza presentan valores semejantes en el componente H (matiz). En el componente CIE $L^*a^*b^*$ los valores de L^* en las variedades Alina y Esperanza son similares y en el componente a^* es semejante en las variedades Alina y Esperanza.




Figura 24. Representación en coordenadas paralelas de las características de color.

Como se mencionó anteriormente el conjunto de características de textura y color fueron los atributos que mayor información aportan en la clasificación de los granos de cebada y los descriptores elípticos de Fourier son parámetros que no muestran diferencias en sus valores que posibilitara la clasificación entre las cinco variedades como se observa en la Figura 25.




Figura 25. Representación en coordenadas paralelas de los descriptores elípticos de Fourier en el coeficiente a para 30 armónicos.

Para encontrar los patrones de entrada para el clasificador RNA2 que es el que se encargó de clasificar los granos de cebada y las impurezas con el análisis factorial por el método de componentes principales se analizaron las 41 características ya seleccionadas donde se encontró que el primer factor reúne una varianza de 98.5%. De este factor se seleccionaron diez características más representativas de las 41 (Cuadro 12), siendo los pesos o cargas de estas variables las que mejor definen a este factor. La representación gráfica se muestra en la Figura 26. Las coordenadas vienen dadas por los respectivos coeficientes de correlación entre la variable y el factor. Las variables al final de un eje son aquellas que tienen correlaciones altas sólo en ese factor y, en consecuencia, lo describen.




Figura 26. Gráfico de componente en espacio rotado.

Se observa que las características de color son las que aportan más al momento de diferenciar granos de cebada e impurezas. En algunos casos las impurezas son partes de granos de cebada por lo que también se seleccionó el área que es el parámetro de tamaño con el peso específico mayor.

Con las diez características presentadas en el Cuadro 12 y el conjunto de entrenamiento formado por 360 granos de cada variedad de cebada y 360 impurezas queda formada la matriz MAT1 que se encargó de clasificar los granos de cebada y las impurezas.

Cuadro 12. Características seleccionadas.

Característica	Peso específico
Tonalidad G	0.998
Tonalidad R	0.957
Tonalidad B	0.929
Componente G	0.901
Componente B	0.897
Componente L ($L^*a^*b^*$)	0.888
Componente V	0.862
Componente R	0.861
Máxima probabilidad en B	0.835
Área	0.337

4.2 Arquitectura de las redes neuronales

Los resultados resumidos del análisis de clasificación para la elección del modelo que identifica la variedad a la que pertenece la muestra de las cinco variedades de cebada estudiadas se presentan en el Cuadro 13.

Cuadro 13. Error cuadrático medio para diferentes arquitecturas entrenadas.

Neuronas en la capa oculta	MSE	Precisión de clasificación (%)	Épocas
50	0.018	91.5	100
55	0.016	91.8	150
60	0.018	91.6	100
80	0.011	93.9	200

Las neuronas de la capa de entrada son las 41 características seccionadas. La capa de salida proporciona la respuesta de la red para un patrón de entrada dado; se tienen para este problema cinco posibles respuestas atendiendo a las cinco variedades a clasificar. Con base en las reglas que se presentan en el Cuadro 5, se experimentó con cuatro diferentes arquitecturas de redes neuronales artificiales para ser entrenadas. La arquitectura que proporcionó el menor error medio cuadrado (MSE) en la fase de entrenamiento está formada de 41 neuronas de entrada que reciben la información de los parámetros extraídos de cada grano de cebada, 80 neuronas en la capa oculta y cinco neuronas en la capa de salida (Figura 27). Además, fue la que presentó la precisión de clasificación más alta con 93.9%.




Figura 27. Arquitectura de la RNA1.

En la Figura 28 se puede ver como la función de desempeño en la curva de la fase de entrenamiento llega a un mínimo con 200 iteraciones. Después de estas épocas el error se mantiene constante. Para esta configuración en la red el mínimo error medio cuadrado es de 0.011 que es la media cuadrática de la

diferencia entre la salida objetivo y la salida de la red de los datos presentados en la fase de entrenamiento.




Figura 28. Curvas de desempeño para el entrenamiento y prueba de la RNA1.

La elección de la arquitectura que clasifica las impurezas y los granos de cebada presentes en una imagen se realizó con base en los resultados resumidos del análisis de clasificación presentados en el Cuadro 14.

Cuadro 14. Diferentes arquitecturas entrenadas para la RNA2.

Neuronas en la capa oculta	MSE	Precisión de clasificación (%)	Épocas
8	0.0009	99.9	78
10	0.0009	99.8	58
12	0.0009	99.9	164
20	0.0009	99.9	198

Todas las topologías probadas presentan el mismo MSE y la precisión de clasificación es de 99.9%. Se escogió la configuración de la red que encontró una combinación óptima de los errores y los pesos en el menor número de iteraciones. La topología seleccionada presenta ocho neuronas en la capa oculta (Figura 29).




Figura 29. Arquitectura de la RNA2.

La Figura 30 muestra la función de desempeño en la curva de la fase de entrenamiento cuando llega a un mínimo con 78 iteraciones. Después de estas épocas el error se mantiene constante. Para esta configuración en la red el mínimo error medio cuadrado es de 0.0009.




Figura 30. Curvas de desempeño para el entrenamiento y prueba de la RNA2.

4.3 Rendimientos de clasificación

El Cuadro 15 muestra los resultados de clasificación en el entrenamiento de la red RNA1 para los 360 granos de cebada de cada variedad. La matriz de confusión es una herramienta que permite la visualización del desempeño del clasificador. La diagonal de la matriz de confusión en la tabla indica el número de casos que fueron clasificados correctamente. Cada columna representa el número de predicciones de cada clase realizadas por el clasificador, mientras que cada fila representa a los granos que realmente pertenecen a la variedad, es decir, la suma vertical muestra la distribución de las clases producidas por el clasificador, mientras que la suma horizontal muestra la distribución real de las clases.

Cuadro 15. Rendimiento de clasificación obtenido por la RNA1 para clasificar granos de cinco variedades de cebada.

Variedad	Adabella	Alina	Armida	Esmeralda	Esperanza	Precisión de clasificación (%)
Adabella	338	4	5	7	6	96.8
Alina	5	339	4	5	7	92.9
Armida	0	8	342	8	2	93.4
Esmeralda	2	8	10	331	9	93
Esperanza	4	6	5	5	340	93.4
Sensibilidad	93.9	94.2	95	91.9	94.4	93.9

El clasificador identificó con mayor eficiencia la variedad Armida en un 95%, es decir, mayor sensibilidad en la clasificación de esta clase; 342 granos de 360 fueron clasificados correctamente. En la calidad de la respuesta positiva del clasificador la variedad Adabella fue la que presentó la mayor precisión con 96.8%. En general los resultados de este clasificador muestran un 93.9% de granos catalogados de manera correcta. En Szczypiński *et al.* (2015) reportan que el clasificador con redes neuronales reconoce correctamente el 86% de los granos de 11 variedades de cebada en el mejor de los casos. Sin embargo, encontró que con clasificadores para diferenciar entre dos variedades la precisión fue de 91%, que es inferior a los resultados obtenidos con el clasificador RNA1.

Comparado con la investigación reportada en Zapotoczny (2012) donde se clasifica cinco variedades de cebada polaca de dos hileras con muestras a granel usando 270 características texturales obteniendo una precisión de clasificación de 99%, el clasificador RNA1 solo utiliza 41 características de las cuales solo 24 son de textura y además identifica granos de cebada de seis hileras que dos de los tres granos que constituyen la espiguilla son asimétricos, en cambio en las variedades de cebada de dos hileras (dística) se desarrollan sólo granos anchos y simétricos.

A continuación, se presentan los mismos datos clasificados con los métodos de análisis discriminante y árboles de decisión.

Cuadro 16. Rendimiento de clasificación obtenido mediante análisis discriminante para clasificar granos de cinco variedades de cebada.

Variedad	Adabella	Alina	Armida	Esmeralda	Esperanza	Precisión de clasificación (%)
Adabella	165	2	3	5	185	83.3
Alina	17	89	13	16	225	78
Armida	7	12	87	21	233	76.3
Esmeralda	4	8	7	108	233	71
Esperanza	5	3	4	2	346	28.3
Sensibilidad	45.8	24.7	24.1	30	96.1	44.1

Cuadro 17. Rendimiento de clasificación obtenidos mediante árboles de decisión para clasificar granos de cinco variedades de cebada.

