



DETERMINACIÓN DE LOS PORCENTAJES DE PALO EN LA YERBA MATE MEDIANTE TÉCNICAS DE INTELIGENCIA ARTIFICIAL

Fabian Edgardo Favret ¹

Karina Eckert ²

Analía Felten ³

Gabriela Sandberg ⁴

RESUMEN: El contenido de palo en la yerba mate elaborada con palo es un factor determinante de su calidad. Actualmente, la determinación del contenido del mismo está dada oficialmente por la zaranda; un método no muy preciso, donde la molienda fina que pasa la malla de la zaranda es considerada hoja. Este trabajo propone un modelo para la determinación del nivel de contenido de palo en la yerba mate, mediante el algoritmo de clasificación Naive Bayes (NB) y Redes Neuronales Artificiales (RNA) para el reconocimiento de patrones en imágenes digitalizadas. El prototipo incluye la preparación de las muestras, adquisición de las imágenes, extracción de las características mediante descriptores de imágenes, definición del conjunto de datos para los vectores de entrada, experimentos y análisis de los resultados obtenidos. El modelo RNA tuvo un correcto desempeño y se lo puede considerar un método confiable para la determinación del porcentaje de palos en la yerba mate.

PALABRAS CLAVES: Inteligencia Artificial, Naive Bayes, Redes Neuronales Artificiales, Análisis de Imagen, Yerba Mate, Contenido de Palo.

¹ Universidad Gastón Dachary - fabianfavret@gmail.com

² Universidad Gastón Dachary - karinaeck@gmail.com

³ Universidad Gastón Dachary - cosmica01@gmail.com

⁴ Universidad Gastón Dachary - gabriela.sandberg@gmail.com

1. INTRODUCCIÓN

El Código Alimentario Argentino establece que el porcentaje de palos en la yerba mate elaborada con palo no debe superar el 35%.

El Instituto Nacional de la Yerba Mate (INYM) ha propuesto en el año 2004 ante la Comisión Nacional de Alimentos (CONAL) que la determinación de palo sea realizado por el método de fibra cruda o fibra bruta (Garín, 1916). Este sistema tiene un alto grado de exactitud, pero la muestra de yerba mate debe ser sometida a un análisis de laboratorio el cual es costoso y demora aproximadamente 24 horas, lo que no posibilita su uso para la rutina. Se han propuesto otros métodos que permiten medir el contenido de palo a partir de valores relacionados con éste, uno de los cuales consiste en el análisis del color de la muestra de yerba mate (Nacional, 2006), en otro se realiza la medición del extracto acuoso (Alimentos, 2004), medición de las cenizas totales (Schmalko, 2005), reconocimiento de patrones mediante redes neuronales artificiales (Favret, Eckert, Felten, & Sanderg, Reconocimiento de patrones mediante redes neuronales para la determinación del nivel de contenido de palo en la yerba mate, 2015) y por último análisis de imágenes con Naive Bayes (Favret, Eckert, Felten, & Sanderg, Determinación del contenido de palo en la yerba mate mediante análisis de imágenes aplicando Naive Bayes, 2015). Actualmente el INYM ha difundido un proyecto que persigue el mismo objetivo a través del análisis de la imagen digitalizada de muestras de yerba mate. Este trabajo es descrito en (Escalada, Schmalko, & Känzig, 1998) y se lo puede encontrar en la lista de proyectos del Instituto en (Ybarra, Duce, & Borden, 2010), el cual permite determinar un valor porcentual del contenido de palo de la yerba mate elaborada a través de un método virtual.

A pesar de la existencia de otros métodos, la mayoría de los proyectos mencionados puede emplearse hoy día en reemplazo del método oficial de la zaranda, debido a que no son de aplicación fluida en el proceso productivo.

La determinación del contenido de palo mediante la zaranda, es un sistema que consiste en una especie de colador o cilindro vibratorio con perforaciones en su interior de 1 x 20 mm y N° 40 (0,420 mm de abertura de malla). La yerba mate triturada en la molienda fina que pasa la malla de la zaranda es considerada hoja, sin embargo no es un método exacto ya que por la malla pueden pasar palos y astillas pequeñas del mismo.

Las cualidades de la yerba mate elaborada con palo dependen directamente de la cantidad de palo en la misma. Si el contenido de palo se encuentra en una proporción muy alta, la infusión será amarga, áspera al paladar, sin suavidad. En cambio si el contenido no es suficiente entonces la infusión será insípida, sin su sabor característico, pudiendo ser barrosa y tapar la bombilla a consecuencia de ello. Este hecho ha sido demostrado varias veces por ingenieros químicos desde 1916 a la actualidad, como podemos encontrar en una publicación del Ministerio de Agricultura de la Nación por el Dr. Víctor Garín (Garín, 1916), donde se afirma que el porcentaje de palo que debe tener el producto final de yerba mate elaborada con palo es del 25 % en relación de su contenido de mezcla total, ya que superando este valor el cambio es muy notable.

En el presente trabajo se plantea la construcción de un modelo de sistema como contribución al control de calidad en la elaboración de yerba mate, específicamente a la determinación del nivel de contenido de palo. Para ello se propone utilizar NB y RNA para el reconocimiento de patrones en las imágenes digitalizadas y así determinar el nivel de contenido de palo en las muestras de la yerba mate.

Los factores diferenciadores para la clasificación están relacionados con la extracción de características de intensidad y textura de las fotografías de las muestras de la yerba mate, que se obtienen por medio de descriptores de imágenes.

Existe una variedad de descriptores, como los de información general o global que representan mejor el concepto de visión humana, como el color, la forma o la textura; los descriptores locales son más robustos al procesamiento de imágenes siendo así más adecuados para ser utilizados

para la aplicación de técnicas computacionales en el reconocimiento de objetos o señales (patrones).

2. LA YERBA MATE

El proceso de elaboración de la yerba mate está compuesto básicamente por las siguientes actividades: recepción y pesaje, descarga/estacionamiento en planchada, sapecado, pre-secado, secado, canchado o molienda gruesa, estacionamiento (natural o acelerado), zarandeo, molienda fina y envasado.

Las primeras actividades hasta el canchado conforman la etapa de transformación primaria o etapa de secado (Michalus & Rabenschlag, 1997) (Naffín, 2006), las cuales se desarrollan en los secaderos, ubicados geográficamente en la provincia de Misiones y norte de Corrientes según el análisis sectorial del INDEC presentado en (Rasband, 2013 - 2007).

