

ELIMINACIÓN DE RUIDO IMPULSIVO EN IMÁGENES MEDIANTE EL USO DE MÁQUINAS DE VECTORES SOPORTE

Hilario Gómez Moreno, Saturnino Maldonado Bascón, Manuel Utrilla Manso, Pilar Martín Martín

Departamento de Teoría de la Señal y Comunicaciones
Universidad de Alcalá
hilario.gomez@uah.es

RESUMEN

En este trabajo se presenta una manera eficiente de suprimir el ruido impulsivo que pueda estar presente en las imágenes mediante el uso de Máquinas de Vectores Soporte (SVM). La eliminación del ruido impulsivo es un problema clásico del procesado no lineal, procesado en el que están demostrándose especialmente útiles las SVM. En este trabajo se utiliza tanto la clasificación como la regresión basadas en SVM. Mediante el clasificador seleccionamos los píxeles de la imagen que son ruidosos y mediante la regresión obtenemos un valor de reconstrucción de dicho píxel usando los píxeles que le rodean. Los resultados obtenidos son comparables y muchas veces mejores que los de otras técnicas ya publicadas y reconocidas. Además esta nueva técnica se puede aplicar con éxito a imágenes con altas tasas de ruido manteniendo tanto la calidad visual como el bajo error de reconstrucción.

1. INTRODUCCIÓN

Algunas veces las imágenes que recibimos tienen añadido un ruido impulsivo. Este ruido impulsivo puede ser debido a un canal de transmisión ruidoso o a imperfecciones del sensor con el que obtenemos las imágenes de manera que en algunos puntos se produce una saturación. Las técnicas lineales se muestran poco eficaces en la reducción de este tipo de ruido y como alternativa aparecen técnicas no lineales. El método no lineal más conocido es el del filtrado de mediana. La principal desventaja de este método es que se aplica sobre todos los puntos de la imagen independientemente de si son ruidosos o no, produciendo un emborronado especialmente acusado con altas tasas de ruido. Este defecto es común a otras técnicas dedicadas a la eliminación de ruido impulsivo. En [1] se presenta una técnica en la que sólo se realiza sustitución en los píxeles considerados ruidosos y la detección de dichos píxeles ruidosos es implementada mediante la comparación con unos determinados umbrales. Los píxeles ruidosos son reemplazados mediante un filtro de mediana modificado, que en ese trabajo es llamado "Rank ordered mean" (ROM) y que no utiliza el píxel ruidoso para calcular la mediana. En este trabajo, realizamos un esquema similar pero tanto la detección de como la sustitución de píxeles ruidosos las realizamos con SVM.

Nuestro método proporciona excelentes resultados tanto en "Peak Signal to Noise Ratio" (PSNR), que mide el error de reconstrucción, como en calidad visual y mantenimiento de los bordes incluso para muy altas tasas de ruido.

2. CLASIFICACIÓN Y REGRESIÓN CON SVM

Los problemas de clasificación y regresión son algunos de los típicos que se han abordado desde el punto de vista de los métodos de aprendizaje. El aprendizaje ha de producirse a partir de ejemplos del proceso que queremos conocer. De estos métodos nosotros usamos el llamado Máquinas de Vectores Soporte cuyos principios fueron propuestos por Vapnik [2]. Las SVM explotan el principio de "Minimización del riesgo estructural" (SRM) que se contraponen al clásico de "Minimización del riesgo empírico" (ERM). Mientras que en el ERM se aprende mediante la minimización del error de entrenamiento, en el SRM se trata de minimizar el posible error que se cometerá al clasificar nuevas muestras del proceso. Con el ERM intentamos obtener una función que clasifique adecuadamente la mayoría de datos de entrenamiento, mientras que con el SRM buscamos una frontera de decisión que esté lo más alejada posible de los dos conjuntos a separar. De esta manera un punto nuevo que debamos clasificar tiene una alta probabilidad de ser correctamente clasificado.



Figura 1. Ejemplo de imágenes de entrenamiento.

En el problema de clasificación tenemos unos vectores divididos en dos conjuntos y debemos encontrar una función de decisión que los separe. Según el SRM, la función de decisión será la que maximice la distancia desde los datos hasta la frontera. En el caso de datos linealmente separables la función tiene la siguiente forma,

$$f(\mathbf{x}) = \sum_{i=1}^l \alpha_i y_i \langle \mathbf{x}_i \cdot \mathbf{x} \rangle + b \quad (1)$$

Los valores de y son $+1$ para vectores clasificados en una categoría y -1 para la otra. En (1) sólo aparecen los puntos de entrenamiento y unos valores α que definen el hiperplano óptimo de separación. El número de vectores l no coincide normalmente con el de entrenamiento, sólo algunos de esos vectores influyen en la función de decisión y son conocidos como "Vectores Soporte" el resto que no influyen tienen α nulos.




