

Eigen-Gradientes contra Histograma de Orientación de Gradientes para Reconocimiento de Señalamientos Viales de Límite de Velocidad

Sheila Esmeralda González Reyna

Universidad de Guanajuato, División de Ingenierías Campus Irapuato-Salamanca. Carretera Salamanca-Valle de Santiago km 3.5 + 1.8 km, Comunidad de Palo Blanco. CP 36885. Salamanca, Gto. México.
se.gonzalezreyna@ugto.mx

José de Jesús Guerrero Turrubiates

Universidad de Guanajuato, División de Ingenierías Campus Irapuato-Salamanca. Carretera Salamanca-Valle de Santiago km 3.5 + 1.8 km, Comunidad de Palo Blanco. CP 36885. Salamanca, Gto. México.
jjg.guerreroturrubiates@ugto.mx

Resumen

El reconocimiento automático de señalamientos viales tiene como principales aplicaciones el inventariado de carreteras, los sistemas de asistencia al conductor y la implementación de automóviles autónomos. El reconocimiento de señalamientos viales de límite de velocidad presenta su mayor importancia debido a que, gran parte de los accidentes carreteros con consecuencias mortales ocurren mientras se maneja a gran velocidad. El presente artículo tiene por objetivo realizar la clasificación de señales de tránsito de límite de velocidad, utilizando para ello dos distintos atributos: los mapas de orientación de gradientes y los histogramas de orientación de gradientes. Los resultados experimentales muestran que ambos atributos presentan eficiencias similares, utilizando diferente número de características.

Palabras Claves: histogramas de orientación de gradientes, mapas de orientación de gradientes, reconocimiento de señalamientos viales.

1. Introducción

Las señales de tránsito pretenden informar a los conductores acerca de las condiciones y los posibles riesgos presentes en su camino. Están diseñadas para ser fácilmente identificadas por las personas, ya que todas ellas tienen formas geométricas que difícilmente se encuentran en paisajes naturales; y colores llamativos, que sobresalgan de las escenas de fondo.

El reconocimiento de señalamientos viales puede pensarse como un problema de dos etapas: detección y reconocimiento. La detección intenta encontrar todos los señalamientos inmersos en una escena, urbana o rural, con infinidad de paisajes de fondo diferentes. Por otro lado, el reconocimiento hace posible la identificación del tipo de señalamiento que ha sido encontrado en la etapa anterior. El presente artículo se enfocará solamente en la etapa del reconocimiento.

La tarea del reconocimiento de las señales de tránsito puede complicarse debido a factores ambientales de iluminación y condiciones climáticas. Además, el señalamiento vial podría presentar transformaciones geométricas como rotación y perspectiva. Debido a lo anterior, un factor importante en el diseño e implementación de un sistema de reconocimiento de señalamientos viales, yace en la correcta elección de las características, las cuales deben presentar cierta invariancia a transformaciones geométricas y condiciones de iluminación.

Los sistemas de reconocimiento de señalamientos viales se caracterizan por su implementación en dos etapas: generación de atributos (características) y clasificación [1]. Algunos sistemas de reconocimiento hacen uso de la información en escala de grises de la imagen para caracterizar los objetos [2]; otros por su parte utilizan descriptores de imágenes diseñados especialmente para identificar forma o textura [3,4].

Una vez generado el conjunto de características adecuado, el siguiente paso es la clasificación. Para esto, los algoritmos de reconocimiento de señalamientos viales se han servido de diversos clasificadores tales como SVM [2,4] y random forests [4], por nombrar algunos.

En este artículo se hace uso de dos conjuntos de características basados en gradientes para el reconocimiento de señalamientos viales de límite de velocidad. Ambos conjuntos son procesados mediante algoritmos de reducción de dimensionalidad y posteriormente son utilizados para la clasificación mediante un vecino más cercano. Los resultados experimentales muestran eficiencias de clasificación similares, sin embargo, uno de los conjuntos de datos está formado por un menor número de atributos, logrando con esto, un requerimiento de memoria menor.

El presente artículo se organiza como sigue. La Sección 2 presenta los atributos utilizados, así como los algoritmos de reducción de dimensionalidad. En la Sección 3 se presenta la configuración del experimento, así como los resultados obtenidos. Finalmente, la Sección 4 proporciona las conclusiones y da algunas ideas para trabajo futuro.