Las actividades restantes conforman la etapa de transformación secundaria o molienda (Michalus & Rabenschlag, 1997) (Naffín, 2006) y son desarrollados en los molinos, ubicados generalmente en la provincia de Misiones dado la disponibilidad de materia prima que es ofrecida por los secaderos. Según el INDEC (Rasband, 2013 - 2007), en menor porcentaje se encuentran molinos ubicados en las provincias de Corrientes, Santa Fé, Córdoba y Buenos Aires.

2.1 La etapa del secado

La yerba mate cosechada debe ser transportada desde el yerbal al secadero, donde se pesa la yerba verde de los camiones y luego son puestas en una planchada para su posterior utilización. La operación de sapecado debe iniciarse dentro de las 24 hs. de la cosecha, evitando la fermentación y pérdida de la materia prima (Naffín, 2006).

En el sapecado, la hoja verde es expuesta directamente al fuego por unos pocos segundos, a través de un cilindro metálico o tambora de sapeco, alimentado por un hogar a leña o chips. Este paso tiene por finalidad realizar un secado rápido reduciendo considerablemente la humedad de la yerba, eliminando así los fermentos e impidiendo la oxidación de la hoja.

Dentro de las 24 hs. siguientes al sapecado, la hoja debe ser sometida a un proceso de secado y ligera torrefacción hasta reducir su contenido de humedad en aproximadamente 5% a 6%, disminuyendo consecuentemente su peso que, con relación a cada 100 kg. de hoja verde queda reducido, según haya sido la madurez de las hojas cosechadas, a unos 33 kg. de yerba mate seca con un 5% de palos. Existen diferentes técnicas de secado, como por ejemplo el secado antiguo conocido como barbacuá, secado de cinta, rotativo, entre otros. En algunos casos se realiza un pre-secado (<http://www.inym.org.ar>, 25-06-13), lo que es muy parecido al sapecado pero en otra tambora a la que se ingresa la hoja de yerba que sale del mismo, esta etapa suele compensar a un sapeco insuficiente.

Seguidamente, en el proceso de canchado, la yerba mate es sometida a un grosero proceso de trituración para luego pasar al siguiente proceso: el estacionamiento. En este último, la yerba es recolectada en bolsas de arpillera de 50 kg. cada una, y almacenadas en el noque o cámara, lugar donde se estaciona la yerba por aproximadamente un año (estacionamiento natural), o 30 días (estacionamiento acelerado). En este proceso la yerba mate alcanza su sabor y aroma característico.

2.2 La etapa de molienda

La yerba mate ya estacionada ingresa a la etapa de molienda, pasando primeramente por una zaranda de limpieza, la cual elimina objetos extraños ajenos a la misma, y también aparta

los palos y ramas muy grandes. La materia prima que pasa la primera zaranda ingresa a una segunda zaranda, esta vez para separar palos y hojas muy gruesas. Las hojas separadas que son muy gruesas son sometidas a un proceso de trituración más refinada en el molino o trapiche. Nuevamente son sometidas a una zaranda para clasificación o tipificado entre hojas y polvo, y son almacenadas en silos. Los palos resultantes de la zaranda de separación pasan por un pica palo y son almacenados en el silo de palitos. Con los silos tipificados se realizan las mezclas de hoja de yerba y palos de acuerdo al consumo de cada región.

3. PROTOTIPO DE SISTEMA PARA LA DETERMINACIÓN DEL NIVEL DE CONTENIDO DE PALO EN LA YERBA MATE

Para determinar el nivel de contenido de palo en la yerba mate, la primer solución es un modelo de Red Neuronal Perceptrón Multicapa con Propagación hacia Atrás, por sus siglas en inglés Multi-Layer Perceptron (MLP), y en la segunda solución se diseña un modelo probabilístico basado en el Teorema de Bayes, conocido como Naive Bayes.

3.1 Materiales y métodos

Para este proyecto se utilizaron muestras de yerba mate preparadas en laboratorio; una computadora tipo laptop; una cámara fotográfica compacta: 18x de zoom óptico, 8 megapíxeles, sensor de 1/2,5" CCD; y un programa (software) desarrollado en el entorno MATLAB versión R2014a.

La metodología a seguir en este proyecto está basada en el desarrollo de un sistema experto propuesto por Weiss y Kulikowski, descrito en (McCulloch WS, 1943), que incluye los siguientes pasos: Diseño; Elección de la herramienta de desarrollo; Construcción y prueba del prototipo; Refinamiento y generalización.

A continuación se detallan los pasos seguidos en la obtención del prototipo para ambas soluciones. Se inicia con la preparación de las muestras que posteriormente integrarán la base del conocimiento tanto para RNA como NB.

3.2 Preparación de las muestras de yerba mate

Cada muestra es preparada en un molino del laboratorio a partir de la yerba mate estacionada de forma natural, que es la que se consume en la región del litoral. Para preparar las diferentes muestras, se utilizaron 2 kg de yerba mate canchada, de los cuales fueron separados manualmente las partículas pertenecientes al palo de las hojas de yerba. La separación de la hoja y palo de yerba mate proveniente del secadero se pasó por el molino que se muestra en la Figura 1, en el laboratorio de la Facultad de Ciencias Exactas, Químicas y Naturales -Universidad Nacional de Misiones, para obtener una molienda fina de hoja y palo de yerba mate.

Una vez obtenido la molienda fina de la hoja y palo de la yerba mate, como se muestra en la Figura 2, se procede a preparar las muestras con diferentes contenidos de palo con una balanza digital de precisión, pesando cada muestra 100 gramos, actividad que se aprecia en la Figura 3.

Figura 1. Molienda de palo de yerba mate.



Fuente: Elaboración propia

Figura 2. Hoja y palo de yerba mate molida.



Fuente: Elaboración propia

Figura 3. Balanza digital de precisión para obtener distintas muestras.



Fuente: Elaboración propia

Se decidió tomar un rango de clasificación de 6 (seis) muestras de yerba mate, separados en envases como se puede distinguir en la Figura 4, con porcentajes de palo conocidos de: 15, 20, 25, 30, 35 y 40 %. El intervalo está tomado con números de porcentaje significativos utilizando 4 valores por debajo del estipulado por el Código Alimentario Argentino y un valor por encima de éste dado que superando el 35% de palo ya no se cumple la norma.

