

Clasificador automático de la calidad de los granos de maíz

Anabella Silvia Saleres¹, Paula Tristan², and Laura Felice²

¹ UNICEN Quequén, Universidad Nacional del Centro de la Provincia de Buenos Aires,
Calle 508 N° 881 (7631), Quequén, Argentina

asaleres@quequen.unicen.edu.ar

² INTIA, Facultad de Ciencias Exactas, Universidad Nacional del Centro de la Provincia de
Buenos Aires

Paraje Arroyo Seco, Campus Universitario (7000), Tandil, Argentina

{ptristan,lfelice}@exa.unicen.edu.ar

Resumen. Actualmente, la determinación de la calidad de los cereales es realizada de forma manual por peritos clasificadores de granos previo a la etapa de comercialización. En este trabajo se presenta una herramienta de software web que permite determinar el grado de calidad de una muestra de maíz en forma automática, a partir de una imagen de la misma. Se implementaron algoritmos de procesamiento de imágenes para corregir distorsiones provocadas principalmente por el proceso de captura. Se utilizó el algoritmo de clasificación K-Means y se desarrolló una función que permite calcular el peso hectolítrico en relación al área de la muestra. Los resultados obtenidos por la aplicación para los grados 1 y 2, se aproximan a los medidos por los peritos. Sin embargo, los de grado 3 no han sido semejantes dado que las submuestras seleccionadas no han sido representativas.

Palabras Claves. Calidad de cereales, Procesamiento de Imágenes, Herramienta Web.

1 Introducción

Los cereales son un elemento esencial en la alimentación y economía de todos los pueblos. Por lo general, su producción es estacional y no siempre cercana a los centros de consumo, lo que genera un complejo mecanismo para lograr el objetivo de que lleguen en forma oportuna a todos los consumidores. Nuestro país, productor de cereales y oleaginosas por excelencia, destina una parte de la producción de granos para autoconsumo, ya sea como semilla, alimento humano o para el ganado. Otra parte es comercializada a través de diversos canales como los intermediarios, acopiadores, importadores, exportadores. Para la comercialización es muy importante conocer la oferta, precios, condiciones físicas o de calidad de los productos, formas y tiempos de entrega [1].

Particularmente, el maíz es uno de los cereales más importantes del mundo utilizado para la producción de aceite vegetal, alimentación animal y producción de biocombustibles. Según anunció la consultora especializada, Oil World, en la Argentina, se calcula que los productores agropecuarios aumentarán el área destinada a la producción de maíz para la cosecha 2018/2019. Se estiman 7 millones de hectáreas sembradas, convirtiéndose en el segundo cereal en la escala seguida de la soja, con 18,5 millones de hectáreas sembradas [2].

La calidad de los cereales se define como el conjunto de defectos que desmejora una partida de granos [3]. Estos defectos pueden producirse por diversos motivos como condiciones climáticas desfavorables, degradación del suelo, adversidades biológicas e inconvenientes producidos durante las prácticas agronómicas. Los granos se deterioran en planta, durante la cosecha o en los depósitos cuando no se les proporcionan los cuidados adecuados. Las alteraciones del estado natural y del nivel de sanidad de los granos se clasifican en varias categorías: granos dañados o con avería, granos picados, presencia de materiales extraños, olores comercialmente objetables, presencia de semillas indeseables, granos quebrados y/o chuzos, entre los más importantes. Los defectos mencionados, conocidos como determinaciones de calidad, son aquellos que deben ser analizados durante el proceso de la estimación de la calidad [4], de acuerdo a la cantidad o intensidad en la que cada uno de ellos se encuentre presente en la muestra.

El proceso de determinación de la calidad es una actividad que, a pesar de la evolución de la tecnología en las prácticas agrícolas, continúa realizándose de forma manual por los técnicos especialistas de laboratorio. Las metodologías de clasificación no han cambiado demasiado desde sus orígenes y la efectividad del sistema de inspección de granos depende en gran medida de la capacidad y experiencia que posea el perito para muestrear, inspeccionar, clasificar y certificar los distintos granos. Existen además, cuestiones psicofísicas como stress o cansancio, y factores externos como luminosidad o posición de trabajo, que pueden influir en la persona al momento de realizar la clasificación.

Por otra parte, los productores no conocen la calidad y/o la condición de sus granos hasta que se desarrolla el proceso de comercialización en donde se fija su valor. Esta situación, elimina la posibilidad de tomar acciones correctivas, como ajustes de la maquinaria en el momento de la cosecha, con el objetivo de minimizar -en la medida de lo posible- los factores externos que pueden afectar o disminuir de alguna forma la calidad de los granos.