2. Sistema de Reconocimiento basado en Gradientes

Los conjuntos de características basados en gradientes tienen por objetivo describir un objeto en base a su forma. Uno de los aspectos más importantes de dichos conjuntos es su invariancia a los cambios en el color y la iluminación. Durante el presente proyecto se hizo uso de dos diferentes conjuntos de características basadas en gradientes: mapas de orientación de gradientes e histogramas de orientación de gradientes.

2.1 Mapas de Orientación de Gradientes

Para la obtención de los mapas de orientación de gradientes [5], basta con calcular los gradientes de una imagen I por medio de la convolución con las máscaras más simples $[-1,0,1]$ y $[-1,0,1]^T$, con lo cual se han de obtener las componentes horizontal $\partial I/\partial x$ y vertical $\partial I/\partial y$ del gradiente en cada pixel. Posteriormente, se calcula la orientación por medio de la ecuación siguiente,

$$\theta = \arctan\left(\frac{|\partial I/\partial y|}{\partial I/\partial x}\right) \quad (1)$$

donde el valor absoluto asegura que θ estará dentro del rango $[0, \pi]$. La información contenida en el mapa de orientación de gradientes representa la dirección en la cual se registra un cambio de intensidad para cada pixel, y ésta es una medida invariante a las condiciones de iluminación.

2.2 Histogramas de Orientación de Gradientes

Dalal y Triggs propusieron en 2005 [6] la generación de histogramas de orientación de gradientes (HOG) como descriptores de imágenes, y los utilizaron para la detección de personas. Este popular conjunto de características ha sido utilizado para diferentes tareas de detección y reconocimiento de dígitos, y también de señalamientos viales. El método realiza el cálculo de los gradientes de la imagen; después divide la imagen en celdas cuadradas y posteriormente agrupa las celdas en bloques, los cuales pueden tener traslape. Dentro de las celdas se calcula un histograma de la orientación de los gradientes. Para cada vector de gradiente, su contribución al histograma está dada por la magnitud del vector, de manera que los gradientes de mayor magnitud tendrán un mayor impacto sobre el histograma; dicha contribución es además dividida entre los dos bins adyacentes. Finalmente, cuando las celdas son agrupadas dentro de un mismo bloque, todos los histogramas que se encuentran dentro del mismo son primero normalizados y después concatenados, formando así el descriptor de HOG.

2.3 Algoritmos de reducción de dimensionalidad

Cuando se pretende clasificar un conjunto de datos con muy alta dimensionalidad, la tarea de comparación puede demorar varias horas o incluso días. Además, muchas de las características pueden o no aportar mayor información al clasificador, y en algunas

ocasiones pueden afectar la decisión final del mismo. Los algoritmos de reducción de dimensionalidad tienen como finalidad, la simplificación de la información, de manera que para el clasificador sea posible realizar su trabajo con mayor precisión.

Existen en la literatura muchos algoritmos para reducción de dimensiones de un conjunto de características. En este proyecto se utilizaron dos de los algoritmos más conocidos: Análisis de Componentes Principales (PCA) [7] y Análisis del Discriminante Lineal (LDA) [8]. Estos algoritmos fueron escogidos debido a la simplicidad en su implementación, y a que presentan altas eficiencias para su aplicación en reconocimiento de patrones.

3. Resultados experimentales

En esta sección se describen los parámetros utilizados durante el desarrollo del experimento, así como los resultados obtenidos.

3.1 Base de datos

En 2011 se dio a conocer la German Traffic Sign Recognition Benchmark (GTSRB) [3]. La GTSRB consta de señalamientos viales de 43 clases diferentes y está dividida en conjuntos de entrenamiento y validación. El conjunto de entrenamiento está conformado por 39,209 imágenes, mientras que el de validación cuenta con 12,430.

Las imágenes utilizadas para el reconocimiento de señales de tránsito de límite de velocidad pertenecen al conjunto de datos de la GTSRB, la cual cuenta con 9 distintos tipos de señalamientos de velocidad (Fig. 1). Para este subconjunto de la GTSRB se tienen 13,200 imágenes para el conjunto de entrenamiento y 4,320 para el conjunto de validación. Todas las imágenes presentan fuertes variaciones en escala, rotación, perspectiva, iluminación y color.

