

**CLASIFICACIÓN DE MUESTRAS DE YERBA MATE
BASADA EN DESCRIPTORES DE TEXTURA**

Deangeli Damián, López David, Senger Agustín

Instituto de Investigación en Señales, Sistemas e Inteligencia Computacional, sinc(i)

Facultad de Ingeniería y Cs. Hídricas, UNL

Área: Ingeniería

Sub-Área: Informática y Sistemas de Información

Grupo: X

Palabras clave: Yerba Mate, Descriptores de Texturas, Clasificador SVM.

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 (*Illexparaguariensis* Saint Hilaire, Aquifoliácea), planta originaria de las cuencas de los ríos Paraná, Paraguay y Uruguay (Giberti, G. C. 2011). Estas plantas previamente secadas, cortadas y molidas forman la yerba mate. 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.

El Código Alimentario Argentino (CAA), 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. Para determinar la composición se utilizan zarandas que permiten separar las partículas que la componen según su tamaño. Lo obtenido de la separación por tamices, es pesado para determinar de esta manera una proporción gravimétrica de cada uno de los componentes de la yerba mate. Este procedimiento resulta hoy deficiente, dado que, existe subestimación del contenido, insume tiempo y requiere alta intervención manual.

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). J. C. O. Hedman, L. Crotti, y C. Xiscatti Pérez (2011) propusieron la utilización de una medida de entropía y otra de umbral adaptativo para identificar la cantidad de palos en las muestras. C. Xiscatti Perez y F. Botteron (2013) utilizan el canal de Luminancia 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*) e Histogramas de Gradientes Orientados (HOG, del inglés *Histogram of Oriented Gradients*); y una etapa de clasificación en la que se utilizan máquinas de soporte vectorial (SVM, del inglés *Support Vector Machines*).

Proyecto: CAID-PJ-50020150100055LI

Director del proyecto: Enrique M. Albornoz

Directores de los becarios/tesistas: Enrique M. Albornoz y César Martínez

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.

El método utilizado como referencia 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. Las técnicas aplicadas para lograr el realce incluyen el ajuste del brillo y contraste, balance de color y corrección Gamma. 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.

Métodos propuestos

A continuación se presentan los dos métodos utilizados para obtener información de las texturas de las imágenes (LBP y HOG) y el método de clasificación que fue el mismo en ambos casos.

Patrones Binarios Locales

Este operador de textura simple y eficiente, definido en T. Ojala, M. Pietikainen, y D. Harwood (1996), 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. 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.

El resultado es una matriz de dimensiones similares a la de la imagen original, sobre la que se le calcula un histograma. Finalmente, el vector de características o descriptor LBP se forma con la concatenación de los histogramas de cada celda.

Histogramas de Gradientes Orientados

Este método contabiliza las ocurrencias de la orientación del gradiente en una determinada porción de una imagen. El primer paso es obtener la información de los gradientes de la imagen, este captura el cambio en la intensidad o en el color de la imagen y la dirección hacia donde cambia. 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, tal como se desarrolla en Dalal, Navneet and Triggs, Bill (2005)

En el siguiente paso, la imagen se divide en celdas. Para cada celda se calcula un histograma del gradiente orientado, usando la magnitud y dirección del gradiente. Estas celdas son agrupadas 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. Luego los vectores normalizados son concatenados, para conformar el descriptor de HOG para dicho bloque. Finalmente, se realiza la concatenación de todos los descriptores de la imagen en un único vector de características, el cual es utilizado en la etapa de clasificación de muestras.

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, Richard O. Duda, Peter E. Hart, David G. Stork (2000). 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.

Esquema de validación

Para evaluar los 3 modelos presentados se utiliza un subconjunto de las imágenes utilizadas en el trabajo de investigación de C. Xiscatti Perez y F. Botteron (2013). Este subconjunto tiene 27 imágenes (2448x3264 pixels) de muestras de yerba mate y contienen 9 ejemplos de cada clase: muestras con 15%, 30% y 45% de palo, respectivamente. En cada experimento se consideró un esquema de validación cruzada de k-fold, el cual nos permite evaluar la capacidad de generalización de los modelos.

Se utilizó un esquema para verificar el desempeño del sistema denominado Leave-3-out estratificado. Para este 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.

CONCLUSIÓN Y RESULTADOS

Dado que el método de referencia es totalmente heurístico y fue definido con base en el análisis arbitrario de todas las muestras, no se puede reproducir el esquema de validación cruzada para contrastarlo. El resultado promedio de la referencia sobre las 27 muestras es 66.67%. Para el esquema de validación Leave-3-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 los resultados presentados puede observarse una importante mejora respecto del método referencia, donde el incremento obtenido es de casi un 15%. Vemos que los descriptores de texturas (LBP y HOG) logran capturar información útil para realizar la clasificación de los distintos tipos de muestras.

Es importante destacar que el método que proponemos presenta una mejor metodología que el de referencia, tanto en las capacidades de automatizar el proceso, de eliminar heurísticas y 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.

BIBLIOGRAFÍA BÁSICA

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.

CÓDIGO ALIMENTARIO ARGENTINO. 1969. Capítulo XV, artículos: 1137 al 1198 - Productos Estimulantes o Frutivos. - Actualizado al 2/2013. En: www.anmat.gov.ar

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.

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

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.

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.

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