

## Determinación del contenido de palo en la yerba mate mediante análisis de imágenes aplicando Naive Bayes

Fabián E. Favret<sup>a</sup>, Karina B. Eckert<sup>b</sup>, Analía R. Felten<sup>c</sup>, Gabriela T. Sandberg<sup>d</sup>

Departamento de Ingeniería y Ciencias de la Producción, Universidad Gastón Dachary  
Posadas, Misiones, Argentina.

{fabianfavret<sup>a</sup>, karinaeck<sup>b</sup>,  
cosmica01<sup>c</sup>, gabriela.sandberg<sup>d</sup>}@gmail.com

**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) 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 por NB. El modelo tuvo un correcto desempeño y se lo puede considerar un método confiable para la determinación del porcentaje de palos en la yerba mate.

**Palabras clave:** Naive Bayes, análisis de imágenes, yerba mate, contenido de palo.

### 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 [1]. 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 [2], en otro se realiza la medición del extracto acuoso [3], medición de las cenizas totales [4] y por último reconocimiento de patrones mediante redes neuronales artificiales [5]. 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 descripto en [6] y se lo puede en-

contrar en la lista de proyectos del Instituto en [7], 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) [8]. 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 [9], 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 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 [10] 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 [10] [11], las cuales se desarrollan en los secaderos, ubica-

dos geográficamente en la provincia de Misiones y norte de Corrientes según el análisis sectorial del INDEC presentado en [12].

Las actividades restantes conforman la etapa de transformación secundaria o molienda [10] [11], 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 [12], 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 [11].

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 palitos. Existen diferentes técnicas de secado, como por ejemplo el secado antiguo o *barbacuá*, secado de cinta, rotativo, entre otros. En algunos casos se realiza un pre-secado [9], 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 almacena-

dos 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 Naive Bayes

Una red bayesiana es un método que ofrece dos tipos de análisis, uno cualitativo en cuanto a los atributos y valores que pueden intervenir en el problema y un análisis cuantitativo de esos atributos. Cualitativamente se puede representar la relación de los atributos ya sea en una forma causal, o expresando la correlación que existe entre esas variables. Cuantitativamente proporciona una medida probabilística de la importancia de esas variables en el problema, dando lugar a una probabilidad explícita de las hipótesis que se enuncian.

Por este motivo, las redes bayesianas difieren de otros de los métodos populares utilizados en problemas de clasificación mediante aprendizaje automático (como las redes neuronales y los árboles de decisión), debido a que plantean una medida cuantitativa de las variables. El aprendizaje basado en redes bayesianas es ampliamente utilizado en tareas como la clasificación de textos, e-mails, entre otras [13].

Las características principales que poseen las redes bayesianas en tareas de aprendizaje son:

- Cada ejemplo observado modifica la probabilidad para que la hipótesis formulada sea correcta, es decir, puede aumentarla o disminuirla.
- Si una hipótesis no concuerda con un conjunto de ejemplos más o menos grande no es desechada por completo sino que se disminuye esa probabilidad estimada para la hipótesis;
- Los métodos bayesianos son robustos a los posibles ruidos presentes en los ejemplos de entrenamiento, además en los casos de que esos ejemplos posean datos incompletos o erróneos;
- Cuentan con la posibilidad de tener el conocimiento a priori o conocimiento del dominio en forma de probabilidades para la predicción de la hipótesis.

En problemas de clasificación es útil la utilización del Teorema de Bayes, el cual permite estimar las probabilidades a posteriori de cualquier hipótesis consistente con el conjunto de datos de entrenamiento y de esta manera se puede escoger la hipótesis más probable. Los clasificadores Bayesianos están basados en el teorema de Bayes, el cual es conocido como la fórmula de la probabilidad de las causas. Los clasificadores bayesianos han demostrado una alta exactitud y velocidad cuando se han aplicado a grandes volúmenes de datos. Básicamente una red bayesiana es un grafo acíclico dirigido, en el que cada nodo representa un atributo/variable y cada arco una dependencia probabilística, en la cual se especifica la probabilidad condicional de cada atributo dados sus padres, el atributo al que apunta el arco es dependiente del que está en el origen de éste (causa-efecto). La estructura de la red brinda información sobre las dependencias probabilísticas entre los atributos, así como las independencias condicionales de un atributo (o conjunto de atributos) dado otro/s atributo/s, dichas independencias simplifican la representación del conocimiento (menos parámetros) y el