Analizando las situaciones antes expuestas, en este trabajo se propone desarrollar una herramienta que permita determinar el grado de calidad de una muestra de maíz en forma automática, a partir de la imagen de una muestra. De este modo, productores, acopiadores y exportadores podrán obtener de forma ágil, precisa y eficiente toda la información de las mediciones de cada uno de los factores determinantes de la calidad, simplemente enviando una imagen de la muestra de su cosecha de maíz desde una computadora o un dispositivo móvil.

2 Evaluación de la Calidad de Granos de Cereales

En la Argentina, la clasificación de granos se rige en base a normas de calidad confeccionadas por el Estado, de las cuales existen dos tipos: los estándares y las bases estatutarias [3].

Los estándares se caracterizan por asignar a la mercadería, de acuerdo a la calidad de la misma, un grado determinado. En cambio, las bases estatutarias, no se manejan por grados, sino que de acuerdo a la calidad de la mercadería, bonifican o rebajan teniendo en cuenta porcentajes de tolerancias, de los distintos rubros de calidad. Los estándares definen dos tipos de rubros, los de calidad que determinan grados y los que determinan la condición de comercialización.

Los grados pueden ser tres: El Grado 1 indica calidad superior. El Grado 2 determina calidad intermedia, y el Grado 3: determina calidad inferior, en consecuencia la mercadería con este grado recibirá un descuento sobre el precio base de compraventa. Para determinar el grado de una mercadería, se encuadra a cada rubro de calidad en el grado correspondiente y luego se analizan globalmente todos los rubros que determinan grado. Así, el rubro que esté encuadrado en el peor grado será el determinante del grado de la mercadería. En consecuencia, para que una mercadería sea Grado 1, todos los rubros tendrán que estar en grado 1, el solo hecho de que un rubro no esté en ese grado, determinará otro grado. Los rubros de calidad determinantes del grado para el maíz son el peso hectolítrico [1], los granos dañados (brotados, fermentados, podridos, calcinados o con verdín), la materia extraña y los granos quebrados.

Se puede observar (Tabla 1: Norma de calidad para la comercialización del maíz-Norma XII) el cuadro de tolerancia máxima (o mínimos para el peso hectolítrico) para cada rasgo de calidad [4].

Tabla 1. Norma de calidad para la comercialización del maíz-Norma XII.

Grado	Peso Hectolítrico Mínimo Kg./hl.	Tolerancias máximas para cada grado		
		Granos Dañados %	Granos Quebrados %	Materia Extraña %
1	75	3	2	1
2	72	5	3	1.5
3	69	8	5	2

3 Estado del Arte

A continuación se detallan algunos proyectos de investigación de clasificación de maíz. En el artículo [5] se presenta una metodología experimental que identifica con mayor precisión y rapidez distintos tipos comerciales de maíz, lo que permitiría

orientar con eficiencia los destinos de industrialización del grano. El nuevo sistema todavía se encuentra en fase experimental, distingue en segundos el tipo comercial de maíz, lo que permite fijar de modo rápido y preciso la proporción de los componentes del grano.

En el trabajo [6] se ha desarrollado un algoritmo capaz de segmentar y clasificar imágenes. La segmentación está destinada a separar la planta de la imagen original, mientras que la clasificación identifica qué imágenes pertenecen a las dos clases definidas. Se aplica una red neuronal convolucional -CNN sigla en Inglés- para discriminar las plantas de maíz de las malezas en tiempo real, en las etapas iniciales de desarrollo del cultivo.

En [7], un artículo publicado recientemente, se detalla la utilización de una CNN y se presenta una arquitectura para la clasificación de la enfermedad de la hoja del maíz. Las CNN propuestas están capacitadas para identificar cuatro clases diferentes (tres enfermedades y una clase saludable).

4 Metodología Propuesta

El objetivo principal de este trabajo se fundamenta en el diseño e implementación de un mecanismo de evaluación para cada uno de los rubros de calidad de maíz (Tabla 1) de manera automática.

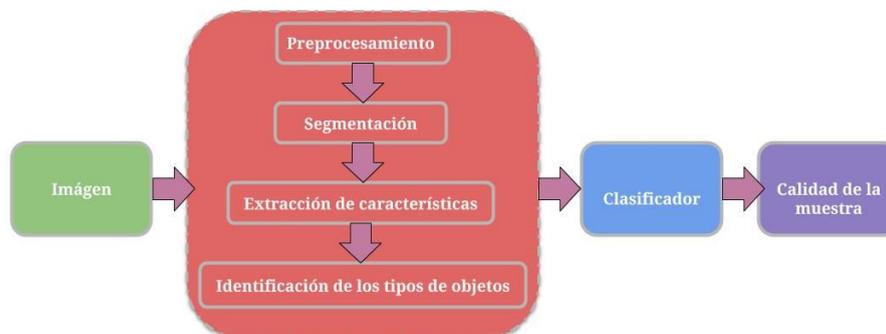


Fig. 1. Esquema general del proceso.