De esta manera se obtuvieron de forma exacta las preparaciones con los diferentes porcentajes de palo y hoja de yerba mate, las cuales fueron almacenadas en recipientes separados para su uso posterior. Para la preparación de las muestras se contó con la ayuda del Ing. Miguel Schmalko, encargado del laboratorio de la Yerba Mate en la Universidad mencionada.

Figura 4. Muestras de yerba mate con diferentes porcentajes de palo.



Fuente: Elaboración propia

3.3 Adquisición de imágenes

Se tomaron fotografías a color por cada uno de los 6 niveles de contenido de palo. Es decir que, para una misma muestra de un determinado nivel de contenido de palo (por ejemplo 15% contenido de palo), se tomaron 50 fotografías variando la posición de palos y hojas de yerba mate por cada captura fotográfica. En total se tendrán 300 fotografías, 50 por 6 niveles de contenido de palo. La cantidad de fotografías necesarias tiene relación que cuanto mayor sea el conjunto de entrenamiento, mayor será el grado de reconocimiento de patrones para la clasificación.

Cada muestra fue colocada en un recipiente rectangular de plástico transparente, una por vez, con las siguientes características de adquisición de imágenes:

- Cámara: Se utilizó una cámara fotográfica compacta con 18x de zoom óptico, 8 megapíxeles, sensor de 1/2,5" CCD.
- Sistema de iluminación: El sistema de iluminación debe ser adecuado para que la captura de la imagen sea correcta. Existen diferentes tipos de sistemas, como ser: retroalimentación difusa, iluminación frontal, luz direccional y luz estructurada. En el presente trabajo se utilizó iluminación frontal. La misma es muy utilizada en los sistemas de visión artificial y consiste en iluminar frontalmente la pieza.
- Fuentes de iluminación: con respecto a las fuentes de iluminación tenemos diferentes elementos: lámparas incandescentes, tubos fluorescentes, fibra óptica, láser. Se utilizaron tubos fluorescentes lineales ya que suministran una luz más difusa.

- Distancia de la cámara: la cámara fue colocada a una distancia de 25 cm de la base del material a fotografiar. Con un ángulo recto de 90° desde arriba.
- Resolución de fotografías: las imágenes fueron obtenidas con una resolución de 72ppp, dada por el hardware de la cámara.

3.4 Extracción de características mediante descriptores de imágenes

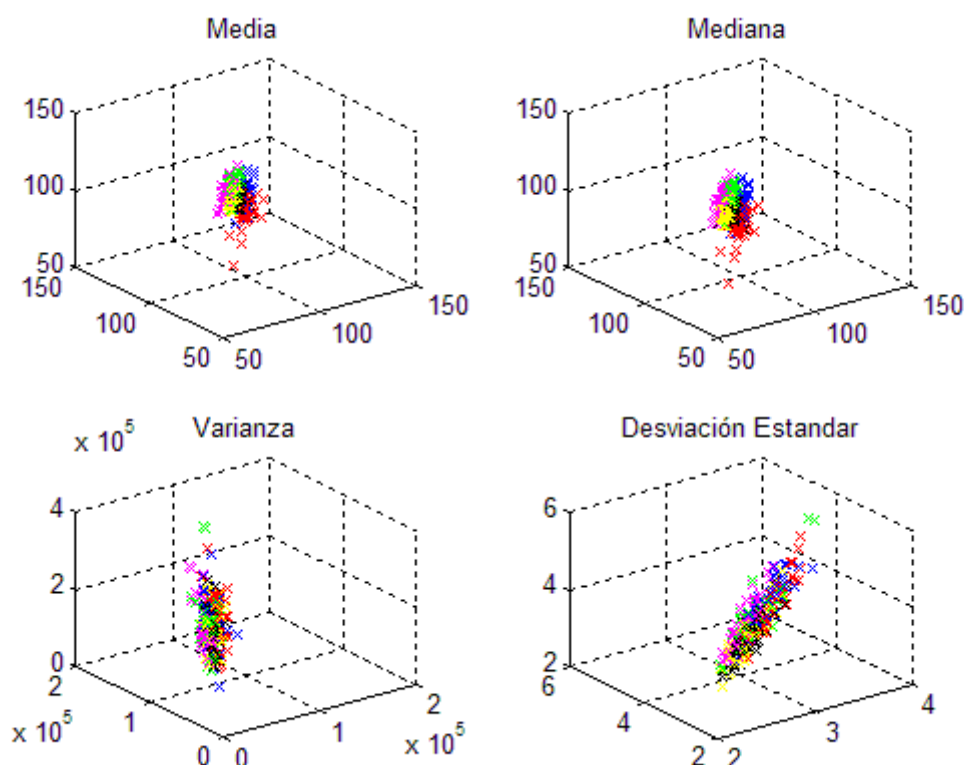
Para que se puedan procesar las imágenes en Matlab, éstas deben ser representadas por medio de arreglos o matrices, las cuales constituyen las características claves que se extraen de cada imagen por medio de descriptores o algoritmos de análisis de imágenes con el objeto de describir los componentes que se encuentran en las mismas.

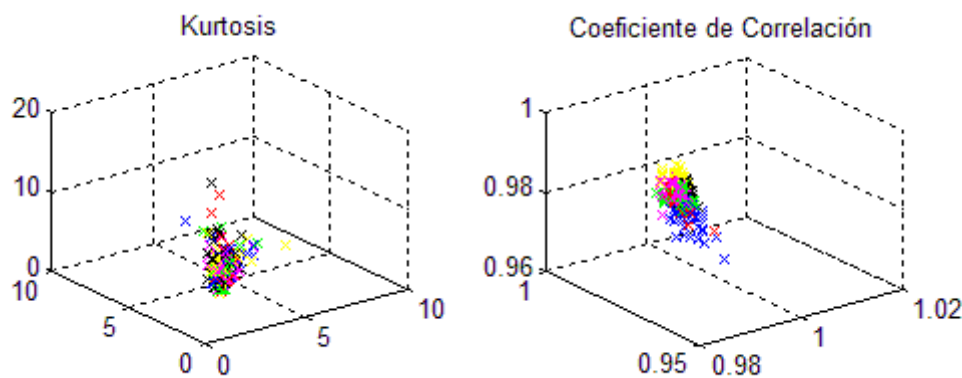
Se utilizaron descriptores de intensidad que tienen un gran uso en el ámbito de la inteligencia artificial aplicados en la imagen a color, dividida en los tres planos RGB: media, mediana, varianza, desviación estándar, coeficiente de kurtosis, coeficiente de correlación. También se usaron descriptores propios de textura: contraste, correlación, energía y homogeneidad, en escala RGB.

