

Clasificación de muestras de yerba mate mediante descriptores de textura

Damián Deangeli, David López, Agustín Senger, César Martínez y Enrique Albornoz

Instituto de Investigación en Señales, Sistemas e Inteligencia Computacional, sinc(i), FICH-UNL/CONICET, Argentina

Abstract

La determinación de la calidad de la yerba mate está fuertemente influenciada por su contenido de palos en la mezcla. El Código Alimentario Argentino establece una técnica basada en zarandeo como método para determinar este parámetro, y éste se realiza de forma manual, mediante zarandas que separan el contenido y balanzas que pesan por separado palos y hojas, insumiendo mucho tiempo y mano de obra. En este trabajo se propone una metodología para la estimación del porcentaje de palo en muestras de yerba mate mediante la utilización de métodos de análisis de texturas en imágenes. Los resultados obtenidos permiten mejorar sustancialmente el comportamiento del método de referencia basado en técnicas de procesamiento digital de imágenes.

Palabras Clave

Yerba mate, procesamiento digital de imágenes, descriptores de textura, LBP, HOG, máquinas de soporte vectorial.

1- Introducción

En Argentina, el mate es considerado una de las principales infusiones, un elemento muy popular y de consumo cotidiano. Esta infusión tiene como insumo a las hojas de yerba mate (*Ilex paraguariensis* Saint Hilaire, Aquifoliácea, ver Figura 1), planta originaria de las cuencas de los ríos Paraná, Paraguay y Uruguay [1]. Estas plantas previamente secadas, cortadas y molidas forman la yerba mate (ver Figura 2). Su producción en nuestro país, por cuestiones climáticas y de características del suelo, se realiza únicamente en la provincia de Misiones y el nordeste de Corrientes [2].



Ilex paraguariensis A. St.-Hil.

Figura 1: partes constitutivas de la yerba mate: hojas, tallos, flores y frutos.

El Código Alimentario Argentino (CAA) [3], capítulo 15 - artículos 1193 y 1194, define el producto “Yerba Mate Elaborada con Palo” cuyos componentes son hojas, polvo y palos. Ésta debe contener al menos 65% de hojas (desechadas, rotas o pulverizadas) y a lo sumo un 35% de palo. El procedimiento tradicional para determinar la composición consiste en utilizar zarandas que permiten separar las partículas que la componen según su tamaño. Lo obtenido de la separación por tamices, es luego pesado para determinar de esta manera una proporción gravimétrica de cada uno de los componentes de la yerba mate. Este procedimiento fue considerado deficiente, ya que existe subestimación del

contenido, insume tiempo y requiere alta intervención manual [3].



Figura 2: obtención de la yerba mate: cosecha, trituración y resultado final (mezcla de hoja con palo).

Recientemente, la Comisión Nacional de Alimentos (CONAL) propuso, con fecha del 28/03/2017, la incorporación de un nuevo método de *análisis de fibra cruda* para determinar los componentes en yerba mate elaborada al CAA con el fin de proporcionar más confiabilidad a la verificación del contenido del producto final. Este método sirve para determinar qué cantidad de palo se encuentra en la fracción que pasa por el tamiz Nro. 40 (polvo) con el fin de mejorar la genuinidad y calidad del producto¹. Si bien esta última

¹ Cabe destacar que éstas aun no han sido incorporadas al CAA, ver http://www.anmat.gov.ar/alimentos/codigoa/CAPITULO_XV.pdf y

técnica permite una determinación más precisa, debe realizarse en laboratorios equipados con instrumentos tecnológicos importantes.