Variedad	Adabella	Alina	Armida	Esmeralda	Esperanza	Precisión de clasificación (%)
Adabella	312	17	8	15	8	82.9
Alina	18	298	16	16	12	78
Armida	15	29	291	15	10	80.8
Esmeralda	10	17	12	307	14	85.2
Esperanza	21	21	23	20	275	76.3
Sensibilidad	86.6	82.7	80.8	85.2	76.3	82.3

Comparando el rendimiento de clasificación con los métodos de análisis discriminante cuadrado y árboles de decisión se observa que las redes neuronales artificiales son las que mejor clasifican cada variedad, seguido del método de árboles de decisión con 82.3% de granos catalogados de manera correcta y siendo el análisis discriminante el que presenta la clasificación más baja que incluso es inviable su utilización.

Los resultados del rendimiento del clasificador para separar dos clases (granos de cebada e impurezas) se muestra en la matriz de confusión del Cuadro 18.

Cuadro 18. Rendimiento de clasificación obtenido por la RNA2 para clasificar granos de cebada e impurezas.

Clase	Cebada	Impurezas	Precisión de clasificación (%)
Cebada	1799	1	99.9
Impurezas	1	319	99.7
Sensibilidad	99.9	99.7	99.9

La calidad de las respuestas positivas del clasificador es de 99.9%. La medida de sensibilidad que nos da la eficiencia del clasificador para reconocer granos de cebada es de 99.9%, esto es que de 1800 granos de cebada solo uno fue clasificado como impureza. De 320 impurezas, 319 fueron correctamente clasificadas como objetos extraños. Resultados similares se reportan en Ebrahimi *et al.* (2014), donde se determinó la pureza de trigo, utilizando el algoritmo imperialista competitivo combinado con redes neuronales artificiales clasificando trigo de impurezas obteniendo un 96.2% de precisión en la clasificación.

En el Cuadro 19 y Cuadro 20 se presentan los mismos datos clasificados con los métodos de análisis discriminante y árboles de decisión, respectivamente.

Cuadro 19. Rendimiento de clasificación obtenido mediante análisis discriminante para clasificar granos de cebada e impurezas.

Clase	Cebada	Impurezas	Precisión de clasificación (%)
Cebada	1752	48	98.4
Impurezas	27	293	85.9
Sensibilidad	97.3	91.5	94.4

Cuadro 20. Rendimiento de clasificación obtenido mediante árboles de decisión para clasificar granos de cebada e impurezas.

Clase	Cebada	Impurezas	Precisión de clasificación (%)
Cebada	1793	7	98.8
Impurezas	21	299	97.7
Sensibilidad	99.6	93.4	96.5

El rendimiento de clasificación mediante los tres métodos superó el 90% de clasificación para las dos clases, sin embargo, el porcentaje de impurezas presentes en una muestra no debe superar el 2% como se establece en la norma mexicana NMX-FF-043-SCFI-2003, por lo tanto, el clasificador que menos errores obtuvo al momento de clasificar impurezas es el de redes neuronales artificiales.

Se desarrolló una interfaz gráfica (Figura 31), integrando todos los algoritmos implementados para el procesamiento de imágenes, caracterización de los granos y clasificación, formando así el algoritmo para la determinación de la pureza varietal en muestras de granos de cebada (Figura 32).




Figura 31. Interfaz de usuario para determinar la pureza varietal de granos de cebada.

4.4 Validación del algoritmo

Para la evaluación de la eficiencia del algoritmo se usaron 40 granos de cada variedad y 114 impurezas. Los resultados de sensibilidad y especificidad para el clasificador RNA1 del algoritmo desarrollado se presentan el Cuadro 21.

Cuadro 21. Sensibilidad y especificidad para el clasificador RNA1 en la evaluación del algoritmo.

Variedad	Adabella	Alina	Armida	Esmeralda	Esperanza	Especificidad
Adabella	38	0	1	1	0	99.3
Alina	0	37	1	1	1	98.6
Armida	1	1	35	3	0	95.4
Esmeralda	0	1	2	35	2	96.0
Esperanza	0	0	3	1	36	97.9
Sensibilidad	95	92.5	87.5	87.5	90	

La mayor sensibilidad se presentó clasificando la variedad Adabella; 38 granos de 40 fueron clasificados correctamente, y fue la variedad que mostró

mayor eficiencia en la clasificación de todos los elementos que no son de la clase, es decir mayor especificidad. La especificidad promedio para esta red neuronal fue de 97.4%. La validación del clasificador confirmó que es eficiente y permite la descripción precisa del 90.5% de las muestras de las cinco variedades analizadas.

La sensibilidad y especificidad obtenidos con el clasificador RNA2 del algoritmo desarrollado se presentan en el Cuadro 22.

Cuadro 22. Sensibilidad y especificidad para el clasificador RNA2 en la evaluación del algoritmo.

Clase	Cebada	Impurezas	Especificidad
Cebada	200	0	98.2
Impurezas	2	112	100
Sensibilidad	100	98.2	

En este caso el clasificador que identifica dos clases (cebada e impurezas) presenta 100% de sensibilidad al clasificar granos de cebada, esto indica la capacidad del clasificador para dar como casos positivos los casos que realmente corresponden a granos de cebada y como se observó en el Cuadro 18 el valor predictivo positivo para las impurezas es inferior al de la clase cebada por lo tanto en la prueba refleja también una sensibilidad inferior. Con respecto a la especificidad, la cual indica la capacidad del clasificador para dar como casos negativos los casos correspondientes a otras clases, para la cebada genera dos falsos positivos, es decir 98.2% de eficiencia en la clasificación de todos los elementos que no son de la clase.

Se utilizaron siete imágenes donde se presentaban diferentes porcentajes de granos de las cinco variedades de estudio en cada una. En el Cuadro 23 se muestra el número real de granos de cada variedad presente en las imágenes y en el

Cuadro 24 se muestra el pronóstico obtenido por el clasificador. Se observó que la variedad Adabella presenta el menor porcentaje de error en la clasificación y la variedad Esmeralda presenta el mayor error (Cuadro 25), esto queda demostrado en la evaluación del algoritmo que se presentó en el Cuadro 21.

Cuadro 23. Número de granos de cada variedad de cebada presentes en las imágenes.

Variedad	Imagen						
	1	2	3	4	5	6	7
Adabella	8	8	4	10	4	8	8
Alina	8	5	8	10	12	3	4
Armida	8	10	6	6	6	7	7
Esmeralda	8	15	10	9	8	0	0
Esperanza	8	12	12	5	10	2	1
No. De granos en la imagen	40	50	40	40	40	20	20

Cuadro 24. Número de granos de cada variedad de cebada identificados por el clasificador.

Variedad	Imagen						
	1	2	3	4	5	6	7
Adabella	8	9	4	9	4	8	8
Alina	7	6	11	9	14	2	3
Armida	8	4	6	6	8	6	5
Esmeralda	9	17	8	9	7	2	3
Esperanza	8	14	11	6	7	2	1
Impurezas	0	0	0	1	0	0	0

Cuadro 25. Porcentaje de errores en la clasificación de cada variedad de cebada.

Variedad	Imagen						
	1	2	3	4	5	6	7
Adabella	0.0	2.0	0.0	2.5	0.0	0.0	0.0
Alina	2.5	2.0	7.5	2.5	5.0	5.0	5.0
Armida	0.0	12.0	0.0	0.0	5.0	5.0	10.0
Esmeralda	2.5	4.0	5.0	2.5	2.5	10.0	15.0
Esperanza	0.0	4.0	2.5	5.0	7.5	0.0	0.0
Impurezas	0.0	0.0	0.0	2.5	0.0	0.0	0.0

Esta prueba se realizó con la finalidad de observar la eficiencia del clasificador cuando se presentaba una mezcla de granos de las cinco variedades en una imagen y aunque el porcentaje más alto de error fue de 15% en la variedad Esmeralda solo tres granos de otra variedad fueron catalogados como granos de ésta variedad.




Figura 32. Algoritmo para la determinación de la pureza varietal de granos de cebada.