Adicionalmente, la base de datos presenta desbalance. Una consecuencia del desbalance en los conjuntos de datos es que los clasificadores podrán presentar altas

eficiencias de clasificación en las clases mayoritarias (clases con mayor número de muestras) y eficiencias de clasificación pobres en las clases minoritarias (clases con menor número de muestras).



Fig. 1. Señalamientos viales de límite de velocidad contenidos en la GTSRB.

3.2 Generación del conjunto de datos

Como ya se mencionó, se generaron dos distintos conjuntos de características: mapas de orientación de gradientes (MOG) [5] e histogramas de orientación de gradientes (HOG) [6]. Para los mapas de orientación de gradientes se utilizaron las mismas condiciones que en [5]; con un tamaño de 28x28 píxeles, generando así 784 características por imagen.

Para el cómputo de las características HOG se utilizó un tamaño de imagen de 40x40 píxeles, celdas de 5x5 píxeles y bloques de 10x10 píxeles, de acuerdo a [3]. El resultado es un conjunto de 1,568 atributos por imagen.

Ambos conjuntos de características fueron transformados por dos algoritmos de reducción de dimensionalidad: PCA y LDA. Como regla general, se conoce que LDA produce un espacio de características con $N - 1$ atributos, siendo N el número de clases.

Cuando se aplica PCA por otro lado, es necesario analizar el número final de atributos a ser conservados. Se decidió estandarizar este número de manera que se conservara el 90% de la información para cada conjunto de datos, quedando de este modo 335 atributos para el mapa de orientación de gradientes y 147 para HOG.

Una vez obtenidos los cuatro conjuntos de características, se procedió con la clasificación. Las pruebas se realizaron clasificando mediante un vecino más cercano, la implementación proporcionada por WEKA [9].

La Tabla 1 muestra las eficiencias de clasificación por clase, obtenidas para cada uno de los conjuntos generados, así como también la eficiencia promedio por cada conjunto de datos y el número de muestras por clase. Como era de esperarse, la clase minoritaria 1 presenta las más bajas eficiencias de clasificación, ya que las muestras que conforman el conjunto de entrenamiento, no son las suficientes para hacer una correcta identificación de este señalamiento. Por otra parte, se observa que la clase minoritaria 7 presenta eficiencias de clasificación relativamente altas para todos los conjuntos, lo cual puede indicar que las muestras, aunque pocas, son lo suficientemente variadas para describir este señalamiento.

Clase	MOG+PCA	MOG+LDA	HOG+PCA	HOG+LDA	Muestras
1	0.483	0.75	0.817	0.483	210
2	0.564	0.807	0.871	0.576	2,220
3	0.829	0.937	0.892	0.544	2,250
4	0.331	0.791	0.796	0.409	1,410
5	0.405	0.842	0.917	0.852	1,980
6	0.465	0.811	0.868	0.384	1,860
7	0.733	0.787	0.853	0.707	420
8	0.447	0.776	0.856	0.562	1,440
9	0.496	0.744	0.816	0.453	1,410

Promedio	0.532	0.823	0.865	0.556	13,200
-----------------	--------------	--------------	--------------	--------------	---------------

Tabla 1. Eficiencias de clasificación para los señalamientos viales de límite de velocidad.

Finalmente, puede observarse que los mejores resultados globales fueron obtenidos para el conjunto MOG+LDA y HOG+PCA, con diferencias de 4.2% en sus eficiencias globales. Sin embargo, el conjunto MOG+LDA cuenta con solamente 8 características, mientras que el HOG+PCA está formado por 147.

4. Conclusiones

Los sistemas de reconocimiento automático de señalamientos viales han resultado ser útiles para aplicaciones de inventariado de carreteras y caminos, y para sistemas de asistencia al conductor. Para su implementación, dichos sistemas deben operar de forma eficiente y con requerimientos de memoria mínimos.