El esfuerzo para conseguir imágenes de muestras para poder entrenar una red neuronal que permita clasificar los distintos tipos de clases (maíz, grano partido, grano dañado, semilla de chamico y materia extraña) es complejo. Debido a esto, se desarrolló un modelo utilizando técnicas de procesamiento digital de imágenes, y un mecanismo de clasificación estándar. Además, como las condiciones climáticas y enfermedades que afectan las cosechas cambian año a año, las determinaciones de calidad también cambian al mismo ritmo.

En esta sección se presenta la metodología aplicada que extiende una versión anterior [8], ofreciendo un importante número de mejoras. En la Figura 1 se presenta un esquema de la propuesta para el clasificador de maíz.

A continuación se describen las etapas involucradas en el procesamiento de la imagen.

4.1 Captura de la Imagen

Para dar inicio a este proceso, se debe dispersar una muestra de maíz de 50 g. sobre una superficie plana, tratando de separar los objetos de la muestra para evitar que queden superpuestos. Se debe ser sumamente cuidadosos en este momento ya que el proceso de homogeneización de la muestra definido por la norma de calidad es bastante riguroso, y de no respetarlo puede concluir en una muestra no representativa, como por ejemplo que algunos los granos pequeños queden en el fondo del recipiente contenedor.

La superficie, debe ser una hoja de tamaño A3 de color celeste con el borde de un rectángulo impreso centrado en la cartulina. De este modo, la muestra queda contenida en el rectángulo. El plano de enfoque, que es el plano donde se coloca la cartulina donde se dispersa la muestra, deberá ser perpendicular al eje del lente de la cámara.

Respecto a la iluminación, si el ambiente tiene una buena iluminación solar, se generan sombras que complica el proceso de detección del contorno de los objetos e interfiere en la intensidad del color en estas zonas. Por lo tanto, para difuminar la luz, suavizar las sombras y realizar una buena captura de la imagen, se utiliza el flash de la cámara en un ambiente cerrado con poca luz.

En la Figura 2 se puede observar las diferentes variantes antes mencionadas para obtener una fotografía de una muestra de maíz con el sistema de referencia elegido.

4.2 Pre-procesamiento de la Imagen

Esta etapa tiene como finalidad eliminar aquellos ruidos o elementos en la imagen que pueden distorsionar el proceso de identificación de objetos correspondiente a la muestra de maíz. Los pasos involucrados en esta etapa, incluyen los procesos clásicos de realce de imágenes como: umbralización de la imagen, transformaciones geométricas o elásticas, procesos morfológicos y binarización [10][11][12]. El resultado generado por esta etapa queda visualizado en la Figura 3.

Para definir el umbral, la aplicación permite seleccionar uno o más fragmentos de la imagen que determinan el fondo de la misma. Este valor queda determinado por el valor mínimo y máximo de matiz, saturación y brillo (HSV) [12] de cada píxel perteneciente al/los fragmento/s seleccionado/s asociado/s al fondo de la imagen.

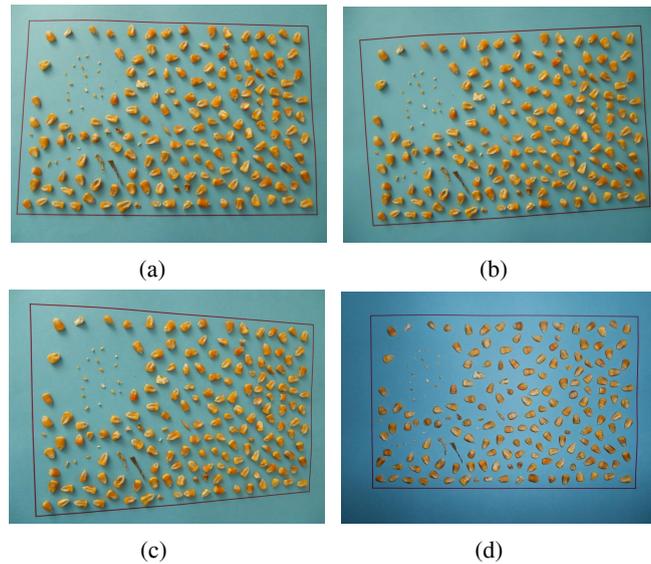


Fig. 2. Alternativas de diferentes capturas: a) Imagen con iluminación solar. b) Imagen con iluminación solar donde el rectángulo presenta una pequeña rotación en relación a la fotografía obtenida. c) Imagen con iluminación solar donde se modifica el ángulo de la cámara levemente y ésta no queda perpendicular al fondo. d) Imagen con flash de la cámara en un ambiente cerrado con poca luz.