Capítulo 5. CONCLUSIONES

En la presente investigación se encontró que el uso de las características morfológicas, de tamaño, color y textura se puede emplear con éxito en el análisis de imágenes para clasificar variedades de granos de cebada e impurezas consiguiendo un 93.9% de precisión en la clasificación de las variedades y una precisión de 99.9% para identificar granos de cebada de impurezas.

Se logró reducir el vector de características a un conjunto de 41 descriptores para el clasificador de variedades de cebada y 10 descriptores para el clasificador de granos de cebada e impurezas. Se encontró que el conjunto de características de textura y color fueron los atributos que mayor información aportan en la clasificación de los granos de cebada, es por esto que se debe procurar mantener constantes la intensidad de la iluminación.

En la etapa de clasificación se implementaron y entrenaron dos redes neuronales artificiales con entrenamiento Levenberg-Marquardt de retropropagación con regulación bayesiana. La primera con una topología de tres capas; 41 neuronas en la capa de entrada, 80 neuronas en la capa oculta y cinco neuronas en la capa de salida (41:80:5) para clasificar cinco variedades de cebada y la segunda formada de tres capas (10:8:2) para clasificar granos de cebada e impurezas.

En la validación del algoritmo para el clasificador de variedades de cebada el promedio obtenido para la sensibilidad fue de 90.5%, para especificidad fue de 97.4% y para el clasificador de granos de cebada e impurezas el promedio para la sensibilidad y la especificidad fue de 99%.

5.1 Recomendaciones

El sistema de adquisición de imágenes debe tener condiciones de iluminación bien controladas para evitar sombras y brillos, además se debe procurar mantener constantes la intensidad y el color de la iluminación, para que en el procesamiento y análisis de la imagen se logre una buena segmentación y se calculen correctamente las características de color y textura.

Se recomienda hacer la captura de imágenes empleando cámaras de uso industrial ya que en esta investigación se empleó una cámara web convencional para probar que se puede utilizar con éxito este tipo de tecnología.

Capítulo 6. REFERENCIAS

- Altman D. G. and J. M. Bland. 1994. Statistics Notes: Diagnostic tests 2: predictive values. *Bmj*. 309(6947): 102.
- Arias G. 1991. Calidad industrial de la cebada cervecera. Instituto Nacional de Investigación Agropecuaria. Recuperado el 26 de enero de 2016. <http://www.ainfo.inia.uy/digital/bitstream/item/2919/1/111219220807120028.pdf>
- Avila D. 2014. Aplicación de las funciones elípticas de Fourier para la descripción de la forma de los huevos de las aves. *Revista de Biología Tropical*. 62(4): 1469-1480.
- Baldevbhai P. J. and R. S. Anand. 2012. Color image segmentation for medical images using $L^* a^* b^*$ color space. *IOSR Journal of Electronics and Communication Engineering*. 1(2): 24-45.
- Barranco G., A. I., S. Martínez D. y J. L. Gómez T. 2012. Visión estereoscópica por computadora con Matlab y OpenCV. Lulu.com.
- Barroso B., A. 2013. Utilización de la textura como rasgo en la clasificación de células en imágenes de microscopía. Tesis Profesional. Universidad Central “Marta Abreu” de Las Villas, Santa Clara, Cuba. 97 pp.
- Beale-Hudson, M., M. Hagan and H. Demuth. 2015. Neural Networks Toolbox. User's Guide. For Use with MATLAB. (Versión 8.4. Release 2015b). The MathWorks. Recuperado el 21 de enero de 2016. En: https://www.mathworks.com/help/pdf_doc/nnet/nnet_ug.pdf
- Betancourt G., D. M. 2014. Sistema de visión por computador para detectar hierba no deseada en prototipo de cultivo de frijol usando ambiente controlado. Proyecto de grado. Universidad Católica de Colombia, Bogotá, D. C. 66 pp.

- Brosnan T. and D. W. Sun. 2004. Improving quality inspection of food products by computer vision—a review. *Journal of Food Engineering*. 61(1): 3-16.
- Burden, F. and D. Winkler. 2009. Bayesian regularization of neural networks. *Artificial Neural Networks: Methods and Applications*. 23-42.
- Callejo D., F. L´pez, J. Pérez, J. Vidal. 2016. e-REdING. Biblioteca de la Escuela Superior de Ingenieros de Sevilla. En: Bibing.us.es, <http://bibing.us.es/proyectos/abreproy/11494/>.
- Calot E. 2008. Reconocimiento de patrones en imágenes médicas basado en sistemas inteligentes. Tesis Profesional. Universidad de Buenos Aires, Argentina. 166 pp.
- Castillo Z., C. 2012. Almacenamiento de semillas de cebada maltera: análisis físico, proximal y deterioro fisiológico. Tesis de Maestría. Colegio de Posgraduados. Montecillo, México. 108 pp.
- Cattell R. B. 1966. The scree test for the number of factors. *Multivariate behavioral research*. 1(2): 245-276.
- Chaugule A. y S. N. Mali. 2014. Evaluation of texture and shape features for classification of four paddy varieties. *Journal of Engineering*. Vol. 2014.
- Choudhary R., J. Paliwal, and D. S. Jayas. 2008. Classification of cereal grains using wavelet, morphological, colour, and textural features of non-touching kernel images. *Biosystems Engineering*. 99(3): 330-337.
- Douik A. and M. Abdellaoui. 2010. Cereal grain classification by optimal features and intelligent classifiers. *International Journal of Computers Communications & Control*. 5(4): 506-516.
- Ebrahimi E., K. Mollazade and S. Babaei. 2014. Toward an automatic wheat purity measuring device: A machine vision-based neural networks-assisted imperialist competitive algorithm approach. *Measurement*. 55: 196-205.
- FAO. 2015. FAOSTAT: Food and Agriculture Organization of the United Nations. <http://faostat3.fao.org>. Recuperado el 10 de enero de 2016.

- Figueroa, J. C. D. 1985. Métodos para evaluar la calidad maltera en cebada. Tema didáctico 17, Secretaria de Agricultura y Recursos Hidráulicos, Instituto Nacional de Investigaciones Agrícolas. México, D.F.
- García S., E. 2008. Detección y clasificación de objetos dentro de un salón de clases empleando técnicas de procesamiento digital de imágenes. Tesis de Maestría. Universidad Autónoma Metropolitana. México. 157 pp.
- Gamarra B., A. Romero, A. Pérez-Pérez, y J. Galbany. 2011. Caracterización morfológica del M2 de primates Hominoidea a partir de análisis de Fourier. *Revista Argentina de Antropología Biológica*. 13.
- Gil P., F. Torres y F. Ortiz G. 2004. Detección de objetos por segmentación multinivel combinada de espacios de color. XXV Jornadas de Automática.
- Goethals, P. L., A. P. Dedecker, W. Gabriels, S. Lek, and N. De Pauw. 2007. Applications of artificial neural networks predicting macroinvertebrates in freshwaters. *Aquatic Ecology*. 41(3): 491-508.
- Golpour I., J. A. Parian and R. A. Chayjan. 2014. Identification and classification of bulk paddy, brown, and white rice cultivars with colour features extraction using image analysis and neural network. *Czech Journal of Food Science*. 32(3): 280-287.
- González E., A., S. Solano H., F. Ramírez P., M. Zamora D., L. A. Márquez C., A. M. Ibañez C., J. Islas G. y Stanley W. 2006. Impacto económico del mejoramiento genético de la cebada en México: Variedad Esperanza. Instituto Nacional de investigaciones, Forestales, Agrícolas y Pecuarias (INIFAP). México, D. F. Publicación técnica No. 20, 67 p.
- González M., G., M. Zamora D. y S. Hernández S. 2016. Evaluación agronómica y física en líneas avanzadas de cebada maltera. *Revista Mexicana de Ciencias Agrícolas*. 7(1): 159-171.
- Gonzales R. and R. Woods. 2007. Digital Image Processing. Prentice Hall.