razonamiento (propagación de las probabilidades). El paradigma clasificatorio en el que se utiliza el teorema de Bayes en conjunción con la hipótesis de independencia condicional de los atributos predictores dada la clase que se conoce como Naive Bayes [14] [15] [16].

#### **4 Prototipo de sistema para la determinación del nivel de contenido de palo en la yerba mate**

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 software desarrollado en el entorno Matlab, en este caso la 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 [17], que incluye los siguientes pasos: Diseño; Elección de la herramienta de desarrollo; Construcción y prueba del prototipo; Refinamiento y generalización.

##### **4.1 Preparación de las muestras de yerba mate**

Cada muestra es preparada en un molino del laboratorio a partir de 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 es molido en el laboratorio del INYM para obtener una molienda fina de hoja y palo de yerba mate (ver Figura 1).



**Fig. 1.** Molienda de palo de yerba mate.

Una vez obtenido la molienda fina de la hoja y palo de la yerba mate (ver Figura 2) se procede a preparar las muestras con diferentes contenidos de palo con una balanza digital de precisión, pesando cada muestra 100 gramos (ver figura3).



**Fig. 2.** Hoja y palo de yerba mate molida.



**Fig. 3.** Balanza digital de precisión para obtener distintas muestras.

Se decidió tomar un rango de clasificación de 6 (seis) muestras (ver figura 4) de yerba mate con porcentajes de palo conocidas 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.



**Fig. 4.** Muestras de yerba mate con diferentes porcentajes de palo.

## 4.2 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.

## 4.3 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 Fig. 5 se observan el gráfico de dispersión para los descriptores de intensidad y en la Fig.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.