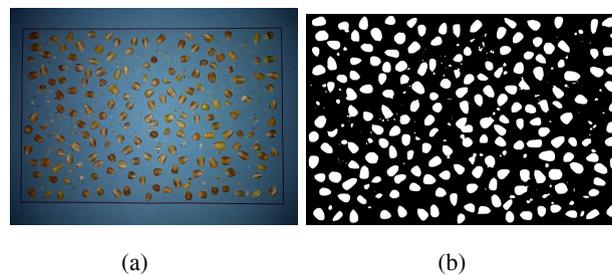


Fig. 3. Pre-procesamiento de la imagen: a) Imagen de entrada. b) Imagen de salida.

4.3 Segmentación de la Imagen

El objetivo de la segmentación se basa en realizar una partición de la imagen en regiones significativas. Con el propósito de obtener una lista de objetos, sobre los cuales se pueden medir las características que permitan determinar a qué tipo pertenece cada uno. En esta etapa, mediante la aplicación de filtros y algoritmos conocidos se logra separar los elementos de interés de la muestra. Posteriormente, el resultado de esta etapa se utilizará en las sucesivas, para su descripción, reconocimiento e interpretación.

Para los casos que el contorno de los objetos no es continuo se utiliza la técnica cierre de contorno que permite completar el contorno de un objeto cuando los puntos que forman el mismo no son contiguos. Por lo tanto, cada vez que se reconoce un nuevo objeto, se debe evaluar si este corresponde a un único objeto o a varios que están unidos. Esta tarea se basa en la idea de que los granos de maíz y los objetos que pueden aparecer en la muestra tienen una forma bastante circular. Si bien el estudio de las características es una etapa posterior en el procesamiento y conceptualmente diferente a la segmentación, se realiza una extracción de características simple para detectar objetos a separar.

Una vez que se tiene el contorno cerrado de un objeto se pueden evaluar fácilmente la circularidad y el aspect ratio del objeto y analizar los valores que toman cuando el contorno corresponde a un único objeto o a varios que están juntos. Al ser los objetos circulares es de esperar que sus contornos sean convexos, pero cuando esto no ocurre es muy probable que se trate de dos objetos que están juntos y es necesario separarlos.

Las zonas del contorno donde el objeto no es convexo constituyen puntos de posible división. Por lo tanto, se determina que un objeto necesita ser dividido si la cantidad de puntos de posible división es mayor a uno. Cuando esto ocurre, se debe evaluar cuáles de todos los posibles pares de puntos constituyen caminos válidos para dividir el objeto y se los divide mediante la línea que une esos puntos.

4.4 Extracción de Características

Una vez segmentada la imagen y extraído el contorno de los objetos, se procede a extraer las características de cada uno. Aunque existen diversos métodos para la selección de estas, en [8] se analizaron las características geométricas que dan a conocer la forma de cada uno de los objetos. Se seleccionaron descriptores de tipo morfológico y de texturas, que representan la forma y el color que observan los peritos para realizar su análisis. Estas características se detallan a continuación:

- **Circularidad:** evalúa cuán semejante es el contorno del objeto a un círculo. Se elige este descriptor debido a que los granos de maíz tienen forma muy circular.
- **Diámetro:** permite diferenciar el grano bueno del grano quebrado, por lo cual su correcta medición es de vital importancia para el análisis. El diámetro de un objeto se calcula como el máximo entre el alto y el ancho del mínimo rectángulo contenedor (MRC) del objeto.
- **Color:** se utiliza la técnica de Histograma que permite distinguir un objeto de otro por su color. Para no perder la información del color de cada pixel se evalúa el histograma normalizado por cada componente de color.

En este caso se utiliza el modelo HSV, de modo que para cada objeto se calcula un histograma para el componente H, uno para el S y otro para el V. Para realizar la comparación de histogramas se utiliza la distancia de Bhattacharya. Ésta mide la semejanza de dos distribuciones discretas de probabilidad. Se utiliza generalmente para medir la posibilidad de separación de clases dentro de una clasificación.

El resultado del proceso es el factor de comparación entre los dos histogramas. Este factor es cercano a uno si los histogramas se parecen, es uno si son iguales, y cercano a cero si no tienen parecido alguno.

- **Aspect Ratio:** es la relación entre el ancho y el alto del objeto. Se calcula como: ancho sobre alto si el ancho es menor que el alto, o viceversa. Donde el valor obtenido se encuentra entre 0 y 1, siendo 1 cuando el alto y el ancho del objeto son iguales.