- Haralick, R. M. and K. Shanmugam. 1973. Textural features for image classification. IEEE Transactions on systems, man, and cybernetics. (6): 610-621.
- Haralick R. M. and L. G. Shapiro. 1993. Computer Robot Vision, volume I. Addison-Wesley Publishing Company.
- Hernández M., E. 2005. Calidad comercial de la cebada maltera (*Hordeum vulgare*) de Calpulalpan, Tlaxcala, México. Tesis profesional. Universidad Autónoma Chapingo, Chapingo, México. 71 pp.
- Herrera C., Y. 2012. Fecha de siembra y estrés de humedad en cebada maltera (*Hordeum vulgare* L.): efecto en la calidad de la malta. Tesis profesional. Universidad Autónoma Chapingo, Chapingo, México. 80 pp.
- Holopainen-Mantila U. 2015. Composition and structure of barley (*Hordeum vulgare* L.) grain in relation to end uses. VTT Science.
- Hornsey S., I. 1999. Elaboración de cerveza (Microbiología, Bioquímica y tecnología). Editorial Acriba S. A. Zaragoza España. pp: 15-29.
- Hu, M. K. 1962. Visual pattern recognition by moment invariants. IRE transactions on information theory. 8(2): 179-187.
- IBM Corp. 2013. Lanzamiento de IBM SPSS Statistics para Windows, versión 22.0. Armonk, Nueva York: IBM Corp.
- Jayas D. S., J. Paliwal and N. S. Visen. 2000. Review Paper (AE—Automation and Emerging Technologies): Multi-layer Neural Networks for Image Analysis of Agricultural Products. Journal of Agricultural Engineering Research. 77(2): 119-128.
- Kong T. Y. and A. Rosenfeld. 1989. Digital topology: Introduction and survey. Computer Vision, Graphics, and Image Processing. 48(3): 357-393.
- Kuhl, F. P. and C. R. Giardina. 1982. Elliptic Fourier features of a closed contour. Computer graphics and image processing. 18(3): 236-258.

- Kunze W. 2006. Tecnología para cerveceros y malteros. Claudio R. Bauer. VLB Berlín, Alemania. 1074 p.
- Lilhare S. F. and N. G. Bawane. 2012. Classification of paddy Varieties using Image processing. In National Conference on Innovative Paradigms in Engineering and Technology. pp. 33-35.
- Luo X., D.S. Jayas and S. J. Symons. 1999. Identification of damaged kernels in wheat using a colour machine vision system. Journal of cereal science. 30(1): 49-59.
- Majumdar S. 1997. Classification of cereal grains using machine vision. Thesis of Doctor of Philosophy. The University of Manitoba. Winnipeg, MB, Canada. 273 pp. Recuperado el 11 de enero de 2015. En: <http://mspace.lib.umanitoba.ca/handle/1993/846>
- Matich D. J. 2001. Redes Neuronales: Conceptos básicos y aplicaciones. Cátedra de Informática Aplicada a la Ingeniería de Procesos–Orientación I.
- The MathWorks Inc. 2015. MATLAB version 8.5.0. Massachusetts.
- Mebatsion H. K., J. Paliwal and D. S. Jayas. 2013. Automatic classification of non-touching cereal grains in digital images using limited morphological and color features. Computers and electronics in agricultura. 90: 99-105.
- Norma Mexicana NMX-FF-043-SCFI-2003. Productos alimenticios no industrializados para consumo humano -cereal- cebada maltera (*Hordeum vulgare* L. y *Hordeum distichum* L.). Especificaciones y métodos de prueba. Publicada en el diario oficial el 18 de octubre del 2003.
- Olgun M., A. O. Onarcın, K. Özkan, Ş. Işık, O. Sezer, K. Özgişi and O. Koyuncu. 2016. Wheat grain classification by using dense SIFT features with SVM classifier. Computers and Electronics in Agriculture. 122: 185-190.
- Ortiz R., F. 2008. Análisis y diseño de redes neuronales CMAC para la identificación y control de sistemas no lineales. Tesis Doctoral. Centro de

- Investigación y de Estudios Avanzados del Instituto Politécnico Nacional. Departamento de Control Automático. México, D.F. 150 pp.
- Otsu N. 1979. A threshold selection method from gray-level histograms. *Automatica*. 11(285-296): 23-27.
- Paliwal J., N. S. Visen, D. S. Jayas and N. D. G. White. 2003. Comparison of a neural network and a non-parametric classifier for grain kernel identification. *Biosystems engineering*. 85(4): 405-413.
- Paliwal J., M. S. Borhan, D. S. Jayas. 2004. Classification of cereal grains using a flatbed scanner. *Canadian Biosystems Engineering*. 46: 3.1–3.5.
- Peña B., R. J., P. Pérez H., E. Villaseñor M., M. M. Gómez V. y M. A. Mendoza L. 2008. Calidad de la cosecha del trigo en México. Ciclo primavera-verano. Publicación Especial del CONASIST-CONATRIGO. México, D. F. 28 p.
- Pérez E., R. y L. A. Medrano. 2010. Análisis factorial exploratorio: bases conceptuales y metodológicas. *Revista Argentina de Ciencias del Comportamiento*. 2(1): 58-66.
- Pérez G, H. M. 2000. Electroforesis en geles de poliacrilamida: fundamentos, actualidad e importancia. *Universo Diagnóstico*, 1:2, 31-4.
- Pohlen T. 2016. Fourier Descriptor. Recuperado el 04 de noviembre de 2016. En: http://www.geekstack.net/index.php?page=fourier_descriptor.
- Pourreza A., H. Pourreza, M. H. Abbaspour-Fard and H. Sadrnia. 2012. Identification of nine Iranian wheat seed varieties by textural analysis with image processing. *Computers and electronics in agricultura*. 83: 102-108.
- Ricolfe V., C. 2006. Caracterización y optimización del proceso de calibrado de cámaras basado en plantilla bidimensional. Tesis Doctoral. Universidad Politécnica de Valencia. España. 192 pp.
- Ruiz S., Y. 2006. Elaboración y evaluación de maltas cerveceras de diferentes variedades de cebada (*Hordeum vulgare*) producidas en los estados de

- Hidalgo y Tlaxcala. Tesis profesional. Universidad Autónoma del Estado de Hidalgo, México. 110 pp.
- Sánchez, C., N. Arizcuren, J. Abril y A. Casp. 2004. Importancia de la visión artificial aplicada a la industria agroalimentaria. *In*: III Congreso Español de Ingeniería de Alimentos. Septiembre. Pamplona, España. Recuperado el 30 de octubre de 2016. Disponible en: http://www.acyja.com/documentos/Comunicaciones_Congresos/Posters/Cesia%202004/vision%20artificial.pdf
- Secretaría de Hacienda y Crédito Público (2014), Panorama de la Cebada, SHCP. Recuperado el 26 de octubre de 2016. Disponible en: <http://www.financiarural.gob.mx/informacionsectorrural/Panoramas/Ficha%20Cebada.pdf>.
- Sevillano B., F. J. 2015. Equipo de clasificación de semillas basado en visión artificial. Implantación sobre hardware libre. Trabajo final de grado. Universidad de Valladolid. Valladolid, España. 100 pp.
- Shouche S. P., R Rastogi, S. G. Bhagwat & J. K. Sainis. 2001. Shape analysis of grains of Indian wheat varieties. *Computers and electronics in agriculture*. 33(1): 55-76.
- SIAP. SAGARPA. 2016. Secretaría de Agricultura, Ganadería, Desarrollo Rural, Pesca y Alimentación. Servicio de Información Agroalimentaria y Pesquera. Disponible en: <https://www.gob.mx/cms/uploads/attachment/file/97401/05270159485Tomaterojo1.pdf>. Último acceso el 31 de diciembre de 2016.
- Silva C. S. and U. Sonnadara. 2013. Classification of rice grains using neural networks. In *Proceedings of Technical Sessions*. Vol. 29, pp. 9-14.
- Solano H., S. y M. Zamora D. 2006. Alina variedad de cebada maltera para riego en El Bajío. Campo Experimental Bajío-INIFAP. Celaya, Guanajuato, México. (Desplegable técnica).