Para graficar los datos en el espacio 3-D (dados por las componentes de las imágenes en color R, G y B), se utilizaron las observaciones de 240 imágenes de muestras de la base total de 300, para los descriptores mencionados. En la Figura 5 se observan el gráfico de dispersión para los descriptores de intensidad y en la Figura 6 de textura, con dimensiones de 1000x1000 píxeles en ambos casos.

Los diferentes colores presentados en los gráficos se corresponden con cada clase de nivel de contenido de palo, por lo que, para la clase de nivel de contenido del 15% de palo se pintan los descriptores obtenidos en color azul, para el 20% de contenido de palo en color rojo, para el 25% en color verde, para el 30% de contenido de palo en color magenta o rosa, para el 35% en color negro y, por último, para la clase de 40% de nivel de contenido de palo en color amarillo.

Figura 5. Descriptores de imágenes de intensidad en escala RGB.





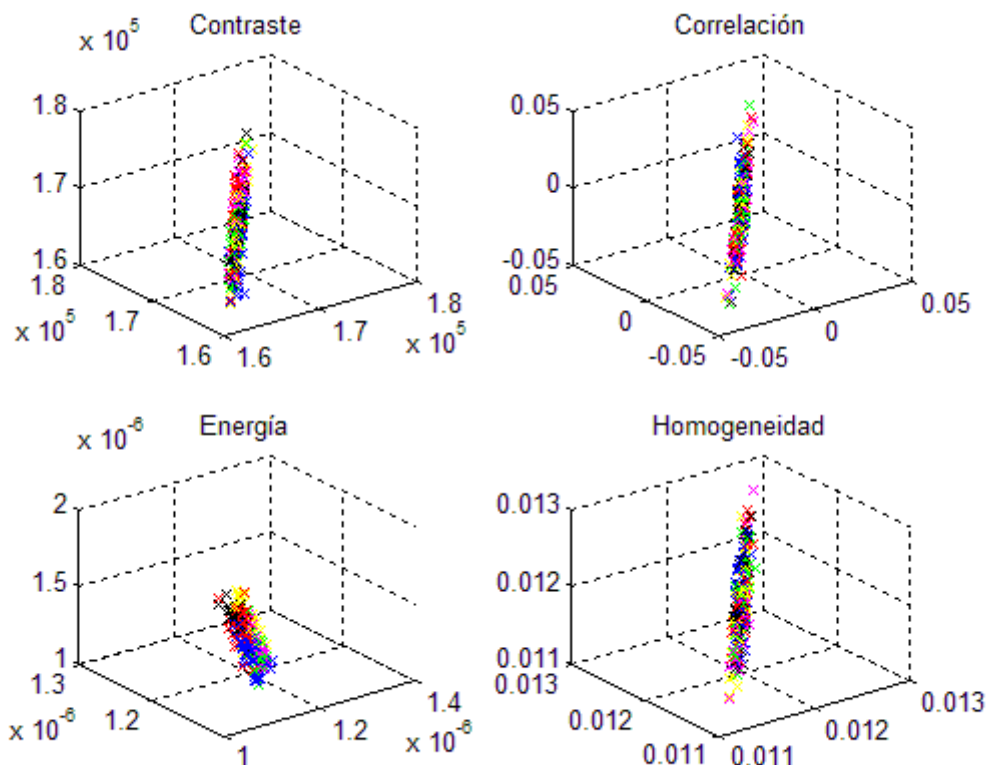
Fuente: Elaboración propia

Para esta investigación se decidió trabajar con un tamaño de imagen de 1000x1000 píxeles. Se ha probado con diferentes tamaños de imágenes y se pudo observar que a medida que se aumenta el tamaño de las imágenes, los datos se dispersan más, permitiendo, en algunos casos, ver las clases con una mejor separabilidad en el espacio, aún con algunos solapamientos entre ellas. Por ejemplo, se analizó con una resolución de 300x300 frente a los demás gráficos y se notó que los datos están menos dispersos, es decir, muy unidos y mezclados a simple vista, lo que dificulta utilizar estos descriptores como base de datos. Por otra parte utilizando tamaños superiores al seleccionado (por ejemplo: 2000x2000 píxeles), se observó que no presentan muchas variaciones en los descriptores que mejor separan las clases; se debe tener en cuenta también que a mayor tamaño de imagen, mayor será el tiempo de procesamiento, por lo que una imagen de 1000x1000 píxeles es considerada la más adecuada al caso de estudio.

Se pudo notar que algunos descriptores no permiten una clara separabilidad de clases, lo que se mantiene en los diferentes tamaños de imagen, este es el caso para la varianza, la desviación estándar y el coeficiente de kurtosis. Mientras que otros, sin embargo, mejoran con el aumento del tamaño, tal es el caso de la media, la mediana y, algo menos disperso, la correlación de Pearson.

A simple vista podemos observar que la media y la mediana son quienes mejores separan las clases. Mientras que la varianza, la desviación estándar y kurtosis parecen ser quienes peores discriminan las clases. Mientras que en los descriptores de textura se puede decir que, como primera observación, el que parece ser mejor discriminante es el de Energía.

Figura 6. Descriptores de imágenes de textura en escala RGB.



Fuente: Elaboración propia

3.5 Conjunto de datos para los vectores de entrada

El conjunto de imágenes de ejemplos está formado por 240 imágenes de muestras de yerba mate preparadas con diferentes contenidos de palo, ver la Tabla 1.

Para calcular los descriptores de intensidad y textura se trabajó con los planos RGB de una imagen por separado, obteniéndose tres vectores de intensidad de niveles de gris. El cálculo de los descriptores de textura se realizó para los ángulos 0° , 45° , 90° y 135° , y una distancia $d=1$. Se utilizó un programa de Matlab para facilitar el cálculo de descriptores de forma rápida para el conjunto de imágenes y se guardó en una matriz los resultados. Para crear la matriz de ejemplos se utilizaron los descriptores seleccionados ver tabla 2.

Tabla 1. Distribución del conjunto de datos.