4.5 Identificación de los Diferentes Tipos de Objetos

En la etapa anterior se definieron los rasgos más determinantes para identificar los distintos tipos de objetos que se encuentran en una muestra. Para poder diferenciar cada una de estos tipos de objetos es necesario definir el valor promedio que puede adquirir un objeto para que pertenezca a un determinado tipo. Para este análisis se determinan los rasgos característicos de cada tipo identificado en una muestra.

Los diferentes tipos de objetos identificados en una muestra son: maíz, grano partido, grano dañado, semilla de chamico y materia extraña.

El método utilizado en [8] consiste en definir los rasgos o características que indiquen la pertenencia o no del objeto a la clase. El valor característico del rasgo para una clase determinada, idealmente, permite diferenciar dicha clase de otra en ese rasgo. Por ejemplo, se puede diferenciar un “Grano quebrado” de un “Maíz” conociendo su diámetro. Por otra parte, las semillas de chamico al tener una forma circular, el valor de circularidad y aspect ratio es cercano a 1. Generalmente el color es marrón oscuro homogéneo en toda su superficie. Para que un objeto pertenezca a la clase Chamico la distancia de Battacharya [9] entre los histogramas HSV de la clase y los histogramas HSV del objeto, debe ser mayor a un valor umbral cercano a 1. Además, se considera materia extraña a todo objeto que no pertenece a ninguna de las clases detalladas anteriormente.

Para cada una de las clases identificadas se realizaron las mediciones de cada uno de los rasgos identificados como determinantes a priori, de forma de poder evaluar si los descriptores o rasgos seleccionados para cada clase cumplen con las propiedades expuestas. Esta medición se llevó a cabo a partir de 400 ejemplares de granos de maíz, 84 de grano partido, 8 de grano dañado, 69 de materia extraña y 18 semillas de chamico.

4.6 Clasificación por Objeto

Una vez que la imagen ha sido satisfactoriamente segmentada y han sido extraídas las características para cada objeto, se procede a determinar el tipo al que finalmente pertenece éste. Si bien existen diferentes técnicas para resolver este tipo de problemas,

el presente trabajo propone una alternativa de clasificación, que requiere un trabajo minucioso, con resultados satisfactorios.

Con la idea básica del método de clasificación K-Means [13] y algunas modificaciones (según la necesidad del problema a resolver), se especifican a continuación los pasos del algoritmo que permite clasificar a los objetos según el conjunto de características determinantes de cada tipo:

Paso 1. Inicialización: Se define el conjunto de objetos a clasificar (que son los objetos pertenecientes a la muestra), el número de grupos (constituido por cada uno de los tipos: Maíz, Grano Partido, Grano Dañado, Chamico y Materia Extraña.) y un centroide por cada grupo. Para cada grupo se determina que el centroide queda determinado como el conjunto de valores asociados a dichos rasgos. Éste valor es calculado como el promedio entre los valores mínimo y máximo para cada rasgo, con la salvedad que el centroide correspondiente al grupo del tipo Materia Extraña no se define con ningún valor ya que es el grupo por defecto. Allí se asignan los objetos que no pertenecen a ninguno de los otros grupos.

Paso 2. Clasificación: Para cada objeto, se calcula su distancia a cada centroide, menos para el de tipo Materia Extraña, y se determina el más cercano. Siempre y cuando el valor del objeto no exceda en un porcentaje predefinido al valor del centroide, el objeto es incorporado al grupo relacionado con ese centroide. En caso contrario, se determina que el objeto corresponde al grupo del tipo Materia Extraña. La distancia a cada centroide se calcula como la sumatoria para cada rasgo de la distancia (diferencia) entre el valor del centroide y del objeto asociado a dicho rasgo.

Paso 3. Cálculo de centroides: Para cada grupo generado en el paso anterior se vuelve a calcular su centroide.

Paso 4. Condición de convergencia: Se converge cuando no existe un intercambio de objetos entre los grupos. Si la condición de convergencia no se satisface, se repiten los pasos dos, tres y cuatro del algoritmo.

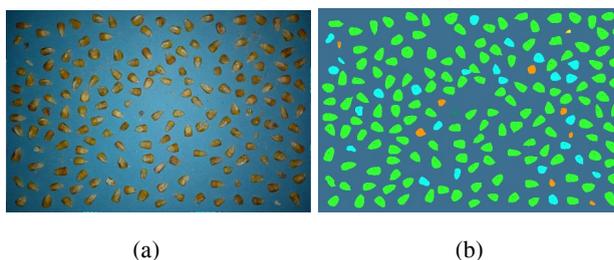


Fig. 4. Clasificación K-Means de los objetos de una muestra: a) Imagen de entrada. b) Imagen de salida

Como resultado de este algoritmo, se obtiene a qué tipo de objeto pertenece cada uno de los objetos de la muestra. En la Figura 4-b se puede observar la clasificación de cada uno de los objetos detectados en la muestra. Los objetos clasificados como maíz amarillo se encuentran pintados de color verde claro, los objetos pertenecientes

al maíz colorado en turquesa, los granos dañados en color naranja, los granos partidos de color verde oscuro, las semillas de chamico en magenta y los objetos correspondiente a materia extraña los podemos visualizar en color amarillo.