- Solano H., S., M. Zamora D., F. P. Gámez V., J. J. García R., Sánchez de la Cruz, R., J. Ireta M., y R. Garza G. 2009. Alina, nueva variedad de cebada maltera para riego en el Bajío. *Agricultura técnica en México*. 35(4): 471-473.
- Szczypiński, P. M. and P. Zapotoczny. 2012. Computer vision algorithm for barley kernel identification, orientation estimation and surface structure assessment. *Computers and electronics in agriculture*. 87: 32-38.
- Szczypiński, P. M., A. Klepaczko and P. Zapotoczny. 2015. Identifying barley varieties by computer vision. *Computers and Electronics in Agriculture*. 110: 1-8.
- Tejada F., C. E. 2016. Evaluación de la capacidad de malteo de tres variedades de cebada (*Hordeum vulgare L.*) producidas en el Estado de México, México, para su potencial uso en la cervecería artesanal. Tesis profesional. Universidad Autónoma Chapingo, Chapingo, México. 71 pp.
- Valiente-Gonzalez J. M., G. Andreu-García, P. Potter and A. Rodas-Jorda. 2014. Automatic corn (*Zea mays*) kernel inspection system using novelty detection based on principal component analysis. *Biosystems Engineering*. 117: 94-103.
- Vargas B., V. 2010. Sistema de visión artificial para el control de calidad en piezas cromadas. Tesis de Maestría. Instituto Politécnico Nacional, México, D. F. 182 pp.
- Vázquez E., R. A., J. Ambrosio B. y G. A. Sandoval S. 2015. Clasificación de cultivos agrícolas utilizando técnicas clásicas de procesamiento de imágenes y redes neuronales artificiales. *Realidad Datos y Espacio. Revista Internacional de Estadística y Geografía*. 6(3): 62-77.
- Vázquez T., V. M. C. 1990. Análisis del mercado de la cebada maltera en México. Tesis de maestría. Colegio de Posgraduados. Montecillo, México.

- Visen N. S., J. Paliwal, D. S. Jayas and N. D. G. White. 2002. AE—automation and emerging technologies: specialist neural networks for cereal grain classification. *Biosystems Engineering*. 82(2): 151-159.
- Visen N.S., J. Paliwal, D.S. Jayas and N.D.G. White. 2004. Image analysis of bulk grain samples using neural networks. *Canadian Biosystems Engineering*. 46: 7.11–7.15.
- Visen N. S., D. S. Jayas, J. Paliwal and N. D. G. White. 2004. Comparison of two neural network architectures for classification of singulated cereal grains. *Canadian biosystems engineering*. 46(3.7): e3.
- Zapotoczny P., M. Zielinska and Z. Nita. 2008. Application of image analysis for the varietal classification of barley: Morphological features. *Journal of Cereal Science*. 48(1): 104-110.
- Zapotoczny P. 2011. Discrimination of wheat grain varieties using image analysis and neural networks. Part I. Single kernel texture. *Journal of Cereal Science*. 54(1): 60-68.
- Zapotoczny P. 2012. Application of image texture analysis for varietal classification of barley. *International Agrophysics*. 26(1): 81-90.
- Zayas I. Y., C. R. Martin, J. L. Steele, and A. Katsevich. 1996. Wheat classification using image analysis and crush-force parameters. *Transactions of the ASAE-American Society of Agricultural Engineers*. 39(6): 2199-2204.
- Zamora D., M., L. A. Márquez C., F. Ramírez P. y A. M. Ibáñez C. 1997. Esmeralda, variedad de cebada maltera para los Valles Altos. SAGARPA–Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias (INIFAP), Centro de Investigaciones de la Región Centro (CIRCE), Campo Experimental Valle de México (CEVAMEX). Chapingo, Estado de México, México. p. 20 (Folleto Técnico Núm. 5).

- Zamora D., M., S. Solano H., R. Gómez M., I. Rojas M., J. Ireta M., R. Garza G. y C. Ortiz T. 2008. Adabella: variedad de cebada maltera para valles altos de la mesa central de México. *Agricultura Técnica en México*. 34: 491-493.
- Zamora Díaz, M., S. Solano H., R. Garza G., J. Islas G., R. Huerta Z. y M. López C. 2010. Armida, nueva variedad de cebada maltera para riego en El Bajío. *Revista mexicana de ciencias agrícolas*. 1(5): 723-726.
- Zhang G. P. 2000. Neural networks for classification: a survey. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*. 30(4): 451-462.
- Zhang Z. 2000. A flexible new technique for camera calibration. *IEEE Transactions on pattern analysis and machine intelligence*. 22(11): 1330-1334.
- Zhang G., D. S. Jayas and N. D. White. 2005. Separation of touching grain kernels in an image by ellipse fitting algorithm. *Biosystems Engineering*. 92(2): 135-142.

ANEXOS

Anexo 1. Programa principal para el procesamiento y extracción de características de granos de cebada.

```
%-----%
% NOMBRE DEL FICHERO: PROGRAMA1.m
% RECIBE: Imagen RGB con cuarenta granos de cebada.
% DEVUELVE: Parámetros de tamaño, forma, color y textura de cada grano
% de cebada.
% ALGORITMO EMPLEADO: Algoritmos de visión artificial.
% AUTOR: Pablo Hernández Santiago
%-----%
close all
clear all
clc
%-----
% Parámetros a calcular:
ARE=[]; % Área del grano o impureza.
PER=[]; % Perímetro.
LAR=[]; % Longitud mayor del objeto.
REC=[]; % Rectangularidad
CIR=[]; % Circularidad
EXC=[]; % Excentricidad
COM=[]; % Compacidad
% Momentos centrales de segundo orden y los siete momentos de (Hu,
1962):
MCFU1=[]; MCFU2=[]; MCFU3=[]; MCFU4=[]; MCFU5=[]; MCFU6=[]; MCFU7=[];
MCFU8=[]; MCFU9=[]; MCFU10=[];
% Coeficientes Elípticos de Fourier (a, b, c y d):
COEFa=[]; COEFb=[]; COEFC=[]; COEFD=[];
% Ocho descriptores de textura: contraste, correlación, energía,
% entropía, homogeneidad local, probabilidad máxima, tonalidad
% e importancia:
% Evaluados en la componente R.
RTCON=[]; RTCOR=[]; RTENE=[]; RTENT=[]; RTHOM=[]; RTPRO=[]; RTTON=[];
RTIMO=[];
% Evaluados en la componente G.
GTCON=[]; GTCOR=[]; GTENE=[]; GTENT=[]; GTHOM=[]; GTPRO=[]; GTTON=[];
GTIMO=[];
% Evaluados en la componente B.
BTCON=[]; BTCOR=[]; BTENE=[]; BTENT=[]; BTHOM=[]; BTPRO=[]; BTTON=[];
BTIMO=[];
%-----
% Características de color en los modelos RGB, HSV y CIE 1976 L*a*b*,
% respectivamente:
RGBR=[]; RGBG=[]; RGBB=[];
HSVH=[]; HSVS=[]; HSVV=[];
LABL=[]; LABA=[]; LABB=[];
%-----%
```

```

lee_archivos = dir('C:\Users\*.jpg');
% El formato de imagen puede ser modificado.
% Recorre número de archivos guardados en el directorio
for k = 1:length(lee_archivos)
    % Obtiene el nombre de los archivos
    archivo = lee_archivos(k).name;
    %Recore el directorio
    nombre='C:\Users\';
    % Lee la primera imagen
    Io = imread(strcat(nombre,archivo));

% -----
% -----
% Utiliza los datos de calibración para eliminar los efectos de
% distorsión de la lente en cada una de las imágenes
load('cameraParams.mat');
undistortedImage = undistortImage(Io, cameraParams);
Im=undistortedImage;
% -----
% Recorta la imagen, con la función imcrop(Imagen,[X1,Y1,ancho,alto]);
Ir= imcrop(Im,[7 7 627 467]);
% -----
% Convierte la imagen original a niveles de grises.
I1=rgb2gray(Ir);
% Busca el umbral con el Método de Otsu.
level = graythresh(I1);
% Binariza la imagen de niveles de grises con un umbral fijo.
I2 = im2bw(I1,level);
% Invierte 0s y 1s.
I3=not(I2);
% -----
% Operaciones morfológicas para imagen binaria
% -----
% Crea un elemento estructurante (strel)
se=strel('disk',2);
I5=imerode(I3,se);
%figure(),imshow(I5), title('Imagen erosionada');
I6=imreconstruct(I5,I3);
%figure(),imshow(I6), title('Imagen rconstruida');
% Rellena los agujeros el interior de los granos.
I7=imfill(I6,'hole');
% -----
% Etiquetar los granos de la imagen
% -----
% [L num] = bwlabel(BW,n) devuelve una matriz de etiquetas L
% que es del mismo tamaño que I7, donde la variable n especifica
% la conectividad, también devuelve num, el número de objetos
conectados.
[L num]=bwlabel(I7,8);
% -----
% -----
% Características de tamaño
% -----