Clase	Nivel de contenido de Palo	Imágenes
1	15 %	40
2	20 %	40
3	25 %	40
4	30 %	40
5	35 %	40
6	40 %	40
Total		240 imágenes

Fuente: Elaboración propia

Tabla 2. Descriptores de Imágenes seleccionados

Nº	Descriptor
1	Media en R
2	Media en G
3	Media en B
4	Mediana en R
5	Mediana en G
6	Mediana en B
7	Correlación de Pearson entre RG
8	Correlación de Pearson entre RB
9	Correlación de Pearson entre BG
10	Energía en R
11	Energía en G
12	Energía en B

Fuente: Elaboración propia

3.6 Selección de características o descriptores

Para decidir sobre los descriptores o características que formarán parte del prototipo final, se recurrieron a diferentes metodologías de reducción de dimensionalidad (Guyón, 2003). Las mismas serán: selección mediante el tipo Wrapper; selección mediante IM; y extracción por ACP. Se presentarán los subconjuntos obtenidos por cada técnica por separado para cada modelo RNA y NB y, por último, se decidirá el mejor de ellos.

Hecho el análisis de los gráficos de descriptores en la sección anterior, se pre-seleccionó el conjunto inicial de características para ser utilizado con el método de Wrapper con los siguientes descriptores de imágenes: media, mediana, coeficiente de Pearson y Energía. Para IM y ACP se utilizó el conjunto original de 30 descriptores ya que la selección o extracción está determinada en sus algoritmos.

4. RESULTADOS

4.1 Resultados para Redes Neuronales Artificiales

Los resultados de los experimentos con los diferentes subconjuntos de datos de entrada seleccionados con un método de selección de características tipo Wrapper se muestran en la Tabla 3.

Tabla 3. Resultados de Clasificación con RNA y selección con Wrapper.

Experimento	Combinación de Descriptores	Porcentaje de Acierto	Micro F-Score	Macro F-Score
1	Media-Mediana-Correlación-Energía	96,67	0,9667	0,9666
2	Media-Mediana-Correlación	95,00	0,9828	0,9833
3	Media-Mediana-Energía	96,67	0,9831	0,9833
4	Media-Correlación-Energía	88,33	0,8983	0,8956
5	Mediana-Correlación-Energía	90,00	0,9310	0,9343
6	Media-Mediana	81,67	0,8305	0,8303
7	Media-Correlación	88,33	0,8983	0,8963
8	Media-Energía	91,67	0,9322	0,9319
9	Mediana-Correlación	91,67	0,9322	0,9311
10	Mediana-Energía	86,67	0,8966	0,8986
11	Correlación-Energía	81,67	0,8750	0,8709
12	Media	75,00	0,7759	0,7754
13	Mediana	80,00	0,8276	0,8294
14	Correlación	60,00	0,6271	0,6186
15	Energía	50,00	0,5172	-

Fuente: Elaboración propia

Debido a los problemas de división por cero en los cálculos no ha podido determinarse la métrica Macro F-Score para el experimento 15.

Puede observarse que con la combinación de descriptores del experimento 1 (Media-Mediana-Correlación-Energía) se obtuvieron los mejores resultados con el mismo porcentaje de aciertos que en experimento 3 (Media-Mediana-Energía), de lo que se puede afirmar que el descriptor de Correlación no influye para este caso, sin embargo, provoca una mínima disminución del desempeño obtenido con los índices Micro y Macro F-Score. Por otro lado, los peores resultados fueron obtenidos en los experimentos 14 y 15, cuyos descriptores son Correlación y Energía, respectivamente. Además, se puede apreciar que los descriptores utilizados individualmente como conjunto de entrada presentan un peor desempeño que utilizándolos conjuntamente.

Para los subconjuntos de datos de entrada que fueron seleccionados a partir del método del

tipo Filter con la IM, se muestran en la tabla 4 a continuación.

Tabla 4. Resultados de Clasificación con RNA y subconjuntos seleccionados con IM.

Experimento	Combinación de Descriptores	Porcentaje de Acierto	Micro F-Score	Macro F-Score
1	Subconjunto por IM N°1	46,67	0,4746	-
2	Subconjunto por IM N°2	45,00	0,4500	-
3	Subconjunto por IM N°3	51,67	0,5254	0,5173
4	Subconjunto por IM N°4	51,67	0,5536	0,5415
5	Subconjunto por IM N°5	53,33	0,5614	0,5405
6	Subconjunto por IM N°6	56,67	0,5763	0,5583
7	Subconjunto por IM N°7	83,33	0,8621	0,8657
8	Subconjunto por IM N°8	80,00	0,8000	0,8011
9	Subconjunto por IM N°9	81,67	0,8167	0,8098
10	Subconjunto por IM N°10	80,00	0,8276	0,8312
11	Subconjunto por IM N°11	81,67	0,8305	0,8155
12	Subconjunto por IM N°12	81,67	0,8750	0,8769
13	Subconjunto por IM N°13	80,00	0,8000	0,7929
14	Subconjunto por IM N°14	81,67	0,8448	0,8450
15	Subconjunto por IM N°15	75,00	0,7895	0,7813

Fuente: Elaboración propia

A continuación se detallan la constitución de cada subconjunto de la Tabla 12 por IM y según la cantidad de descriptores elegidos, empezando con 1 hasta 15 (la mitad del total de descriptores).

Subconjunto N°1:

- pearsonRB(2,1)

Subconjunto N°2:

- pearsonRG(2,1)
- pearsonRB(2,1)

Subconjunto N°3:

- pearsonRG(2,1)
- pearsonRB(2,1)
- pearsonBG(2,1)

Subconjunto N°4:

- mediaB
- pearsonRG(2,1)
- pearsonRB(2,1)
- pearsonBG(2,1)

Subconjunto N°5:

- mediaB
- medianaB
- pearsonRG(2,1)
- pearsonRB(2,1)
- pearsonBG(2,1)

Subconjunto N°6:

- mediaB
- medianaG
- medianaB
- pearsonRG(2,1)
- pearsonRB(2,1)
- pearsonBG(2,1)

Subconjunto N°7:

- mediaB
- medianaR
- medianaG
- medianaB
- pearsonRG(2,1)
- pearsonRB(2,1)
- pearsonBG(2,1)

Subconjunto N°8:

- mediaR
- mediaB
- medianaR
- medianaG
- medianaB
- pearsonRG(2,1)
- pearsonRB(2,1)

- pearsonBG(2,1)