Para abordar el problema de clasificar el porcentaje de palos en la mezcla se han propuesto algunos métodos basados en procesamiento digital de imágenes (PDI) [4,5]. Éstos pueden obtener un alto grado de eficiencia en un período corto de tiempo, pueden incorporarse a la cadena de procesos de la yerba mate sin grandes inversiones en lo que respecta al hardware y reducirían la manipulación de las muestras del producto evitando alteraciones en la calidad de las mismas. En [4] se propuso utilizar una medida de entropía y otra de umbral adaptativo para identificar la cantidad de palos en las muestras. En [5] se utiliza el canal de Luminancia [6] y una secuencia heurística de técnicas básicas de PDI para estimar el contenido de palos. Hasta nuestro conocimiento, este último trabajo es el más reciente que utiliza PDI en esta tarea, por lo que fue tomado como referencia. En este trabajo se propone un esquema de clasificación que contempla una etapa de extracción de características utilizando dos métodos de análisis de texturas: Patrones Binarios Locales (LBP, del inglés *Local Binary Patterns*) [7] e Histogramas de Gradientes Orientados (HOG, del inglés *Histogram of Oriented Gradients*) [8]; y una etapa de clasificación en la que se utilizan máquinas de soporte vectorial (SVM, del inglés *Support Vector Machines*) [9].

La organización del trabajo se presenta de la siguiente manera: la Sección 2 describe los métodos utilizados para la etapas de extracción de características y clasificación, además se aborda la metodología de experimentación utilizada. La Sección 3 presenta los resultados obtenidos para los diferentes modelos sobre la base de datos utilizada. La Sección 4 discute los

<http://www.alimentosargentinos.gov.ar/contenido/marco/CAA/ModificacionesCAA.html>

resultados, se comparan con el sistema de referencia y se proponen las posibles generalizaciones de los resultados obtenidos. Finalmente, en la Sección 5 se presentan las conclusiones y trabajos futuros.

2 - Materiales y metodología

En esta sección describiremos el método utilizado como referencia y las alternativas propuestas en este trabajo. Luego se introducirá la metodología utilizada en la validación de los modelos y el conjunto de imágenes utilizadas.

2.1 Sistema de referencia

Este método consiste en una secuencia de pasos para realizar realce de la imagen, la extracción de los componentes y la extracción de características que permite estimar la cantidad de palos. En la Figura 3 se presenta un esquema general. Las técnicas aplicadas para lograr el realce incluyen el *ajuste del brillo y contraste*, *balance de color* y *corrección Gamma* [6]. Luego, la imagen es binarizada y se le aplican filtros morfológicos para quitar puntos aislados (ruido) y obtener regiones convexas (palos). Finalmente, se obtienen imágenes de sólo palo y sólo hoja, que son utilizadas para calcular la relación porcentual (de área) entre estos componentes.

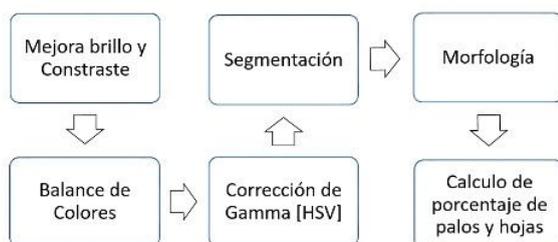


Figura 3. Esquema general del método de referencia.

2.2 Métodos propuestos

A continuación se presentan los dos métodos utilizados para obtener información de las texturas de las imágenes

(LBP y HOG) [7,8] y el método de clasificación que fue el mismo en ambos casos.

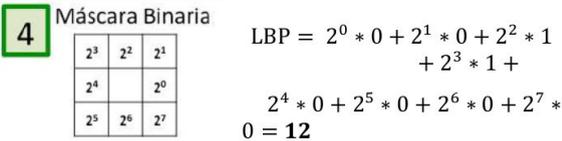
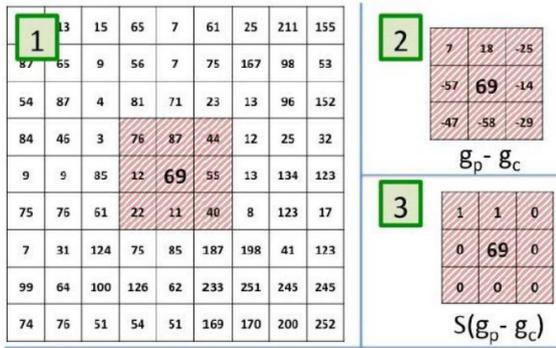
Local Binary Patterns