```

```

% Devuelve mediciones para el conjunto de propiedades especificadas
% por las propiedades de cada componente conectado (objeto) en la
% imagen binaria.
propiedades=regionprops(L, 'area', 'Perimeter', 'MajorAxisLength',...
'MinorAxisLength', 'Eccentricity', 'centroid', 'BoundingBox', 'Orientation'
);
[w v]=size(propiedades(:,1));
% -----
% .....
%Calcula parámetros de tamaño y forma de cada uno de los granos.
% .....
for (i=1:w)
    A(i)=propiedades(i).Area;
    P(i)=propiedades(i).Perimeter;
    Largo(i)=propiedades(i).MajorAxisLength;
    Ancho(i)=propiedades(i).MinorAxisLength;
    Comp(i)=4*pi*A(i)/P(i)*P(i);
    Rec(i)=(A(i))/(Largo(i)*Ancho(i));
    Cir(i)=P(i)*P(i)/A(i);
    Ori(i) = propiedades(i).Orientation;
end
% -----
% ARE=[ARE A]; PER=[PER P]; LAR=[LAR Largo]; ANC=[ANC Ancho];
% REC=[REC Rec]; CIR=[CIR Cir]; COM=[COM Comp];
% -----
% .....
% Guarda las características de los momentos calculados.
Mcu1=[]; Mcu2=[]; Mcu3=[]; Mcu4=[]; Mcu5=[]; Mcu6=[]; Mcu7=[];
Mcu8=[]; Mcu9=[]; Mcu10=[];
% -----
% Guarda Coeficientes Elípticos de Fourier.
Ca=[]; Cb=[]; Cc=[]; Cd=[];
% .....
% Calcula 10 momentos de la forma y 30 armónicos de los 4 Coeficientes
% Elípticos de Fourier.
% .....
for n=1:num
    [r, cc] = find(L==n);
    I8 = I7(min(r):max(r),min(cc):max(cc));
    %figure(), imshow(I8);
    % -----
    angle = (-1)*(Ori(n));
    I9 = imrotate(I8,angle);
    %figure(), imshow(I9), title('Grano rotado');
    % -----
    se=strel('disk',1);
    I10=imerode(I9,se);
    % Eliminar áreas menores a 500 píxeles
    I11=bwareaopen(I10,500);
    %figure(), imshow(I11), title('Elimina otras áreas');
    % -----
    [LL,nume]=bwlable(I11); % Etiquetado de componentes

```

```

% -----
[M1,N1]=size(LL);
I=zeros(M1,N1);
for i=1:M1
    for j=1:N1
        if(LL(i,j)==nume)
            I(i,j)=1;
        else
            I(i,j)=0;
        end
    end
end
% -----
% -----
% Se calculan los 10 momentos de la forma
[u1,u2,u3,u4,u5,u6,u7,u8,u9,u10]=hu(I);
% -----
% Guarda las características de los momentos calculados.
Mcu1=[Mcu1 u1]; Mcu2=[Mcu2 u2]; Mcu3=[Mcu3 u3]; Mcu4=[Mcu4 u4];
Mcu5=[Mcu5 u5]; Mcu6=[Mcu6 u6]; Mcu7=[Mcu7 u7]; Mcu8=[Mcu8 u8];
Mcu9=[Mcu9 u9]; Mcu10=[Mcu10 u10];
% -----
% Se calculan los 30 armónicos de los 4 Coeficientes Elípticos de
% Fourier.
filename=I11;
N1=30;
p=0.20;
rotation=false;
[a, b, c, d, T]=ellipticFourierDescriptor(filename, N1, p,
rotation);
xt = ellipticFourierFunction(a,b,T);
s=0.5;
%figure(), plotEllipticFourierDescriptor(a,b,c,d,T,s);
% -----
% Guarda Coeficientes Elípticos de Fourier.
Ca=[Ca a];
Cb=[Cb b];
Cc=[Cc c];
Cd=[Cd d];
% -----
end
% -----
% -----
MCFU1=[MCFU1 Mcu1]; MCFU2=[MCFU2 Mcu2]; MCFU3=[MCFU3 Mcu3];
MCFU4=[MCFU4 Mcu4]; MCFU5=[MCFU5 Mcu5]; MCFU6=[MCFU6 Mcu6];
MCFU7=[MCFU7 Mcu7]; MCFU8=[MCFU8 Mcu8]; MCFU9=[MCFU9 Mcu9];
MCFU10=[MCFU10 Mcu10];
% -----
COEFa=[COEFa Ca]; COEFb=[COEFb Cb]; COEFc=[COEFc Cc];
COEFd=[COEFd Cd];
% -----
% Dividir la imagen original en tres imágenes simples, que representan

```

```

% a cada banda RGB
I12=uint8(I7a);
iR=(Ir(:,:,1));
iG=(Ir(:,:,2));
iB=(Ir(:,:,3));

IR(:,:,1)=iR(:,:,1).*I12; % Plano rojo
IG(:,:,1)=iG(:,:,1).*I12; % Plano verde
IB(:,:,1)=iB(:,:,1).*I12; % Plano azul
% .....
% Calcula características de textura en el plano R
% .....
[L num]=bwlabel(IR,8);
% -----
RTCon=[]; RTene=[]; RTent=[]; RTHom=[]; RTPro=[]; RTTon=[]; RTImp=[];
RTCor=[];
% -----
for n=1:num
    [r, cc] = find(L==n);
    I13 = IR(min(r):max(r),min(cc):max(cc));
    % -----
    angle = (-1)*(Ori(n));
    I14 = imrotate(I13,angle);
    % -----
    se=strel('disk',1);
    I15=imerode(I14,se);
    % Eliminar áreas menores a 500 píxeles
    I16=bwareaopen(I15,500);
    % -----
    I17=uint8(I16);
    I18=I15.*I17; % Multiplicacion de imágenes
    % -----
    % Valores para cada una de las cuatro orientaciones principales,
    % 0°, 45°, 90° y 135° respectivamente, para una distancia de un
    % píxel.
    % -----
    N=4;
    [glcm]=coomat(I18);

    [contraste, correlac, energia, homogen, entropia, probmax, tonalidad, import]=
    cocaract(glcm,N);
    % -----
    RTCor=[RTCor correlac];
    RTene=[RTene energia];
    RTent=[RTent entropia];
    RTHom=[RTHom homogen];
    RTPro=[RTPro probmax];
    RTTon=[RTTon tonalidad];
    RTImp=[RTImp import];
end

```

```

% -----
RTCOR=[RTCOR RTCor]; RTENE=[RTENE RTene]; RTENT=[RTENT RTent]; ...
RTHOM=[RTHOM RTHom]; RTPRO=[RTPRO RTPro]; RTTON=[RTTON RTTon]; ...
RTIMO=[RTIMO RTImp];
% -----
% .....
% Calcula características de textura en el plano G
% .....
[L num]=bwlabel(IG,8);
% -----
GTCon=[]; GTene=[]; GTent=[]; GTHom=[]; GTPro=[]; GTTon=[]; GTImp=[];
GTCor=[];
% -----
for n=1:num
    [r, cc] = find(L==n);
    I19 = IG(min(r):max(r),min(cc):max(cc));
    % -----
    angle = (-1)*(Ori(n));
    I20 = imrotate(I19,angle);
    % -----
    se=strel('disk',1);
    I21=imerode(I20,se);
    % Eliminar áreas menores a 500 píxeles
    I22=bwareaopen(I21,500);
    % -----
    I23=uint8(I22);
    I24=I21.*I23; % Multiplicacion de imágenes
    % -----
    % Valores para cada una de las cuatro orientaciones principales,
    % 0°, 45°, 90° y 135° respectivamente, para una distancia de un
    % píxel.
    % -----
    N=4;
    [glcm]=coomat(I24);

[contraste,correlac,energia,homogen,entropia,probmax,tonalidad,import]=
cocaract(glcm,N);
% -----
GTCon=[GTCon contraste];
GTCor=[GTCor correlac];
GTene=[GTene energia];
GTent=[GTent entropia];
GTHom=[GTHom homogen];
GTPro=[GTPro probmax];
GTTon=[GTTon tonalidad];
GTImp=[GTImp import];
end
% -----
GTCON=[GTCON GTCon]; GTCOR=[GTCOR GTCor]; GTENE=[GTENE GTene];
GTENT=[GTENT GTent]; GTHOM=[GTHOM GTHom]; GTPRO=[GTPRO GTPro];
GTTON=[GTTON GTTon]; GTIMO=[GTIMO GTImp];
% -----