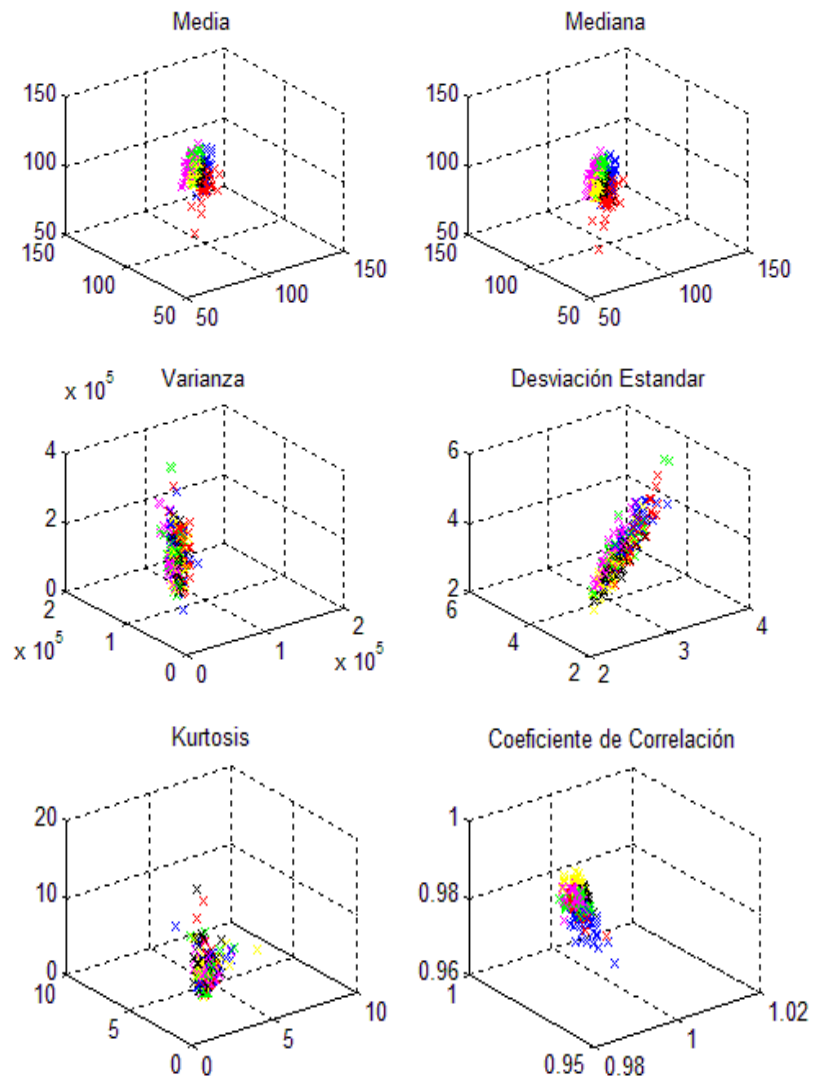


Fig. 5. Descriptores de imágenes de intensidad en escala RGB.

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.

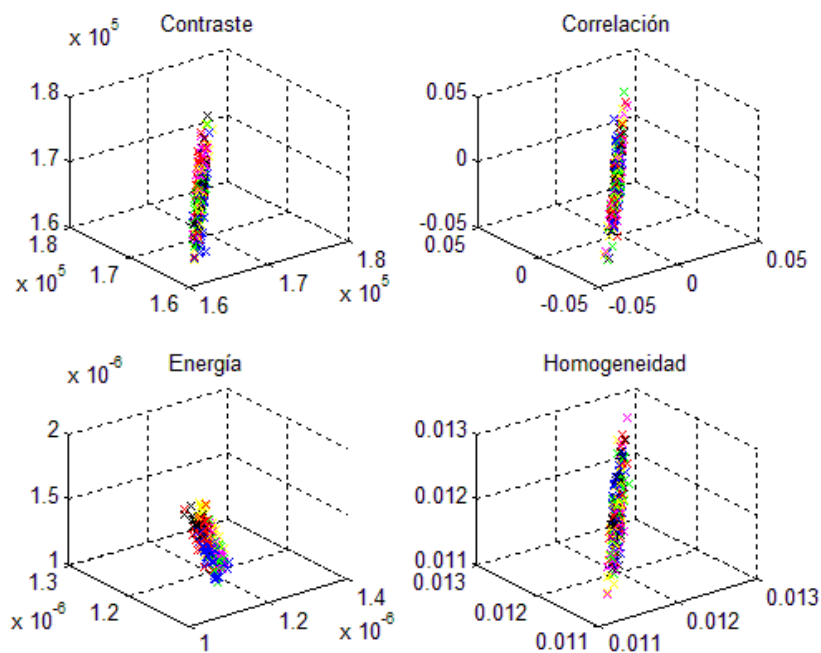


Fig. 6. Descriptores de imágenes de textura en escala RGB.

#### 4.4 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. En el conjunto las diferentes

clases corresponden a los 6 niveles de contenido de palo: 15%, 20%, 25%, 30%, 35% y 40%.

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 1.

**Tabla 1.** 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

#### 4.5 Experimentos y análisis de resultados con NB

El rendimiento o performance del uso de NB como clasificador, es analizado en función al número de aciertos obtenidos en el proceso de clasificación de palos y hojas de la yerba mate.

En la Tabla 2 se exponen los resultados obtenidos de los experimentos que se llevaron a cabo con cada combinación posible de los descriptores seleccionados, los mismos conforman los diferentes subconjuntos de datos de entrada.