Este operador de textura simple y eficiente, etiqueta cada píxel de la imagen analizando su vecindario, si el nivel de gris vecino supera al valor central se le asigna 1 y 0 en otro caso. Luego, se obtiene un valor LBP para el píxel central basado en la aplicación de una *máscara binaria*, calculada como la combinación lineal de los valores binarios multiplicados por potencias de 2. Entre las ventajas de este método se pueden mencionar el bajo coste computacional, su gran poder discriminativo y la robustez frente a variaciones en la intensidad del nivel de gris (que pueden ser causadas por diferencias en la iluminación). La ecuación que lo define está dada por:

$$LBP_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p, s(x) = \begin{cases} 1 & \text{si } x \geq 0 \\ 0 & \text{si } x < 0 \end{cases}$$

donde P es el número de vecinos a considerar, R es el tamaño del vecindario y g_c y g_p son los valores de gris del píxel central y del píxel vecino, respectivamente [7]. En la Figura 4 se presenta un ejemplo gráfico del cálculo del LBP, usando los parámetros $P=8$ y $R=1$.

El resultado es una matriz de dimensiones similares a la de la imagen original, sobre la que se le calcula un histograma.



El cálculo se realiza sobre celdas de 16x16 píxeles y se cuantizan los 2^k valores posibles en 50 niveles diferentes. Finalmente, el vector de características o descriptor LBP se forma con la concatenación de los histogramas de cada celda.

Figura 4. Ejemplo de cálculo de LBP.

Histogram of Oriented Gradients

Este método contabiliza las ocurrencias de la orientación del gradiente en una determinada porción de una imagen. La idea del descriptor de HOG es que la apariencia y forma de un objeto dentro de una imagen puede ser caracterizada por la manera en que la dirección e intensidad del gradiente varían en el borde (contorno) del objeto o región específica de la imagen [8]. El primer paso es obtener la información de los gradientes de la imagen. Luego, la imagen se divide en celdas, que se agrupan en bloques y con ellos se calculan los histogramas para formar el descriptor HOG de la imagen.

Para el cálculo de los gradientes de primer orden se utilizan filtros de Sobel [6], que capturan los bordes, siluetas y alguna otra información de textura mientras que reducen la influencia de las variaciones en iluminación de la imagen. El gradiente de una imagen captura el cambio en la

intensidad o en el color de la imagen y la dirección hacia donde cambia. En el siguiente paso, la imagen se divide en celdas (8x8, 16x16 píxeles, etc.). Para cada celda se calcula un histograma del gradiente, usando la magnitud y dirección del gradiente.

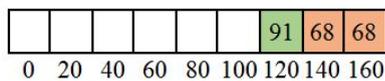
Para esto se fracciona el rango en que puede variar la dirección, que está representado por ángulos, y en cada porción del mismo se acumula la magnitud que toma el gradiente. Luego, se agrupan las celdas (considerando un tamaño fijo) en bloques. En nuestro análisis se utilizan bloques de 2x2 celdas, con un solapamiento de la mitad las mismas. Los histogramas de cada celda individual son normalizados con la norma del vector fila conformado por la concatenación de los histogramas de las celdas que conforman un bloque. Este vector normalizado es el que se denomina descriptor de HOG para dicho bloque. Finalmente, se realiza la concatenación de todos los descriptores en un único vector de características, el cual es utilizado en la etapa de clasificación de muestras.

2	3	4	4	3	4	2	2
5	11	17	13	7	9	3	4
11	21	23	27	22	17	4	6
23	99	165	135	85	32	26	2
91	155	133	136	144	152	57	28
98	196	76	38	26	60	170	51
165	60	60	27	77	85	43	136
71	13	34	23	108	27	48	110

Magnitud del Gradiente

80	36	5	10	0	64	90	73
37	9	9	179	78	27	169	166
87	136	173	39	102	163	152	176
76	13	1	168	159	22	125	143
120	70	14	150	145	144	145	143
58	86	119	98	100	101	133	113
30	65	157	75	78	165	145	124
11	170	91	4	110	17	133	110

Dirección del Gradiente



Histograma de Gradientes

Figura 5. Ejemplo de cálculo de HOG.