Subconjunto N°9:

- mediaR
- mediaG
- mediaB
- medianaR
- medianaG
- medianaB
- pearsonRG(2,1)
- pearsonRB(2,1)
- pearsonBG(2,1)

Subconjunto N°10:

- mediaR
- mediaG
- mediaB
- medianaR
- medianaG
- medianaB
- pearsonRG(2,1)
- pearsonRB(2,1)
- pearsonBG(2,1)
- texturaR.Contrast

Subconjunto N°11:

- mediaR
- mediaG
- mediaB
- medianaR
- medianaG
- medianaB
- pearsonRG(2,1)
- pearsonRB(2,1)
- pearsonBG(2,1)
- texturaR.Contrast
- texturaR.Energy

Subconjunto N°12:

- mediaR
- mediaG
- mediaB
- medianaR
- medianaG
- medianaB
- pearsonRG(2,1)
- pearsonRB(2,1)
- pearsonBG(2,1)
- texturaR.Contrast
- texturaR.Energy

- texturaR.Homogeneity

Subconjunto N°13:

- mediaR
- mediaG
- mediaB
- medianaR
- medianaG
- medianaB
- pearsonRG(2,1)
- pearsonRB(2,1)
- pearsonBG(2,1)
- texturaR.Contrast
- texturaR.Correlation
- texturaR.Energy
- texturaR.Homogeneity

Subconjunto N°14:

- mediaR
- mediaG
- mediaB
- medianaR
- medianaG
- medianaB
- desviacionR,
- pearsonRG(2,1)
- pearsonRB(2,1)
- pearsonBG(2,1)
- texturaR.Contrast
- texturaR.Correlation
- texturaR.Energy
- texturaR.Homogeneity

Subconjunto N°15:

- mediaR
- mediaG
- mediaB
- medianaR
- medianaG
- medianaB
- desviacionR
- desviacionB
- pearsonRG(2,1)
- pearsonRB(2,1)
- pearsonBG(2,1)
- texturaR.Contrast
- texturaR.Correlation
- texturaR.Energy
- texturaR.Homogeneity

Para este caso, se obtuvo el mejor resultado de acierto con el experimento 7, sin embargo, en cuanto a las medidas de desempeño fue superior el experimento 12, notándose que en segundo caso, el subconjunto de entrada incorpora descriptores de textura. El peor resultado se observa en el experimento 2, con un subconjunto de entrada con descriptores de Pearson. Se evidencia que la utilización individual de este descriptor no favorece los resultados finales, sin embargo, utilizándolo en combinación de otros descriptores, los beneficia.

Para el método por extracción de características ACP, los subconjuntos de datos de entrada determinaron los resultados plasmados en la Tabla 5. Al ser un método de transformación lineal no es posible describir los conjuntos de descriptores, ellos quedan representados de acuerdo a la cantidad de características extraídas, desde 1 hasta 15, comenzando por el Subconjunto N° 1 hasta el Subconjunto N° 15 respectivamente. En la última columna de la misma, debido a los problemas de división por cero en los cálculos no ha podido determinarse la métrica Macro F-Score.

Tabla 5. Resultados de Clasificación con RNA y subconjuntos seleccionados con ACP.

Experimento	Combinación de Descriptores	Porcentaje de Acierto	Micro F-Score	Macro F-Score
1	Subconjunto por ACP N° 1	23,33	0,2500	-
2	Subconjunto por ACP N° 2	16,67	0,1667	-
3	Subconjunto por ACP N° 3	20,00	0,2000	-
4	Subconjunto por ACP N° 4	21,67	0,2167	-
5	Subconjunto por ACP N° 5	25,00	0,2500	-
6	Subconjunto por ACP N° 6	31,67	0,3167	-
7	Subconjunto por ACP N° 7	30,00	0,3000	-
8	Subconjunto por ACP N° 8	31,67	0,3167	-
9	Subconjunto por ACP N° 9	35,00	0,3500	-
10	Subconjunto por ACP N° 10	45,00	0,5000	-
11	Subconjunto por ACP N° 11	41,67	0,4237	-
12	Subconjunto por ACP N° 12	43,33	0,4333	-
13	Subconjunto por ACP N° 13	30,00	0,3000	-
14	Subconjunto por ACP N° 14	45,00	0,4655	-
15	Subconjunto por ACP N° 15	26,67	0,2667	-

Fuente: Elaboración propia

Se observa en la Tabla 5, que los experimentos 10 y 14 presentan los valores los mejores porcentajes de acierto (45%), no obstante, es un valor muy bajo.

4.2 Resultados para Naive Bayes

Los resultados de los experimentos con los diferentes subconjuntos de datos de entrada seleccionados con el método de tipo Wrapper se muestran en la Tabla 6. El detalle de los resultados que se obtuvieron para cada imagen de prueba por cada experimento con sus correspondientes matrices de confusión se observan en el Anexo X.

Tabla 6. Resultados de Clasificación con NB y subconjuntos seleccionados con Wrapper.

Experimento	Combinación de Descriptores	Porcentaje de Acierto	Micro F-Score	Macro F-Score
1	Media-Mediana-Correlación-Energía	63,33	0,6333	0,6129
2	Media-Mediana-Correlación	78,33	0,7833	0,7794
3	Media-Mediana-Energía	51,67	0,5167	0,5065
4	Media-Correlación-Energía	60,00	0,6000	0,5869
5	Mediana-Correlación-Energía	61,67	0,6167	0,6041
6	Media-Mediana	68,33	0,6833	0,6633
7	Media-Correlación	0,00	0,0000	0,0000
8	Media-Energía	45,00	0,4500	0,4451
9	Mediana-Correlación	85,00	0,8500	0,8471
10	Mediana-Energía	51,67	0,5167	0,5028
11	Correlación-Energía	53,33	0,5333	0,5276
12	Media	70,00	0,7000	0,6811
13	Mediana	65,00	0,6500	0,6304
14	Correlación	58,33	0,5833	0,5740
15	Energía	23,33	0,2333	0,0000

Fuente: Elaboración propia

Se evidencia que el mejor resultado está dado por el experimento 9, con un porcentaje de acierto del 85%. Además, se puede ver claramente en el experimento, con la combinación de la Media y la Correlación no se obtiene ningún acierto, dando el peor resultado.