```

```

% .....
% Calcula características de textura en el plano B
% .....
[L num]=bwlabel (IB,8);
% -----
BTCon=[]; BTENE=[]; BTEnt=[]; BTHom=[]; BTPro=[]; BTTon=[]; BTImp=[];
BTCor=[];
% -----
for n=1:num
    [r, cc] = find(L==n);
    I25 = IB(min(r):max(r),min(cc):max(cc));
    % -----
    angle = (-1)*(Ori(n));
    I26 = imrotate(I25,angle);
    % -----
    se=strel('disk',1);
    I27=imerode(I26,se);
    % Eliminar áreas menores a 500 píxeles
    I28=bwareaopen(I27,500);
    % -----
    I29=uint8(I28);
    % Multiplicacion de imágenes
    I30=I27.*I29;
    % -----
    % Valores para cada una de las cuatro orientaciones principales,
    % 0°, 45°, 90° y 135° respectivamente, para una distancia de un
    % píxel.
    % -----
    N=4;
    [glcm]=coomat(I30);

[contraste,correlac,energia,homogen,entropia,probmax,tonalidad,import]=
cocaract(glcm,N);
% -----
BTCon=[BTCon contraste];
BTCor=[BTCor correlac];
BTENE=[BTENE energia];
BTEnt=[BTEnt entropia];
BTHom=[BTHom homogen];
BTPro=[BTPro probmax];
BTTon=[BTTon tonalidad];
BTImp=[BTImp import];
end
% -----
BTCON=[BTCON BTCon]; BTCOR=[BTCOR BTCor]; BTENE=[BTENE BTENE];
BTEnt=[BTEnt BTEnt]; BTHOM=[BTHOM BTHom]; BTPRO=[BTPRO BTPro];
BTTON=[BTTON BTTon]; BTIMO=[BTIMO BTImp];
% -----
% .....
% Calcula características de color en el espacio RGB
% .....
% Plano R

```

```

[a1 b1]=bwlabel(IR,8);
propiedades=regionprops(a1,IR,'MeanIntensity');
[w v]=size(propiedades(:,1));

for (j=1:w)
    rgbR(j)= propiedades(j).MeanIntensity;
end
% -----
% Plano G

[a2 b2]=bwlabel(IG,8);
propiedades=regionprops(a2,IG,'MeanIntensity');
[w v]=size(propiedades(:,1));

for (j=1:w)
    rgbG(j)= propiedades(j).MeanIntensity;
end
% -----
% Plano B

[a3 b3]=bwlabel(IB,8);
propiedades=regionprops(a3,IB,'MeanIntensity');
[w v]=size(propiedades(:,1));

for (j=1:w)
    rgbB(j)= propiedades(j).MeanIntensity;
end
% -----
RGBR=[RGRB rgbR];    RGBG=[RGBG rgbG]; RGBB=[RGRB rgbB];
% -----

% .....
% Calcula características de color en el espacio HSV
% .....
% La función rgb2hsv convierte mapas de colores o imágenes RGB al
% espacio de color HSV.
HSV = rgb2hsv(Ir);
% Para una inspección más cercana del espacio de color HSV,
% el siguiente bloque de código muestra los planos de color
% separados (tono, saturación y valor) de una imagen HSV.
I31=double(I7);
iH =(HSV(:, :,1));
iS =(HSV(:, :,2));
iV =(HSV(:, :,3));

IH( :, :,1)=iH( :, :,1).*I31; % Plano H (Matiz)
IS( :, :,1)=iS( :, :,1).*I31; % Plano S (Saturación)
IV( :, :,1)=iV( :, :,1).*I31; % Plano B (Brillo)
% -----

```



```

% Plano H
[a4 b4]=bwlabel(IH,8);
propiedades=regionprops(a4,IH,'MeanIntensity');
[w v]=size(propiedades(:,1));
for (k=1:w)
    hsvH(k)= propiedades(k).MeanIntensity;
end
% -----
% Plano S
[a5 b5]=bwlabel(IS,8);
propiedades=regionprops(a5,IS,'MeanIntensity');
[w v]=size(propiedades(:,1));
for (k=1:w)
    hsvS(k)= propiedades(k).MeanIntensity;
end
% -----
% Plano V
[a6 b6]=bwlabel(IV,8);
propiedades=regionprops(a6,IV,'MeanIntensity');
[w v]=size(propiedades(:,1));
for (k=1:w)
    hsvV(k)= propiedades(k).MeanIntensity;
end
% -----
HSVH=[HSVH hsvH]; HSVS=[HSVH hsvS]; HSVV=[HSVH hsvV];
% -----
% .....
% Calcula características de color en el espacio CIE 1976 L*a*b*.
% .....
% La función rgb2lab convierte mapas de colores o imágenes RGB al
% espacio de color CIE 1976 L*a*b*.
lab = rgb2lab(Ir);
I32=double(I7);

il =(lab(:, :,1));
ia =(lab(:, :,2));
ib =(lab(:, :,3));

IL( :, :,1)=il( :, :,1).*I32; % Plano L*
Ia( :, :,1)=ia( :, :,1).*I32; % Plano a*
Ib( :, :,1)=ib( :, :,1).*I32; % Plano b*
% -----
% Plano L*
[a7 b7]=bwlabel(IL,8);
propiedades=regionprops(a7,IL,'MeanIntensity');
[w v]=size(propiedades(:,1));

for (k=1:w)
    labl(k)= propiedades(k).MeanIntensity;
end
% -----

```

```

% Plano a*
[a8 b8]=bwlabel(Ia,8);
propiedades=regionprops(a8,Ia,'MeanIntensity');
[w v]=size(propiedades(:,1));
for (k=1:w)
    laba(k)= propiedades(k).MeanIntensity;
end
% -----
% Plano b*
[a9 b9]=bwlabel(Ib,8);

propiedades=regionprops(a9,Ib,'MeanIntensity');
[w v]=size(propiedades(:,1));
for (k=1:w)
    labb(k)= propiedades(k).MeanIntensity;
end
% -----
LABL=[LABL labl]; LABA=[LABA laba]; LABB=[LABB labb];
% -----
% Guarda una matriz con todas las características calculadas.
% -----
MATRIZT=[ARE' PER' LAR' ANC' REC' CIR' EXC' COM' MCFU1' MCFU2' ...
        MCFU3' MCFU4' MCFU5' MCFU6' MCFU7' MCFU8' MCFU9' MCFU10' ...
        COEFa' COEFb' COEFc' COEfd' RTCON' RTCOR' RTENE' RTENT' ...
        RTHOM' RTPRO' RTTON' RTIMO' GTCON' GTCOR' GTENE' GTENT' ...
        GTHOM' GTPRO' GTTON' GTIMO' BTCON' BTCOR' BTENE' BTENT' ...
        BTHOM' BTPRO' BTTON' BTIMO' RGBR' RGBG' RGBB' HSVH' HSVS' ...
        HSVV' LABL' LABA' LABB'];
% -----

```

Anexo 2. Programa para el entrenamiento de la red neuronal RNA1 que clasifica cinco variedades de cebada.

```

close all
clear all
clc
% -----
% NOMBRE DEL FICHERO: RNA1.m
% RECIBE: Matriz de características de 1800 granos de cebada (MAT0).
% DEVUELVE: Red neuronal entrenada (RNA1.mat).
% ALGORITMO EMPLEADO: Algoritmos Levenberg-Marquardt con regulación
% bayesiana.
% AUTOR: Pablo Hernández Santiago
% -----

% Variables de entrada % -----
cebada= xlsread('MAT0.xlsx',1,'B2:AQ1801');
% -----
Area= cebada(:,1);
Perimetro= cebada(:,2);

