



RECONOCIMIENTO DE GRANOS DE CAFÉ EMPLEANDO TÉCNICAS ESTADÍSTICAS DE CLASIFICACIÓN



RECOGNITION OF COFFEE BEANS USING STATISTICAL CLASSIFICATION TECHNIQUES

¹José Alfredo Palacio, ²Mauricio Vásquez Carvajal, ³Daniel Esteban Agudelo

¹Esp. Ingeniería Automática, Docente ITM, Calle 73 No 76A -354 Vía al Volador - Medellín - Colombia. E-mail: josepalacio@itm.edu.co. ²Esp. Automatización y Control, Docente ITM, Calle 73 No 76A -354 Vía al Volador - Medellín - Colombia. E-mail: henryvasquez@itm.edu.co. ³Matemático e Ingeniero Electrónico, Docente UdeA, Calle 67 Número 53 - 108-Medellín - Colombia. E-mail: dagudelo@matematicas.udea.edu.co.

RECONOCIMIENTO DE GRANOS DE CAFÉ EMPLEANDO TÉCNICAS ESTADÍSTICAS DE CLASIFICACIÓN

RECOGNITION OF COFFEE BEANS USING STATISTICAL CLASSIFICATION TECHNIQUES

José Alfredo Palacio, Mauricio Vásquez Carvajal, Daniel Esteban Agudelo

RESUMEN

En este artículo se pone a prueba un método de clasificación bayesiana en la identificación de granos de café con tres grados de maduración, seleccionando como características, los valores RGB y HIV y se compara con otros clasificadores ya conocidos. En el problema de procesamiento de imágenes, se separan en K clases con una probabilidad mínima de error de clasificación, todos los parámetros en cada clase son conocidos. El conjunto de parámetros en cada imagen se toman como los patrones de entrada para establecer una regla de Bayes empírica que separa las K clases y conduce a un procedimiento de aproximación estocástica para la estimación de los conjuntos desconocidos. Esta clasificación se puede adaptar a una métrica que adopta una mejor posibilidad de decisión.

Palabras clave: Clasificación, Reconocimiento de Patrones, Café, Estadística de Dispersión.

Recibido 21 de septiembre de 2010.

Aceptado 24 de Mayo de 2011

ABSTRACT

This article tested a Bayesian classification method in the identification of coffeebeans with three levels of maturity, selecting as features RGB and HIV values and compared with other known classifiers. In the image processing problem is separated into K classes with a minimum probability of misclassification, all parameters in each class are known. The set of parameters in each image are taken as the input patterns to establish an empirical Bayes rule separating the classes K and leads to a stochastic approximation procedure for estimating the unknown sets.

Keywords: Classification, Pattern Recognition, Coffee, Statistics of Dispersion.

Received: September 21, 2011

Accepted: May 24, 2011

1. INTRODUCCIÓN

Para el reconocimiento de patrones de granos de café, se requiere como en todo proceso de clasificación, determinar las características que mejor representen cada imagen o señal, estas imágenes son distribuidas en un mapa de características en el caso de dos dimensiones y finalmente mediante un clasificador se determina la clase a la que pertenece una imagen o una señal.

La base de imágenes fue tomada con una cámara digital de 10.2 megapíxeles, en un fondo blanco a la misma distancia y con iguales condiciones de iluminación, el número de muestras fue de 20 fotografías por cada grado de maduración, para el entrenamiento se permite cambiar el número de muestras manteniendo la misma estructura algorítmica, dejando los restantes para su validación.

Se hizo la comparación del clasificador propuesto (Técnicas Estadísticas de Dispersión TED) con otros seis clasificadores empleado en el ToolboxPRTOOLS de Matlab® para ver la separación de los grupos, los clasificadores utilizados fueron Parzen que está basado en el histograma de los datos y estima las densidades de cada clase [1]. El clasificador por Kernel que clasifica elementos con características semejantes, QDC y LDC que son clasificadores bayesianos cuadrático, lineal respectivamente y se basan en el cálculo de las distancias del punto a entrenar a su media de grupo y lo clasifica según la menor distancia [2]. KNN es un clasificador que reúne los vecinos más cercanos en un grupo de elementos que genera cierta similitud [3] y Tree es un clasificador que usa la estadístico de árbol que cuenta con la característica principal de agrupar sucesivamente los datos de entrada en subconjuntos homogéneos basados en reglas desarrolladas a partir de puntos de entrenamiento, utilizando una amplia fuente de datos espectrales y datos auxiliares [4].