En la Tabla 7 se muestran los resultados de los subconjuntos de datos de entrada que fueron seleccionados a partir del método del tipo Filter con la IM. Se aprecian algunos casos donde no se ha podido determinar las métricas de desempeño debido al problema de división por cero en el cálculo.

Puede observarse que los experimentos 10 y 11 presentaron los mejores resultados con el mismo porcentaje de acierto, no obstante, en el desempeño obtenido con el índice Macro F-Score se evidencia una depreciación.

Tabla 7. Resultados de Clasificación con NB y subconjuntos seleccionados con IM.

Experimento	Combinación de Descriptores	Porcentaje de Acierto	Micro F-Score	Macro F-Score
1	Subconjunto por IM N°1	38,33	0,3833	-
2	Subconjunto por IM N°2	46,67	0,4667	0,4559
3	Subconjunto por IM N°3	53,33	0,5333	0,5409
4	Subconjunto por IM N°4	58,33	0,5833	0,5804
5	Subconjunto por IM N°5	55,00	0,5500	0,5454
6	Subconjunto por IM N°6	21,67	0,2167	-
7	Subconjunto por IM N°7	61,67	0,6167	0,5908
8	Subconjunto por IM N°8	61,67	0,6167	0,5908
9	Subconjunto por IM N°9	61,67	0,6167	0,5949
10	Subconjunto por IM N°10	63,33	0,6333	0,6095
11	Subconjunto por IM N°11	63,33	0,6333	0,6130
12	Subconjunto por IM N°12	61,67	0,6167	0,6008
13	Subconjunto por IM N°13	0,00	-	-
14	Subconjunto por IM N°14	0,00	-	-
15	Subconjunto por IM N°15	0,00	-	-

Fuente: Elaboración propia

A continuación se pueden observar en la Tabla 8 los resultados obtenidos de los subconjuntos de datos de entrada que fueron seleccionados con un método de extracción mediante el ACP.

En los primeros 6 experimentos no pudo determinarse la Macro F-Score al igual que en las tablas anteriores por la división por cero.

Se evidencia que, en general, los resultados son muy deficientes, ya que el mayor porcentaje de acierto obtenido es, en el mejor de los casos, del 58,33%, con un desempeño similar.

Tabla 8. Resultados de Clasificación con NB y subconjuntos seleccionados con ACP

Experimento	Combinación de Descriptores	Porcentaje de Acierto	Micro F-Score	Macro F-Score
1	Subconjunto por ACP N° 1	15,00	0,1500	-
2	Subconjunto por ACP N° 2	18,33	0,1833	-
3	Subconjunto por ACP N° 3	31,67	0,3167	-
4	Subconjunto por ACP N° 4	25,00	0,2500	-
5	Subconjunto por ACP N° 5	36,67	0,3667	-
6	Subconjunto por ACP N° 6	45,00	0,4500	-
7	Subconjunto por ACP N° 7	41,67	0,4167	0,3914
8	Subconjunto por ACP N° 8	56,67	0,5667	0,5326
9	Subconjunto por ACP N° 9	53,33	0,5333	0,5026
10	Subconjunto por ACP N° 10	56,67	0,5667	0,5317
11	Subconjunto por ACP N° 11	58,33	0,5833	0,5448
12	Subconjunto por ACP N° 12	56,67	0,5667	0,5267
13	Subconjunto por ACP N° 13	56,67	0,5667	0,5417
14	Subconjunto por ACP N° 14	56,67	0,5667	0,5417
15	Subconjunto por ACP N° 15	50,00	0,5000	0,4645

Fuente: Elaboración propia

4.3 Tabla comparativa entre técnicas de Inteligencia Artificial

Los mejores resultados obtenidos para RNA y NB con el método Wrapper se plasman en una nueva tabla para permitir una mejor apreciación ver tabla 9.

Según la tabla 9 se obtuvieron mejores resultados con RNA en general, tanto en porcentajes de acierto como en los índices de desempeño Micro y Macro F-Score. En la quinta columna se aprecian las diferencias de porcentajes de aciertos entre ambas técnicas. En el experimento 14, utilizando el descriptor Correlación como conjunto de entrada, se observa una mínima diferencia

de aciertos entre RNA y NB, donde los clasificadores se comportan de forma casi similar, sin embargo no presentan los mejores resultados en comparación con los demás. Los experimentos 7 y 15 presentan la mayor diferencia de aciertos debido a que NB, con esas combinaciones de descriptores, no fue capaz de clasificar correctamente ninguna imagen.

Tabla 9. Resultados de Clasificación con RNA y NB

Nº Exp	Combinación de Descriptores	Porcentaje de Acierto RNA	Porcentaje de Acierto NB	Dif. de Porc. de Acierto	Micro F-Score RNA	Micro F-Score NB	Macro F-Score RNA	Macro F-Score NB
1	Media-Mediana-Correlación-Energía	96,67	63,33	33,34	0,9667	0,6333	0,9666	0,6129
2	Media-Mediana-Correlación	95,00	78,33	16,67	0,9828	0,7833	0,9833	0,7794
3	Media-Mediana-Energía	96,67	51,67	45,00	0,9831	0,5167	0,9833	0,5065
4	Media-Correlación-Energía	88,33	60,00	28,33	0,8983	0,6000	0,8956	0,5869
5	Mediana-Correlación-Energía	90,00	61,67	28,33	0,9310	0,6167	0,9343	0,6041
6	Media-Mediana	81,67	68,33	13,34	0,8305	0,6833	0,8303	0,6633
7	Media-Correlación	88,33	0,00	88,33	0,8983	0,0000	0,8963	0,0000
8	Media-Energía	91,67	45,00	46,67	0,9322	0,4500	0,9319	0,4451
9	Mediana-Correlación	91,67	85,00	6,67	0,9322	0,8500	0,9311	0,8471
10	Mediana-Energía	86,67	51,67	35,00	0,8966	0,5167	0,8986	0,5028
11	Correlación-Energía	81,67	53,33	28,34	0,8750	0,5333	0,8709	0,5276
12	Media	75,00	70,00	5,00	0,7759	0,7000	0,7754	0,6811
13	Mediana	80,00	65,00	15,00	0,8276	0,6500	0,8294	0,6304

14	Correlación	60,00	58,33	1,67	0,6271	0,5833	0,6186	0,5740
15	Energía	50,00	-	50,00	0,5172	0,2333	-	0,0000

Fuente: Elaboración propia

5. CONCLUSIONES

En este trabajo se analizó el desempeño de las redes neuronales del tipo multicapa con propagación hacia atrás, y redes bayesianas del tipo NB en cuanto a su capacidad de clasificación del nivel de contenido de palo en imágenes de yerba mate elaborada.