4.7 Determinación del Grado de Calidad y Descuentos

A fin de evaluar la calidad de la mercadería de una muestra de maíz, tal como se indica en la Tabla 1, se necesita conocer el porcentaje de granos dañados, de granos quebrados y de materia extraña, la cantidad de semillas de chamico, el porcentaje de humedad y el peso hectolítrico. Para poder obtener los tres primeros, se calcula el porcentaje del área ocupada respecto al área total de los objetos de la muestra, dado que es la única forma de determinar esta magnitud a partir de una imagen. Respecto a la cantidad de semillas de chamico, solo se cuenta la cantidad de objetos que tiene asociado la clase chamico y se ajusta la cuenta al duplicado de la misma. Esto es debido a que cantidad de objetos asociados a esta clase corresponde a una muestra de 50 g..

La humedad de la muestra es un dato que se tiene que conocer a priori para poder obtener el grado de calidad de la misma. Esto es posible porque en la actualidad es muy común que los productores o contratistas rurales que realizan la cosecha, posean el dispositivo que permite determinar el grado de humedad de una muestra de cereal.

Para determinar el peso hectolítrico de una manera sencilla se define una función que permite calcular dicho valor a partir de una imagen de una muestra de maíz. Para esto, se desarrolló una función lineal por intervalos, donde el área y el peso hectolítrico son las variables involucradas.

Se tomaron muestras certificadas por los peritos de la Cámara Arbitral de Cereales de Bahía Blanca [14] y por los peritos de la Cooperativa General Necochea [15], que determinan el valor del peso hectolítrico. Se seleccionó para cada una de ellas una submuestra de 50 g., y se les aplicó el método definido en este trabajo determinando el valor del área total de la muestra. Con estos datos, se definió la función lineal por tramos del Peso Hectolítrico (eje Y) en función del Área (eje X).

Para determinar el valor de peso hectolítrico a partir de una imagen, la aplicación calcula el área total de la misma y determina cual es el valor almacenado más próximo a dicha área, tanto inferior como superiormente. Dado que estos dos valores tienen asociado su correspondiente valor de peso hectolítrico medido por los peritos, se procede a construir la ecuación de la recta que pasa por dos puntos. Así, el peso hectolítrico se determina evaluando el valor obtenido del área en la ecuación anteriormente definida.

Por último, teniendo valorizadas las determinaciones, se deduce el grado de calidad de la muestra y consecuentemente las bonificaciones o descuentos establecidos en los estándares.

5 Desarrollo de la Aplicación

La arquitectura que se utilizó para el desarrollo de la aplicación web fue el Modelo-Vista-Controlador (MVC) de Spring Framework [16] para la separación entre las distintas capas de la aplicación. Se utilizó Hibernate [17] para la persistencia y MySQL [18] como sistema de gestión de base de datos que permite el mapeo objeto-relacional de la base de datos. Para la gestión, se usó Maven [19], y Apache Tomcat [20] para el despliegue de la aplicación.

La herramienta web desarrollada permite realizar la clasificación de granos de maíz y ser accedida desde la web a través de una fotografía digital de la muestra de maíz.

Debido a las variantes de iluminación que se pueden generar en una fotografía digital durante el proceso de la captura de la misma, la aplicación permite seleccionar uno o más fragmentos de la imagen que determinarán el fondo. Una vez cargada la imagen y seleccionado el fragmento de la imagen que pertenece al fondo de la misma, se deberá ingresar el valor de la humedad de la muestra para poder finalmente comenzar con la clasificación de la muestra de forma totalmente automática. A modo de ejemplo, en la Figura 5 se visualiza la clasificación realizada de forma automática por la aplicación desarrollada.



Fig. 5. Aplicación web - Resultado de la clasificación.

6 Resultados Obtenidos

La aplicación desarrollada permite evaluar la calidad de la muestra de maíz mediante una sola imagen, aplicando técnicas de procesamiento de imágenes y un mecanismo de clasificación no supervisado. En la Tabla 2 se visualizan los resultados comparativos medidos por los técnicos especialistas y los obtenidos por la aplicación. Estos resultados corresponden a las cinco muestras analizadas por los peritos de la Cámara Arbitral de Cereales de Bahía Blanca [14] y las seis muestras analizadas por los peritos de la Cámara Arbitral de la Bolsa de Cereales de Buenos Aires [21].