Finalmente empleando el valor medio, nivel de varianza y covarianza, se genera una tendencia elipsoidal para cada patrón con valores de amplitud que se rigen por una distribución gaussiana.

El entrenamiento de los datos fue supervisado eligiendo previamente las medias aritméticas y las desviaciones típicas para las tres clases elegidas. Se procura generar un ambiente adecuado para la toman las muestras buscando la mejor luminosidad, estado de los granos, un fondo uniforme y una cámara de buena resolución. Al final se logra obtener que con este conjunto de minucias, el sistema cumpla con unos requerimientos mínimos para selección adecuada del grado de maduración del café.

2. PROCEDIMIENTO.

Se probaron diferentes variables que representaban las propiedades inherentes de cada grano, como lo son el tamaño, la forma, el contenido de color (RGB) (Figura 1), el tono (H), la saturación (S), la intensidad (V) [5] (figura 2), la razón entre cada color $\left(\frac{R}{G}, \frac{R}{B}, \frac{G}{B}\right)$ y finalmente se obtuvo una pobre representación en cuanto a tamaño y forma de los granos de café.

2.1. Extracción de características

Se hizo un análisis en histograma para analizar el HSV- HIV, en donde se observa que se traslapan dos de las clases (figura 3), al hacer todo el proceso de clasificación de los datos mediante validación cruzada, se obtuvo errores del 16% mediante HSV- HIV (figura 4).



Figura 1. Imágenes en niveles RGB



Figura 2. Imágenes en niveles HSV- HIV

Se puede notar en la figura 3 la similitud en cuanto a la tonalidad (H) y la intensidad (I) para los granos verdes y pintones que se confunden en la nube de puntos.

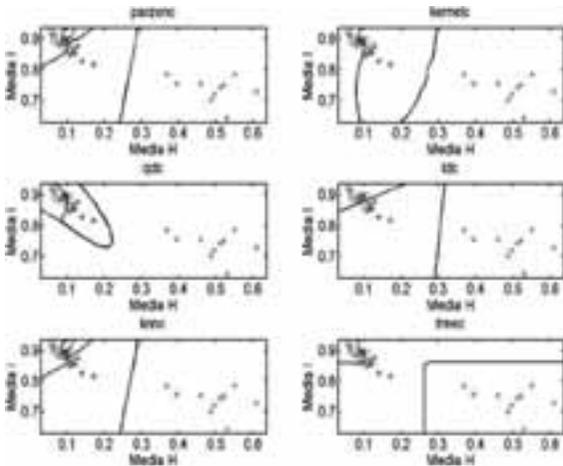


Figura 3. Clasificadores en HSV- HIV

Tratando de mejorar el desempeño de los clasificadores se retomó nuevamente la etapa de caracterización, en donde se apoya la teoría en los valores significativos de RGB [6]. Observando las medias en el contenido de rojo y verde (características) de cada imagen, estas presentan un agrupamiento selectivo para cada clase, el mapa de característica (figura 4) muestra cómo se agrupan en tres clases analizando las características de contenido de rojo (R) y verde (G).

De acuerdo a las distribuciones anteriores, que para la mayoría de clasificadores presentan un buen desempeño en la etapa de entrenamiento, se decide pasar a la etapa de clasificación empleando el clasificador por TED, empleando trece muestras para entrenamiento y siete para prueba. La ecuación asociada a dicho clasificador está dada por:

$$g_i(X) = -\frac{1}{2\sigma_i^2} [X^T X - 2\mu_i^T X + \mu_i^T \mu_i] + \frac{1}{2} \frac{P(\omega_i)}{P(\omega_j)} \quad (1)$$

Donde $P(\omega_i)$ es la probabilidad de que la media con la cual se está comparando el dato esté dentro del conjunto y $P(\omega_j)$ es la probabilidad de que el dato pertenezca al conjunto, X es el vector de medias de la imagen de prueba, μ es el vector de medias de las medias de las imágenes de entrenamiento en cada clase generada, σ_i es la desviación típica en cada una de las clases generadas. Se hace la comparación en cada uno de los g_i encontrados y se elige la menor de ellos.