5.1 Experimentos con Redes Neuronales Artificiales

Los resultados obtenidos para las diferentes técnicas de reducción de dimensionalidad determinaron que el método de Wrapper ha sido superior a las técnicas por IM y ACP. En la Tabla 3 Sección 4.1, se observa que el experimento 3 tuvo el mejor desempeño tomando como base la premisa de que el clasificador sin haber visto anteriormente el conjunto de 60 imágenes de prueba, pudo clasificar las mismas con una tasa de acierto del 96,67%.

Los descriptores de imágenes involucrados en dicho experimento fueron la media, la mediana y la energía. En primera instancia, tanto el experimento 1 como el 3 han tenido iguales porcentajes de aciertos pero, tras la evaluación de desempeño, el segundo ha demostrado ser superior con 98,31% y 98,33% para las métricas F-Score Micro y F-Score Macro, respectivamente.

5.2 Experimentos con Naive Bayes

Al igual que para el apartado anterior con RNA, en NB también ha quedado demostrada la superioridad del método de reducción de dimensionalidad por Wrapper.

Teniendo como base los resultados de la Tabla 6 Sección 4.2, se puede apreciar que el algoritmo que alcanzó el mejor desempeño es el experimento número 9, donde el porcentaje de acierto sobre el conjunto de prueba de 60 imágenes nunca vistas por el clasificador fue del 85%, con un desempeño cuasi igualados del 85% alcanzado por Micro F-Score y un 84,71% por Macro F-Score.

A partir de estos resultados se puede afirmar que los descriptores que mejor definen las fotografías de yerba mate en este caso son la mediana y la correlación de Pearson en todos sus planos. Por otra parte, el experimento 7 obtuvo los resultados más bajos sin ningún acierto sobre el conjunto de prueba.

5.3 Comparación de las técnicas de Inteligencia Artificial utilizadas

Para realizar la comparación entre las técnicas RNA y NB los mejores resultados obtenidos para los subconjuntos de entrada por Wrapper fueron plasmados en la Tabla 9, Sección 4.3, donde se pueden observar los porcentajes de aciertos y métricas de desempeño de ambos clasificadores, permitiendo una fácil comparación visual.

Analizando los resultados se evidencia que RNA tiene un mayor desempeño y acierto para resolver el problema de clasificación.

Como se mencionó en un principio, el método utilizado en la actualidad es el de la zaranda, sin embargo es un método inexacto ya que por la malla puede pasar palos de menor tamaño,

polvo y astillas pequeñas del mismo.

El prototipo que utiliza RNA determinó porcentajes de acierto muy cercanos a sus valores reales, con un error del 3.33% de clasificación, adicionando la ventaja de su facilidad en cuanto a su implementación y utilización, y principalmente, la posibilidad de ser utilizado en tiempo real en el proceso rutinario de envasado.

DETERMINATION OF THE PERCENTAGE OF YERBA MATE STICK THROUGH THE ARTIFICIAL INTELLIGENCE TECHNIQUES

ABSTRACT: The content of stick yerba mate with stems is a determinant of its quality. Currently, determining the content thereof it is officially given by the sieve; not too accurate method, where the fine grinding passes mesh sieve is considered the leaf. This paper proposes a model for determining the level of content of yerba mate stick by the classification algorithm Naive Bayes (NB) and Artificial Neural Networks (ANN) for recognizing patterns in scanned images. The prototype includes sample preparation, image acquisition, feature extraction using descriptors of images, defining the data set for input vectors, experiments and analysis of the results obtained. The ANN model was correct performance and can be considered a reliable method for determining the percentage of clubs in yerba mate.

KEYWORDS: Artificial Intelligence, Naive Bayes, Artificial Neural Networks, Image Analysis, Yerba Mate, Stick Content.

Originais recebidos em: 30/06/2017
Aceito para publicação em: 11/06/2018

Bibliografía

- Alimentos, C. N. (2004). Reunión Plenaria -14, 15 y 16 de Abril de 2004. ACTA N° 61.
- Escalada, M., Schmalko, M., & Känzig, R. (1998). El extracto acuoso como una medida del contenido de palos en la Yerba Mate. *Revista de ciencia y tecnología*, 1.
- Favret, F. E., Eckert, K., Felten, A., & Sanderg, G. (2015). Determinación del contenido de palo en la yerba mate mediante análisis de imágenes aplicando Naive Bayes. 44 JAIIO - Jornadas Arg. de Informática - 4th Argentine Symposium on Industrial Informatics (ISSN: 2451-7542), 37-48.
- Favret, F. E., Eckert, K., Felten, A., & Sanderg, G. (2015). Reconocimiento de patrones mediante redes neuronales para la determinación del nivel de contenido de palo en la yerba mate. WICC - Workshop de Investigadores en Ciencia de la Computación (Artículo N° 6939 - ISBN: 978-987-633-134-0).
- Garín, V. (1916). "Contribución al estudio del cultivo e industria de la Yerba Mate". . Ministerio de Agricultura de la Nación.
- Guyón, E. (2003). An Introduction to Variable and Feature Selection. *Journal of Machine Learning Research*, 3, 1157-1182.
- <http://www.inym.org.ar>, S. d. (25-06-13). /P.R.A.S.Y/Proyectos en Ejecución: Proyectos de investigación, experimentación y capacitación financiados parcial o totalmente por el INYM.
- McCulloch WS, P. W. (1943). A logical calculus of the ideas immanent in nervous activity.
- Michalus, J. C., & Rabenschlag, D. R. (1997). Análisis de diagrama de proceso aplicado al Proceso de elaboración primaria de yerba mate.
- Nacional, C. A. (2006). Capítulo XV. (1194).
- Naffín, M. (2006). Recopilación de Información del Inym.
- Rasband, W. S. (2013 - 2007). Análisis Sectorial Nro 1. Yerba Mate. INDEC.
- Schmalko. (2005). El color como una medida del porcentaje de palos en la yerba mate.
- Ybarra, L. R., Duce, J. A., & Borden, S. A. (2010). Estudio de las cenizas y su utilización en la determinación del contenido de palo en la Yerba Mate. *Revista de ciencia y tecnología*(13).