Figura 2. Ejemplos de reducción de ruido. (a) Imagen ruidosa 20 % (b) Imagen reconstruida. PSNR = 36.76 dB (c) Detalle con 40% de ruido (d) Imagen reconstruida PSNR = 30.50 dB

Si los datos no son linealmente separables, la expresión (1) se modifica de la forma presentada en (2),

$$f(\mathbf{x}) = \sum_{i=1}^l \alpha_i y_i K(\mathbf{x}_i \cdot \mathbf{x}) + b \quad (2)$$

En (2), K representa una función no lineal que transforma los puntos del espacio original a otro donde sí son linealmente separables. En ese nuevo espacio es donde se calcula la frontera de decisión para luego retornar al espacio original. La elección de la función K es crucial para el funcionamiento de la clasificación. La usada en nuestro trabajo es conocida como función de base radial y tiene por expresión,

$$K(x, y) = \exp\left(-\gamma(x - y)^2\right) \quad (3)$$

Tanto el parámetro γ en (3) como un parámetro, que llamaremos C , de penalización de los vectores mal clasificados se deben fijar de forma empírica para conseguir los mejores resultados. El significado de dichos parámetros es tratado en [2].

El proceso de regresión es similar al de clasificación, pero en este caso los valores de y son reales y representan los valores de la función conocidos sobre los que hacemos la regresión.

El tipo de ruido sobre el que vamos a trabajar es conocido como "salt&pepper" (sal y pimienta). En este tipo de ruido los píxeles ruidosos toman valores 0 ó 255 con igual probabilidad.

Evidentemente, no podemos usar todos los píxeles de la imagen a la vez, hemos de extraer la información de alguna manera. Lo que hacemos es formar un vector para cada píxel formado por él mismo y por los que tiene alrededor en una ventana de 3x3 (excepto para los bordes). En el entrenamiento a cada uno de estos vectores le asignamos un +1 cuando hay ruido y un -1 cuando no. Si queremos aplicarlo a las imágenes reales, esos vectores serán la entrada para la función de decisión (2).

En las imágenes de entrenamiento (Figura 1) debemos controlar su porcentaje de ruido y su tamaño. Las de la figura tienen un tamaño de 32x64 y un porcentaje de ruido del 30%.

La detección de píxeles ruidosos se hace por partes. Primero detectamos los píxeles negros y los convertimos en blancos. Después buscamos los blancos y los sustituimos. Esta es la mejor opción, puesto que tanto la detección de píxeles blancos y negros a la vez como su regresión es problemática dada la disparidad de valores. Evidentemente la detección de píxeles negros se realiza después de haber entrenado con imágenes con las de la figura 1 pero con píxeles de ruido negros.

En el proceso de regresión también utilizamos imágenes sintéticas como las de la figura 1, pero en este caso lo que

hacemos es formar un vector alrededor de cada píxel y poner como valor de regresión el de la imagen original que ocupa la misma posición. En este caso excluimos el píxel central puesto que lo consideramos como ruidoso.

3. RESULTADOS

Los resultados presentados han sido obtenidos usando la librería LIBSVM [3] escrita en C++. Las imágenes utilizadas para las pruebas son de 512x512 con una escala de grises de 8 bits.

En la figura 2 se muestran dos ejemplos de reducción de ruido. En el primer ejemplo usamos la imagen "Lena" con una tasa de ruido del 20%. Visualmente podemos comprobar el alto grado de calidad de reconstrucción y además el PSNR obtenido es de 36.76 dB. En comparación, el método propuesto en [1] obtiene un PSNR de 35.70 dB para la misma imagen. La imagen de la figura 2-c muestra un detalle de "Lena" con una tasa de ruido del 40% y la figura 2-d ese mismo detalle reconstruido. Podemos comprobar que aparece un ligero emborronado debido a la alta tasa de ruido pero que la imagen es totalmente reconstruida obteniéndose un PSNR de 30.50 dB.

4. CONCLUSIONES

En este trabajo se muestra un nuevo método de reducción de ruido impulsivo que es muy eficiente incluso para muy altas tasas de ruido y que es incluso superior que otras técnicas consideradas como estándar. Esta técnica está basada en el uso de máquinas de vectores soporte tanto para la detección de los píxeles que son ruidosos como para la obtención de los valores de reconstrucción de dichos píxeles. Con este trabajo se amplía el abanico de aplicaciones de esta nueva técnica de aprendizaje y además se demuestra que puede ser usada con éxito en el procesado de imagen, puesto que los resultados obtenidos son muy buenos.

5. REFERENCIAS

- [1] Abreu, E., Lightstone, M., Mitra, S.K., Arakawa, K. "A new Efficient Approach for the Removal of Impulse Noise from Highly Corrupted Images", IEEE Trans. on Image Processing, 5(6):1012-1025,1996.
- [2] Vapnik, V. *The Nature of Statistical Learning Theory*, Springer-Verlag, New York, 2000.
- [3] Chang, C., Lin, C. "Libsvm: Introduction and benchmarks". 2000. <http://www.csie.ntu.edu.tw/~cjlin/libsvm>.