```

```

Longitud= cebada(:,3);
Rectangularidad= cebada(:,4);
Circularidad= cebada(:,5);
Anchura= cebada(:,6);
Compacidad= cebada(:,7);
MC8= cebada(:,8);
MC10= cebada(:,9);
CorrelacionR= cebada(:,10);
EnergiaR= cebada(:,11);
EntropiaR= cebada(:,12);
HomogeneidadR= cebada(:,13);
ProbMaxR= cebada(:,14);
TonalidadR= cebada(:,15);
ImportanciaR= cebada(:,16);
ContrasteG= cebada(:,17);
CorrelacionG= cebada(:,18);
EnergiaG= cebada(:,19);
EntropiaG= cebada(:,20);
HomogeneidadG= cebada(:,21);
ProbMaxG= cebada(:,22);
TonalidadG= cebada(:,23);
ImportanciaG= cebada(:,24);
ContrasteB= cebada(:,25);
CorrelacionB= cebada(:,26);
EnergiaB= cebada(:,27);
EntropiaB= cebada(:,28);
HomogeneidadB= cebada(:,29);
ProbMaxB= cebada(:,30);
TonalidadB= cebada(:,31);
ImportanciaB= cebada(:,32);
Rojo= cebada(:,33);
Verde= cebada(:,34);
Azul= cebada(:,35);
Matiz=cebada(:,36);
Saturacion= cebada(:,37);
Brillo= cebada(:,38);
LabL= cebada(:,39);
Laba= cebada(:,40);
Labb= cebada(:,41);
clear cebada;
% -----
% Variables de salida
scebada = xlsread('C:\Users\...\xlsx',1,'AR2:AV1801');
ADA=scebada(:,1);
ALI=scebada(:,2);
ARM=scebada(:,3);
ESM=scebada(:,4);
ESP=scebada(:,5);
clear scebada;
% -----
% Vector de datos de entrada
DatosEntrada = [Area Perimetro Longitud Rectangularidad ...

```

```

Circularidad Anchura Compacidad MC8 MC10 CorrelacionR EnergiaR ...
EntropiaR HomogeneidadR ProbMaxR TonalidadR ImportanciaR ...
ContrasteG CorrelacionG EnergiaG EntropiaG HomogeneidadG ...
ProbMaxG TonalidadG ImportanciaG ContrasteB CorrelacionB EnergiaB ...
EntropiaB HomogeneidadB ProbMaxB TonalidadB ImportanciaB ...
Rojo Verde Azul Matiz Saturacion Brillo LabL Laba Labb]';
% -----
% Vector de datos de salida
DatosSalida = [ADA ALI ARM ESM ESP]';
% -----
% Tamaño de la capa oculta
sizeCapaOcultas=80;
% -----
% Las redes de reconocimiento de patrones (patternnet) son las redes
% de alimentación directa que pueden ser entrenadas para clasificar
% entradas de acuerdo a clases objetivo.
% hiddenSizes: Tamaño la de capa oculta.
% Función de entrenamiento: 'trainbr'.
% performFcn: Función del rendimiento 'mse'.
% Utiliza la función de transferencia sigmoidal en la capa oculta,
% y una función de transferencia softmax en la capa de salida.
net = patternnet(sizeCapaOcultas,'trainbr');
net.trainParam.epochs = 200;
net.performFcn = 'mse';
% "trainbr" es una función de la red de formación que actualiza los
% valores de los pesos y bias acuerdo con la optimización Levenberg-
% Marquardt. Minimiza una combinación de errores y pesos al cuadrado,
% y luego determina la combinación correcta a fin de producir una red
% que generalize bien. El proceso se llama regularización bayesiana.
% -----
% División de datos para entrenamiento y prueba.
net.divideParam.trainRatio=80/100;
net.divideParam.testRatio=15/100;
% -----
% Entrenamiento de la red
[net, tr]=train(net, DatosEntrada, DatosSalida);
% -----
% Prueba de la red
% Después de que la red ha sido entrenada, se puede utilizar para
% calcular las salidas de la red. El siguiente código calcula las
% salidas de la red, los errores y el rendimiento general.
SalidaNet = net(DatosEntrada);
Errores = gsubtract(DatosSalida,SalidaNet);
Performance = perform(net, DatosSalida, SalidaNet)
% -----
% Calcula el rendimiento de la red sólo en el conjunto de prueba,
% mediante el uso de los índices de prueba, que se encuentran en
% el registro de entrenamiento.
tInd = tr.testInd;
tstOutputs = net(DatosEntrada(:,tInd));
tstPerform = perform(net,DatosSalida(:,tInd),tstOutputs)
% -----

```

```

%Muestra el diagrama de la red
view(net)
% Traza el rendimiento de entrenamiento y prueba de la red.
figure; plotperform(tr)
% Muestra la matriz de confusión.
figure; plotconfusion(DatosSalida,SalidaNet)
% -----
% Guarda la red neuronal 1 entrenada.
save RNA1
% -----

```

Anexo 3. Programa para el entrenamiento de la red neuronal RNA2 que clasifica granos de cebada e impurezas.

```

close all
clear all
clc
% -----
% NOMBRE DEL FICHERO: RNA2.m
% RECIBE: Matriz de características de 360 granos de cebada y 360
% impurezas (MAT1).
% DEVUELVE: Red neuronal entrenada (RNA1.mat).
% ALGORITMO EMPLEADO: Algoritmos Levenberg-Marquardt con regulación
% bayesiana.
% AUTOR: Pablo Hernández Santiago
% -----
% Variables de entrada
cebada= xlsread('MAT1.xlsx',1,'B2:K2121');
TonalidadR =cebada(:,1);
TonalidadG=cebada(:,2);
TonalidadB=cebada(:,3);
Verde=cebada(:,4);
Azul= cebada(:,5);
L= cebada(:,6);
Brillo= cebada(:,7);
Rojo= cebada(:,8);
ProMaxB= cebada(:,9);
Area=cebada(:,10);
clear cebada;
% Variables de salida
scebada = xlsread('MAT1.xlsx',1,'L2:M2121');
CEB=scebada(:,1);
IMP=scebada(:,2);
clear scebada;
% Vector de datos de entrada
DatosEntrada = [TonalidadR TonalidadG TonalidadB Verde Azul L ...
                Brillo Rojo ProMaxB Area]';
% Vector de datos de salida
DatosSalida = [CEB IMP]';

```

```

% Tamaño de la capa oculta
sizeCapaOcultas=8;
% Crear una red de reconocimiento de patrones
net = patternnet(sizeCapaOcultas,'trainbr');
net.trainParam.epochs = 200;
net.performFcn = 'mse';
% Division de datos para entrenamiento y prueba
net.divideParam.trainRatio=80/100;
net.divideParam.testRatio=15/100;
% Entrenamiento de la red
[net, tr]=train(net, DatosEntrada, DatosSalida);
% Prueba de la red
SalidaNet = net(DatosEntrada);
Errores = gsubtract(DatosSalida,SalidaNet);
Performance = perform(net, DatosSalida, SalidaNet);
% Calcula el rendimiento de la red sólo en el conjunto de prueba,
% mediante el uso de los índices de prueba, que se encuentran en
% el registro de entrenamiento.
tInd = tr.testInd;
tstOutputs = net(DatosEntrada(:,tInd));
tstPerform = perform(net,DatosSalida(:,tInd),tstOutputs)
%Muestra el diagrama de la red
view(net)
% Traza el rendimiento de entrenamiento y prueba.
figure
plotperform(tr)
% Traza la matriz de confusión
figure
plotconfusion(DatosSalida,SalidaNet)
% Guarda la red neuronal 2 entrenada
save RNA2

```

Anexo 4. Mediciones realizadas para calcular el error de reproyección en milímetros.

Cuadro 26. Medidas en píxeles de un milímetro de una regla ubicada en diferentes posiciones dentro del área de la imagen.

Posición de la regla dentro de la imagen	Medida en píxeles
Arriba	7.96
	8
	8.02
	8.02
En medio	8.01
	7.97
	7.98
	7.99
	8.01
Abajo	7.97
	8
	7.98
	8
Promedio	7.990 = 1 mm

Factor de calibración = (1 mm) / (7.990 píxeles) = 0.125146 mm / píxeles

Error de re proyección = 0.49 píxeles.

Error de re proyección = (0.125146 mm / píxeles) *(0.49 píxeles) = 0.0613 mm.

Cuadro 27. Medidas en píxeles de un centímetro de una regla ubicada dentro del área de la imagen.

Medida en píxeles	Error (mm)
83.02	0.3896
84.91	0.6261
84.05	0.5185
85.02	0.6399
84.97	0.6336
82.99	0.3858
84.02	0.5147
Error promedio	0.529

Por cada centímetro se encontró un error promedio de 0.529 mm.