En la Figura 5 se puede observar cómo es procesada la información de la dirección y magnitud del gradiente de un píxel en particular para el cálculo de HOG. A partir de la dirección, la cual toma valores entre [0,180], observamos a qué región del rango pertenece, ya que el mismo fue fragmentado de a 20 grados. Una vez identificada la región, debemos ir acumulando la magnitud del gradiente de ese píxel. Cuando el valor de la dirección se encuentra en el medio de dos rangos, se acumula la mitad del valor de magnitud en cada uno de estos. Repitiendo el proceso para cada píxel que conforma la celda obtendremos el histograma de la misma.

Clasificador SVM

Se optó por este tipo de clasificador ya que en trabajos previos con objetivos similares los SVM han demostrado tener un buen desempeño [11]. Entonces, los vectores obtenidos con los métodos presentados previamente se utilizan para entrenar y probar el clasificador SVM.

Las máquinas de soporte vectorial son clasificadores lineales, puesto que producen separadores lineales o hiperplanos en un espacio transformado que puede tener una dimensión muy superior al de características. Las SVMs fueron pensadas para resolver problemas de clasificación binaria, aunque se han adaptado para resolver problemas de regresión, de agrupamiento o de múltiples clases. El objetivo del entrenamiento de una SVM es seleccionar un hiperplano de separación que equidista de los ejemplos más cercanos a las fronteras de cada clase y así se logra un margen máximo a cada lado del hiperplano. La ventaja es que sólo se consideran estos ejemplos para el entrenamiento y son los que reciben el nombre de vectores soporte. Este método ha demostrado tener una buena capacidad de generalización, evitando en gran medida el problema del sobreajuste a los ejemplos de entrenamiento [9].

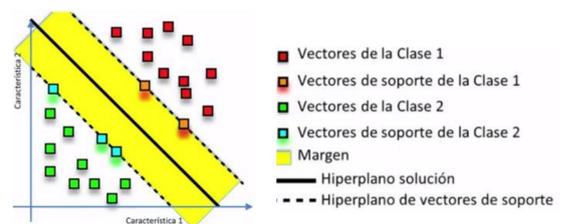


Figura 6. Ejemplo de un SVM binario.

En la Figura 6 se presenta un ejemplo de definición de un hiperplano de SVM para dos clases diferentes. Para este trabajo se utilizan 3 clases que representan diferentes contenidos de palo en muestras de yerba mate.

2.3 Esquema de validación

Para evaluar los 3 modelos presentados se utiliza un subconjunto de las imágenes utilizadas en [5]². Este subconjunto tiene 27 imágenes de 2448x3264 pixels de muestras de yerba mate y contienen 9 ejemplos de cada clase: muestras con 15%, 30% y 45% de palo, respectivamente (ver Fig. 7).



Figura 7. Imágenes pertenecientes a la base de datos. De derecha a izquierda: 15%, 30%, y 45% de palo en la muestra

En cada experimento se consideró un esquema de validación cruzada de k -fold [10], ya que asegura que todas las imágenes sean utilizadas tanto en el entrenamiento como en la validación. Ésto permite evaluar la capacidad de generalización de los modelos.

Se utilizaron 2 esquemas para verificar el desempeño del sistema: Leave-1-out y Leave-3-out estratificado. Para el primer caso, se hacen 27 pruebas donde 26 imágenes se utilizan para entrenamiento y 1 para validación, así todas se prueban una vez. Mientras que, en el segundo esquema, se seleccionan 3 imágenes (una por cada clase) de forma aleatoria y sin repetición para cada conjunto de validación, en cada caso se utilizan las 24 restantes para entrenamiento (8 por clase), de esta manera se realizan 9 pruebas.