Tabla 2. Resultados comparativos entre los peritos clasificadores de granos y la aplicación web desarrollada.

Muestra N°	Grado	Grano Dañado		Materia Extraña		Grano Quebrado		Peso Hectolítrico		
		Perito	App.	Perito	App.	Perito	App.	Perito	App.	
1	1	1	2.00	2.55	0.14	0.31	0.08	0.08	76.20	76.12
2	1	1	1.30	1.56	0.02	0.07	0.68	0.28	76.12	75.35
3	1	1	1.90	1.37	0.04	0.00	1.04	0.03	76.30	75.43
4	2	2	1.20	0.86	0.10	0.12	0.40	0.18	72.60	72.24
5	2	2	4.00	3.69	0.20	0.14	0.10	0.09	73.80	73.15
6	2	2	1.40	1.84	0.10	0.31	0.50	0.55	72.20	72.40
7	2	2	1.60	1.17	0.10	0.09	0.80	0.28	73.40	72.01
8	2	2	1.92	2.04	0.02	0.00	2.31	0.73	75.07	74.67
9	3	3	2.08	2.18	0.11	0.44	3.66	3.11	73.25	70.45
10	3	3	1.86	5.05	0.40	0.15	4.02	0.83	75.10	72.20
11	3	3	1.94	3.44	0.17	1.24	3.11	0.29	73.49	72.59

Tabla 3. Resultados estadísticos para el rubro de calidad Grano Dañado y Materia Extraña.

Grado N°	Grano Dañado				Materia Extraña			
	Perito	App.	Perito	App.	Perito	App.	Perito	App.
	\bar{x}	\bar{x}	σ	σ	\bar{x}	\bar{x}	σ	σ
1	1.73	1.83	0.38	0.63	0.07	0.13	0.06	0.16
2	2.02	1.92	1.14	1.10	0.10	0.13	0.06	0.10
3	1.96	3.56	0.11	1.44	0.23	0.61	0.15	0.56

Tabla 4. Resultados estadísticos para el rubro de calidad Grano Quebrado y Peso Hectolítrico.

Grado N°	Grano Quebrado				Peso Hectolítrico			
	Perito	App.	Perito	App.	Perito	App.	Perito	App.
	\bar{x}	\bar{x}	σ	σ	\bar{x}	\bar{x}	σ	σ
1	0.60	0.13	0.48	0.13	76.21	75.63	0.09	0.42
2	0.82	0.37	0.87	0.27	73.41	72.89	1.12	1.08
3	3.60	1.41	0.46	1.50	73.95	71.75	1.01	1.14

Se puede observar en la Tabla 2 que los resultados obtenidos por la aplicación han sido similares a los analizados por los profesionales experimentados. En consecuencia, se estudiaron los resultados estadísticos de las pruebas analizadas. En la Tabla 3 se puede observar para las once muestras analizadas, el valor medio y desvío estándar para los resultados medidos por los peritos y los obtenidos por la aplicación, para el rubro grano dañado y materia extraña. Del mismo modo, en la Tabla 4 se puede observar el valor medio y desvío estándar para el rubro grano quebrado y peso hectolítrico para las mismas once muestras anteriormente mencionadas.

El análisis comparativo concluye que los resultados obtenidos por la aplicación correspondientes a los grados 1 y 2, se aproximan a los medidos por los peritos. Sin embargo, para los resultados generados de las muestras de grado 3, los valores no han sido semejantes a los medidos por los especialistas, dado que las submuestras seleccionadas no han sido homogeneizadas correctamente.

Así mismo, varias de las pruebas antes expuestas se repitieron utilizando capturas con diferentes resoluciones, lo que permite concluir que la resolución recomendada es de 3 Mpx. Utilizar imágenes con menos resolución puede provocar error en la clasificación de los objetos, mientras que utilizar imágenes de resolución superior incrementa el tiempo de proceso sin proveer mejoras notables en los resultados.

7 Conclusiones y Trabajo Futuro

La aplicación desarrollada extendió la aplicación de escritorio existente [8] para la clasificación de granos a un entorno web, posibilitando la evaluación de la calidad de las muestras desde cualquier dispositivo con acceso a Internet. En este sentido, no es ajeno a que la revolución tecnológica también ha llegado al sector agropecuario con cada vez más profesionales de diferentes disciplinas que se agrupan para desarrollar aplicaciones, pensando en facilitar sus tareas.

Además, esta aplicación incorpora un mecanismo de clasificación no supervisada como K-Means, mejorando los resultados previos.

En base a los análisis de las pruebas realizadas y la interacción con los profesionales del área se pudo perfeccionar la herramienta incorporando la funcionalidad de la estimación del peso hectolítrico de manera satisfactoria.