**Tabla 2.** Resultados obtenidos por los distintos experimentos.

Experimento	Descriptores	Porcentaje de Aciertos
1	media-mediana-correlación-energía	70,00
2	media-mediana-correlación	78,33
3	media-mediana-energía	68,33
4	media-correlación-energía	68,33
5	mediana-correlación-energía	70,00
6	media-mediana	68,33
7	media-correlación	00,00
8	media-energía	63,33
9	mediana-correlación	85,00
10	mediana-energía	63,33

11	correlación-energía	53,33
12	media	70,00
13	mediana	65,00
14	correlación	58,33
15	energía	35,00

## 5 Conclusiones

En este caso de estudio se investigó el desempeño del algoritmo de clasificación NB para la determinación del nivel de contenido de palo en la yerba mate elaborada.

A partir de las pruebas y los resultados obtenidos de las mismas, se puede destacar 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.

Al evaluar cada descriptor por separado se podría pensar que combinándolos arrojarían resultados superiores y brindarían un mayor aporte al proceso de clasificación. Sin embargo, al realizar estas combinaciones muchas veces los datos se desestabilizan arrojando como resultado final una clasificación de menor nivel. En este caso particular se puede apreciar que la combinación de los descriptores de media y mediana dio como resultado un porcentaje de aciertos superior a los demás.

Analizando los resultados finales se puede concluir que el clasificador de NB es un método confiable en el reconocimiento de una clase a priori, logrando un 85% de aciertos en la clasificación del nivel de palo. Este método permite además, la posibilidad de automatizar este proceso rutinario de control de calidad en la elaboración de yerba mate.

## 6 Bibliografía

- [1] V. Dr. Garín, «Contribución al estudio del cultivo e industria de la Yerba Mate». Ministerio de Agricultura de la Nación».
- [2] C. A. Nacional, «Capítulo XV,» n° 1194.
- [3] C. N. d. Alimentos, *Reunión Plenaria -14, 15 y 16 de Abril de 2004. ACTA N° 61.*
- [4] Schmalko, «El color como una medida del porcentaje de palos en la yerba mate,» 2005.
- [5] F. E. Favret, K. Eckert, A. Felten y G. Sanderg, «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*, n° Artículo N° 6939 - ISBN: 978-987-633-134-0, 2015.
- [6] M. Escalada, M. Schmalko y . R. G. Känzig, «El extracto acuoso como una medida del contenido de palos en la Yerba Mate,» *Revista de ciencia y tecnología*, vol. 1, 1998.

- [7] L. R. Ybarra, J. A. Duce y S. A. Borden, «Estudio de las cenizas y su utilización en la determinación del contenido de palo en la Yerba Mate,» *Revista de ciencia y tecnología*, nº 13, 2010.
- [8] Hedman, Crotti y Xiscatti Perez, «Determinación del contenido de palo en la yerba mate elaborada con palo mediante análisis de imagen,» *Hedman Ingeniería*.
- [9] S. d. I. <http://www.inym.org.ar>, «P.R.A.S.Y/Proyectos en Ejecución: Proyectos de investigación, experimentación y capacitación financiados parcial o totalmente por el INYM,» 25-06-13.
- [10] J. C. Michalus y D. R. Rabenschlag, «Análisis de diagrama de proceso aplicado al Proceso de elaboración primaria de yerba mate,» 1997.
- [11] M. Naffin, «Recopilación de Información del Inym,» 2006.
- [12] W. S. Rasband, «Análisis Sectorial Nro 1. Yerba Mate,» 2013 - 2007.
- [13] L. L. Chao, Estadística para las ciencias administrativas, Santa Fé - Bogotá: McGraw Hill, 1993.
- [14] F. García Castellano, «Modelos Bayesianos para la clasificación supervisada. Aplicaciones al análisis de datos de expresión genética.,» Universidad de Granada, Granada, 2009.
- [15] J. P. C. J. Gámez Martín, «Sistemas Expertos Probabilísticos,» *Colección Ciencia y Técnica*, nº 20, 1998.
- [16] R. O. Duda, H. P. E. y D. G. Stork, Pattern Classification, 2d Edition ed., USA y Canadá: Editorial Wiley - Interscience, 2000.
- [17] E. Castillo, J. M. Gutiérrez y A. S. Hadi, Sistemas Expertos y Modelos de Redes Probabilísticas, Academia de Ingeniería, 1996.