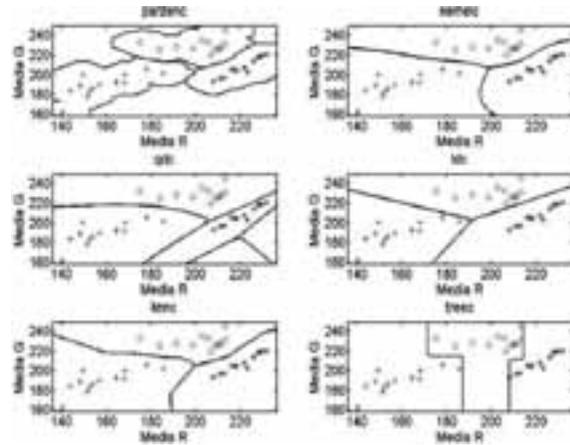


Figura 4. Entrenamiento clasificador de media RG

Finalmente empleando el clasificador por TED representado en la ecuación (1), se obtiene un porcentaje del 100% de selección para los granos verdes y maduros y un 85.7143% de granos pintones que fueron bien clasificados con un entrenamiento de trece imágenes por clase y una prueba de veintiuno imágenes. La matriz de confusión está dada por la tabla 1:

Tabla 1. Matriz de confusión 39-21

Clase	Verde	Pintón	Maduro
Verde	100%	0%	0%
Pintón	14.3%	85.7%	0%
Maduro	0%	0%	100%

Al entrenar con diez imágenes por clase y una prueba de 30 imágenes. La matriz de confusión está dada por la tabla 2:

Tabla 2. Matriz de confusión 30-30

Clase	Verde	Pintón	Maduro
Verde	100%	0%	0%
Pintón	0%	100%	0%
Maduro	0%	0%	100%

2.2. Discusión

Inicialmente se planteó una solución discriminando bajo las características HIV, tono (H) e intensidad (V). Aplicando diferentes clasificadores se observó un traslape debido a la cercanía de las características. En esta etapa se notó que uno de los mejores clasificadores fue el clasificador bayesiano cuadrático.

Para tratar de eliminar el traslape de los datos se hizo una dilatación de estos multiplicándolos por un factor radial

y funcionó muy bien en la etapa de entrenamiento, pero al recuperar la información en los datos de prueba, que igualmente se multiplicaban por los mismos valores, produjeron que la desviación típica aproximaba mucho los datos a alguno de los grupos diferentes al propio, clasificándolos de forma errónea en un pequeño porcentaje, pero aún así presentaba cierto rango de confusión por lo que se decidió mantener el mismo clasificador pero cambiando las características al contenido de RGB debido a la alta separabilidad entre el verde y el rojo y al punto intermedio en el grano pintón para el contenido de las características del rojo (R) y Verde (G).

Finalmente aplicando las TED según (1), se obtuvieron mejoras considerables como las mostradas en las matrices de confusión (tablas 1 y 2). Se notó además una dependencia entre la cantidad de muestras de entrenamiento y las muestras de prueba.

3. CONCLUSIÓN

Los métodos observados en el entrenamiento permiten detectar cual es el clasificador que mejor se ajusta a los datos.

En la etapa de entrenamiento el clasificador que menos se ajusta a los datos es el de tipo árbol como se aprecia en la figura 5.

Es importante conocer la relación entre muestras de entrenamiento y de reconocimiento pues, según las tablas uno y dos, esta selección influye en los resultados de clasificación.

En la etapa de clasificación de las muestras de prueba se observó un rendimiento del 100% cuando se utiliza el 50% de muestras como entrenamiento y 50% de muestras de prueba aunque es posible emplear otras técnicas de validación menos sesgadas.

4. REFERENCIAS BIBLIOGRÁFICAS

- Geosciences, 32,1-16, 2006.
- [3] Nasibov. E., Kandemir, CC. "Efficiency analysis of KNN and minimum distance-based classifiers in enzyme family prediction, Computational Biology and Chemistry, In Press, Corrected Proof, 2009.
- [4] Park, Y., Sklansky, J, Automated design of linear tree classifiers, Pattern Recognition, 23, 1393-1412, 1990.
- [5] Chaves, J. M., Vega, M. A., Gómez, J., Sánchez, J. M., Detecting skin in face recognition systems: A colour spaces study, Digital Signal Processing, In Press, Corrected Proof, Available, 2009.
- [6] Chandra, D., Bibhas, C., Bhabatosh, Color image compression based on block truncation coding using pattern fitting principle, Pattern Recognition, 40, 2408-2417, 2007.
- [1] Hamamoto, Y., Fujimoto. Y., Tomita. S, On the estimation of a covariance matrix in designing Parzen classifiers, Pattern Recognition, 29, 1751-1759, 1996.
- [2] Porwal. A., Carranza, E.J.M., Hale. M. Bayesian network classifiers for mineral potential mapping, Computers &