No obstante a los resultados obtenidos, en general satisfactorios, resulta imprescindible analizar alternativas de mejoras. Una alternativa sencilla sería extender la aplicación a una arquitectura móvil promoviendo una nueva oportunidad para ampliar las facilidades de acceso.

Por otra parte, la inteligencia artificial se ha afianzado en los últimos años como la gran tendencia en el desarrollo de software y tecnología. En particular, Deep Learning [22] que es una técnica basada en redes neuronales convolucionales que permite aprender de las características de los objetos permitiendo así su posterior reconocimiento automático. Existen hoy día varias alternativas de desarrollo de esta tecnología para clasificación automática en imágenes, con lo cual, avanzar en este sentido presenta un nuevo desafío. Cualquiera sea la alternativa de continuidad de este tipo de herramientas, es fundamental trabajar colaborativamente con los peritos y con las instituciones oficiales que determinan calidad de granos en nuestro país, para obtener un trabajo interdisciplinario que garantice el éxito.

Finalmente, una vez perfeccionada la herramienta, resultaría beneficioso comenzar a ampliar la base de conocimiento del clasificador incluyendo otros granos, y con

cada uno de ellos las determinaciones que su condición de comercialización involucra.

Referencias

1. Mora, M.: Glosario técnico sobre factores de calidad en granos básicos. Organización de las Naciones Unidas para la Agricultura y la Alimentación. Costa Rica. (1997)
2. Calzada, J., Rozadilla, B.: Área sembrada en Argentina para la campaña 2018/19. Las predicciones de Oil World. Bolsa de Comercio de Rosario (2019)
3. Pepa, R. C.: "Incidencia de la calidad en el precio de maíz. Área de Chapaleofú, provincia de La Pampa" Facultad de Agronomía. Argentina (2013)
4. Secretaría de agricultura, ganadería, pesca y alimentación del ministerio de economía y producción de la República Argentina: Muestreo en granos "Norma XXII". <http://servicios.infoleg.gob.ar/infolegInternet/anexos/25000-29999/28301/norma.htm> (1994)
5. Weber, C., Dai Pra, A. L., Passoni, L. I. Rabal, H. J., Trivi, M., & Poggio Aguerre, G. J. Determination of maize hardness by biospeckle and fuzzy granularity. *Food Science & Nutrition*. 2(5): 557– 564 (2014).
6. Alimboyong, C.R., Hernandez, A. A., Medina, R. P. "Classification of Plant Seedling Images Using Deep Learning", Region 10 Conference TENCON 2018 - 2018 IEEE, pp. 1839-1844. (2018).
7. Ahila Priyadharshini, R., Arivazhagan, S., Arun, M. and Mirmalini, A. "Maize leaf disease classification using deep convolutional neural networks". *Neural Comput & Applic* (2019).
8. Giorgetti, O., Colavita, S.: Clasificación de Granos (Tesis de grado). UNICEN, Fac de Cs. Exactas. Argentina (2012)
9. Naik, N., Patil, S., and Joshi, M. A scale adaptive tracker using hybrid color histogram matching scheme. In *Emerging Trends in Engineering and Technology (ICETET)*, 2009.
10. Jain, A.: "Fundamentals of Digital Image Processing" Prentice-Hall (1989)
11. Castleman, K.: *Digital Image Processing*. Ed. Prentice Hall, New Jersey (1996)
12. Gonzalez, C., Woods, R.: *Digital Image Processing*. Addison Wesley Publishing Co. Massachusetts (1992)
13. Pollard, D.: Strong Consistency of K-Means Clustering. *The Annals of Statistics*, Vol. 9 No 1, 135140 (1981)
14. Cámara Arbitral de Cereales de Bahía Blanca: <http://www.cacbb.com.ar/index.html> (2019)
15. Cooperativa General Necochea: <http://coopnecochea.com/web/> (2019)
16. Universidad de Alicante, Departamento de Ciencia de la Computación e Inteligencia Artificial: <http://www.jtech.ua.es/j2ee/publico/spring-2012-13/sesion03-apuntes.html> (2019)
17. Hibernate: <https://hibernate.org/> (2019)
18. Oracle Corporation: MySQL 8.0 Reference Manual. <https://dev.mysql.com/doc/refman/8.0/en/> (2019)
19. The Apache Software Foundation: Maven Documentation. <http://maven.apache.org/guides/> (2019)
20. The Apache Software Foundation. Apache Tomcat 8. <https://tomcat.apache.org/tomcat-8.5-doc/index.html> (2019)
21. Cámara Arbitral de la Bolsa de Cereales de Buenos Aires. <http://www.cabcbue.com.ar/#/> (2019)
22. Goodfellow, I, Bengio, Y, Courville, A: *Deep Learning* (2016)