3 - Resultados

En esta sección se presentan los resultados obtenidos de evaluar el desempeño al

utilizar descriptores de texturas en la clasificación de muestras de yerba para los dos esquemas de validación definidos previamente. Los porcentajes de efectividad serán contrastados con los del sistema referencia [5]. Sin embargo, dado que el método referencia es totalmente heurístico y fue definido con base en el análisis arbitrario de todas las muestras, no se pueden reproducir en él los esquemas de validación cruzada. Además, esta metodología no asegura la capacidad de generalización del sistema, ya que éste se ajusta y se prueba con las mismas muestras. Adicionalmente a los rendimientos promedio de los métodos, se presentarán las matrices de confusión para evaluar más detalladamente en qué casos se presentan los problemas de clasificación. En una matriz de confusión las filas representan las etiquetas verdaderas de los ejemplos mientras que las columnas indican las etiquetas predichas por el modelo, y la diagonal principal muestra los aciertos. El resultado promedio de la referencia sobre las 27 muestras es 66.67%. En la Tabla 1 se presenta la matriz de confusión respectiva.

Tabla 1. Matriz de confusión de sistema referencia.

		Valor predicho		
		15%	30%	45%
Valor verdadero	15%	9	0	0
	30%	0	9	0
	45%	0	9	0

Para el esquema de validación Leave-1-out, el resultado promedio obtenido por el modelo que utiliza LBP es de 81.48% mientras que para el modelo basado en HOG también se obtiene un 81.48% de aciertos. En las Tablas 2 y 3 se presentan las matrices de confusión de estos modelos, respectivamente, para este esquema de validación.

Tabla 2. Matriz de confusión LBP, leave-1-out.

² Estas imágenes fueron provistas por el Ing. Christian Xiscatti Pérez, fueron obtenidas con una cámara de 8 Mpx de un dispositivo Samsung Galaxy S5 y forman parte de su tesis doctoral en colaboración con el INYM.

		Valor Predicho (SVM)		
		15%	30%	45%
Valor Verdadero	15%	8	0	1
	30%	1	6	2
	45%	1	0	8

Tabla 3. Matriz de confusión HOG, leave-1-out.

		Valor Predicho (SVM)		
		15%	30%	45%
Valor Verdadero	15%	9	0	0
	30%	0	6	3
	45%	0	2	7

Los resultados promedios obtenidos para el esquema de validación Leave-3-out estratificado son similares a los anteriores, el modelo que utiliza LBP obtiene de 81.48% al igual que el modelo basado en HOG. Las matrices de confusión se muestran en las Tablas 4 y 5, respectivamente.

Tabla 4. Matriz de confusión LBP, leave-3-out estratificado.

		Valor Predicho (SVM)		
		15%	30%	45%
Valor Verdadero	15%	8	0	1
	30%	1	6	2
	45%	1	0	8

Tabla 5. Matriz de confusión HOG, leave-3-out estratificado.

		Valor Predicho (SVM)		
		15%	30%	45%
Valor Verdadero	15%	9	0	0
	30%	0	6	3
	45%	0	2	7

4 - Discusión

En los resultados presentados puede observarse una importante mejora respecto del método referencia, donde el incremento obtenido es de casi un 15%. Los descriptores de texturas (LBP y HOG)

logran capturar información útil para realizar la clasificación de los distintos tipos de muestras, consecuentemente se logra un comportamiento similar en ambos esquemas de validación. En las matrices de confusión es posible notar que existen más confusiones a mayor contenido de palos en las muestras. Si bien es necesario hacer una experimentación más intensa, de mantenerse la tendencia de las confusiones, se podría proponer un esquema de clasificación jerárquico (tipo árbol de decisión binario). Así, en cada nivel que se agrega se clasifican patrones cada vez más complicados o confundibles.

Es importante destacar que el método que proponemos presenta una mejor metodología que el de referencia, al haber eliminado heurísticas y tener la capacidad de generalizar resultados. Sin embargo, se espera mejorar el desempeño obtenido explorando diferentes técnicas de preprocesamiento de imágenes, a fin de realzar características que sean provechosas para los métodos de extracción de texturas.