El presente artículo presentó la evaluación de dos distintos conjuntos de datos aplicados al reconocimiento de señalamientos viales de límite de velocidad, ambos basados en la información de orientación de gradientes. Los mapas de orientación de gradientes son simples en su cálculo, y presentan invariancia a los cambios en la coloración e iluminación. Los histogramas de orientación de gradientes por su parte, también presentan invariancia al color e iluminación, pero resultan en conjuntos de datos con mayor número de atributos.

Se aplicó un proceso de reducción de dimensionalidad a ambos conjuntos, ya sea por medio de PCA o de LDA, resultando así en cuatro conjuntos de entrenamiento y de validación. Las pruebas experimentales indican que en algunos casos el algoritmo del PCA produce resultados mejores que el LDA, pero siempre, con mayor número de atributos finales.

Las pruebas de clasificación realizadas sobre conjuntos de entrenamiento desbalanceadas pueden conducir a resultados bajos sobre las clases minoritarias, y altos sobre las mayoritarias. Sin embargo, se concluye que esto depende altamente de variabilidad en la información contenida en el conjunto de entrenamiento de cada clase.

Como trabajo a futuro, se pretende la combinación de descriptores para lograr así mayores eficiencias de clasificación en cada una de las clases. De la misma manera, se pretende explorar alguna técnica que sobrelleve el problema del desbalance, tal como un clasificador con ponderación, o algoritmos de balance.

5. Referencias

- [1] M.-Y. Fu y Y.-S. Huang. "A survey of traffic sign recognition". In *Wavelet Analysis and Pattern Recognition (ICWAPR)*, 2010 International Conference on. pp. 119-124, 2010.
- [2] S. Maldonado-Bascon, J. Acevedo-Rodriguez, S. Lafuente-Arroyo, A. Fernandez-Caballero, y F. Lopez-Ferrer. "An optimization on pictogram identification for the road-sign recognition task using SVMs". *Computer Vision and Image Understanding*. Vol. 114, No. 3. pp. 373-383. 2010.
- [3] J. Stallkamp, M. Schlipsing, J. Salmen, y C. Igel. "Man vs. computer: Benchmarking machine learning algorithms for traffic sign recognition". *Neural Networks*. 2012.
- [4] F. Zaklouta y B. Stanculescu. "Real-time traffic sign recognition in three stages". *Robotics and Autonomous Systems*. Vol. 62, No. 1. pp. 16-24. 2014.
- [5] S.E. Gonzalez-Reyna, J.G. Avina-Cervantes, y S.E. Ledesma-Orozco. "Eigen-gradients for traffic sign recognition". *Mathematical Problems in Engineering*. Vol. 2013. 2013.

- [6] N. Dalal y B. Triggs. "Histograms of oriented gradients for human detection". In *Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on*. Vol. 1, 2005, pp. 886-893.
- [7] H. Abdi y L. J. Williams. "Principal Component Analysis". *Wiley Interdisciplinary Reviews: Computational Statistics*. Vol. 2, No. 4. pp. 433-459. 2010.
- [8] C. Croux, P. Filzmoser, y K. Joossens. "Robust linear discriminant analysis for multiple groups: influence and classification efficiencies". Disponible en <http://ssrn.com/abstract=876896> o <http://dx.doi.org/10.2139/ssrn.876896>. 2005.
- [9] M. Hall, E. Frank, G. Holmes, B. Pfahringer, P. Reutemann, y I.H. Witten. "The WEKA data mining software: An update". *SIGKDD Explor. Newsl.* Vol. 11. pp. 10-18. 2009.

6. Autores

M.I. Sheila Esmeralda González Reyna recibió su título de Maestría en Ingeniería Eléctrica con especialidad en robótica móvil e inteligencia artificial en 2011, en la División de Ingenierías Campus Irapuato-Salamanca, Universidad de Guanajuato. Actualmente es estudiante de Doctorado en Ingeniería Eléctrica, con especialidad en visión por computadora y reconocimiento de patrones en la misma Universidad.

M.I. José de Jesús Guerrero Turrubiates recibió su título de Maestría en Ingeniería Eléctrica con especialidad en procesamiento digital de señales en 2013, en la División de Ingeniería Campus Irapuato-Salamanca, Universidad de Guanajuato. Actualmente es estudiante de Doctorado en Ingeniería Eléctrica, con especialidad en procesamiento digital de señales, en la misma Universidad.