5 - Conclusiones y trabajos futuros

En este trabajo se abordó el problema de identificación de la cantidad de palos presentes en una muestra de yerba mate, útil para determinación de calidad de las muestras. Se han propuesto dos métodos de clasificación que utilizan técnicas de análisis de texturas: LBP y HOG. Se implementó el método reportado más actual de identificación basado en PDI [6], a fin de utilizarlo como referencia. Para la etapa de validación de los modelos se utilizaron dos estrategias de validación cruzada.

En los resultados puede verse que los dos métodos propuestos mejoran el rendimiento previamente reportado, por lo que las técnicas basadas en análisis de texturas serían muy apropiadas para la tarea mientras que evitan la sobrecarga de heurísticas aplicadas en el método referencia. Ambas técnicas (HOG y LBP) logran un 81.48% promedio de aciertos, lo

que representa un incremento del 14.81% respecto a la referencia. Además, dada la metodología de validación, se obtuvo un modelo cuyos resultados son generalizables a muestras que no ha visto el sistema.

Como trabajo futuro, se pretende enfocar la tarea como un problema de regresión, para lo que se requerirá un mayor conjunto de datos con diversos contenidos de palos en las muestras. Además, se pretende explorar el uso de otros indicadores de texturas y usarlos combinados para la clasificación de muestras.

Agradecimientos

Los autores quieren agradecer la colaboración del Ing. Christian Xiscatti Pérez en la facilitación de las imágenes. Además, se agradece a la *Agencia Nacional de Promoción Científica y Tecnológica* (ANPCyT) (con PICT-2015-977), la Universidad Nacional del Litoral (con PACT 2011 #58, CAI+D 2011 #58-511 y CAID-PJ-50020150100055LI) y al Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET), por su apoyo.

Referencias

- [1] Giberti, G. C. (2011). La “yerba mate” (*Ilex paraguariensis*, Aquifoliaceae) en tempranos escritos rioplatenses de Bonpland y su real distribución geográfica en Sudamérica austral. *Bonplandia* (JSTOR), 203-212.
- [2] Carolina Sessa and Maria Sol Niemand, “Análisis de diagnóstico tecnológico sectorial Yerbatero y Tealero”, Reporte técnico, Ministerio de Ciencia, Tecnología e Innovación Productiva, 2013.
- [3] CÓDIGO ALIMENTARIO ARGENTINO. 1969. Capítulo XV, artículos: 1137 al 1198 - Productos Estimulantes o Frutivos. - Actualizado al 2/2013. En: www.anmat.gov.ar

[4] J. C. O. Hedman, L. Crotti, and C. Xiscatti Pérez, "Determinación del contenido de palo de la Yerba Mate elaborada con palo mediante análisis de la imagen.," en 5to. Congreso Sudamericano de la Yerba Mate, Posadas, 2011.

[5] C. Xiscatti Perez and F. Botteron, "A Practical Approach for Segmentation of Twigs on Samples of Yerba Mate by Digital Image Processing," in *IEEE Latin America Transactions*, vol. 11, no. 1, pp. 21-26, Feb. 2013.

[6] González, Rafael C. and Woods, Richard E, "Digital Image Processing (3rd Edition)", 2006. Prentice-Hall, Inc. Upper Saddle River, NJ, USA.

[7] T. Ojala, M. Pietikainen, and D. Harwood, "A Comparative Study of Texture Measures with Classification Based on Feature Distributions," *Pattern Recognition*, vol. 29, no. 1, pp. 51-59, 1996.

[8] Dalal, Navneet and Triggs, Bill, "Histograms of oriented gradients for human detection" in *Computer Vision and Pattern Recognition IEEE Computer Society Conference on*, vol. 1, pp. 886-893, 2005.

[9] Duda, Richard O., Peter E. Hart, David G. Stork, "Pattern Classification (2nd Edition)", 2000.

[10] Payam Refaeilzadeh, Lei Tang, Huan Liu. Cross-Validation. In "Encyclopedia of Database Systems" pages 532-538, 2009.

[11] C. Wallraven, B. Caputo, and A. Graf. "Recognition with local features: the kernel recipe". In *Proc. ICCV*, pages 257-264, 2003.

Datos de Contacto:

David López. *sinc(i)*, FICH-UNL/CONICET.
david.lopezyen@gmail.com