

Reconocimiento de Patrones y Generación de Características con Restricciones Temporales

Javier Giacomantone, Lucía Violini, Luciano Lorenti, Marcelo Naiouf,
Oscar Bria, María José Abásolo

Instituto de Investigación en Informática LIDI (III-LIDI)
Facultad de Informática – UNLP

{jog, lviolini, llorenti, mnaiouf, obria, mjabasolo, frapiva}@lidi.info.unlp.edu.ar

CONTEXTO

Esta línea de investigación y desarrollo (I/D) forma parte del proyecto “Cómputo Paralelo de Altas Prestaciones (HPC). Fundamentos y Evaluación de Rendimiento en HPC. Aplicaciones a Sistemas Inteligentes, Simulación y Tratamiento de Imágenes”, del Instituto de Investigación en Informática LIDI acreditado por la UNLP en el marco del Programa de Incentivos.

RESUMEN

Este trabajo describe una línea de I/D y los resultados esperados de la misma. El objetivo principal es estudiar, investigar, desarrollar y evaluar métodos computacionales en aprendizaje automático y reconocimiento estadístico de patrones, en particular clasificación supervisada, no supervisada, reducción de dimensión y análisis de rendimiento. El segundo objetivo general es investigar métodos de generación de características a partir de señales en general e imágenes digitales en particular, desde el punto de vista del método de clasificación subyacente, su poder de discriminación y su posible aplicación en tiempo real.

Palabras Clave: Reconocimiento de Patrones. Análisis de Imágenes. Aprendizaje Automático. Generación de Características. Tiempo Real.

1. INTRODUCCION

El objetivo principal de un sistema de reconocimiento automático de patrones es descubrir la naturaleza subyacente de un fenómeno u objeto, describiendo y seleccionando las características fundamentales que permitan clasificarlos en una categoría determinada [1][2]. Sistemas automáticos de reconocimiento de patrones permiten abordar problemas en informática, en ingeniería y en otras disciplinas científicas [3][4], por lo tanto el diseño de cada etapa requiere de criterios de análisis conjuntos [5] para validar los resultados [6][7]. El espectro de aplicaciones de los sistemas de reconocimiento automático de patrones es muy amplio. Entre las principales áreas de aplicación podemos mencionar: reconocimiento de voz, escritura, iris, y huellas digitales. También se puede mencionar el creciente número de aplicaciones en biología y medicina como: reconocimiento de secuencias ADN, mamografías, electrocardiogramas y electroencefalogramas. En general todo tipo de fenómeno físico o químico del cual podamos directa o indirectamente extraer descriptores viables, es potencialmente tratable por un sistema automático de reconocimiento de patrones. Es de particular interés en esta línea de I/D la generación de características a partir de señales en general e imágenes en particular. En general se analizan problemas en cada una de las tres eta-

pas en que un modelo general clásico de un sistema automático puede ser dividido para su diseño y estudio, sensor, selector de características y clasificador. La primera etapa puede ser considerada a su vez como la que trata de obtener la representación más fiel del fenómeno estudiado, y como un módulo que permite generar características del mismo. La etapa de selección de características permite simplificar la etapa de clasificación al generar un vector de entrada con mayor potencial de discriminación entre clases y menor redundancia de información. La etapa de clasificación finalmente asigna un patrón a la clase correspondiente minimizando la probabilidad de error del sistema.

1.1 Reconocimiento de Patrones

En esta línea de investigación el trabajo actual lo podemos clasificar en tres tópicos bien diferenciados correspondientes a tres sub-disciplinas dentro del área. La primera es clasificación supervisada donde el énfasis de nuestro trabajo es en métodos de clasificación basados en núcleos dispersos, en particular máquinas de soporte vectorial. La segunda es en clasificación no supervisada donde la principal línea de trabajo son las técnicas de agrupamiento basadas en teoría espectral de grafos y su aplicación a imágenes de rango. El tercer tópico de fundamental importancia es el de reducción de dimensión en particular selección de características. Las máquinas de soporte vectorial (SVM) [8] son herramientas fundamentales en sistemas de aprendizaje automático, permitiendo el tratamiento de problemas actuales en reconocimiento de patrones y minería de datos tales como, reconocimiento y caracterización de texto manuscrito, detección ultrasónica de fallas en materiales, clasificación de imágenes médicas [9], sistemas biométricos [10], clasificación en bioinformática [11] y en física de altas energías [12]. Las SVM implementan reglas de decisión complejas, por medio de una función no lineal que permite mapear los puntos de entrenamiento a un espacio de mayor

dimensión. En el nuevo espacio de características las clases son separadas por un hiperplano, siendo este el que maximiza la distancia entre el mismo y los puntos de entrenamiento. La distancia se denomina margen y esos vectores son los vectores de soporte. Las SVM cumplen un rol muy importante en teoría de aprendizaje estadístico y cuando es necesario entrenar un clasificador no lineal en un espacio de características de considerable dimensión con un número limitado de muestras. Podemos diferenciar dos aspectos importantes que en general reciben la denominación de máquinas de soporte vectorial, el uso de SVM en clasificación SVC y el uso de las mismas en regresión SVR. La línea de investigación propuesta estudia ambos aspectos y en particular en el caso de clasificación mediante SVM tiene como objetivo diseñar sistemas con alta capacidad de generalización. Entre las tendencias actuales podemos mencionar las investigaciones sobre SVM paralelas y secuenciales (PSVM, SSVM) [13]. Una serie temporal es una secuencia de puntos medidos a intervalos sucesivos, normalmente de tiempo, y en general a intervalos regulares. Las series temporales son el resultado de medidas de distintos fenómenos físicos en la naturaleza pero también son comunes en econometría, marketing, control industrial y como resultado de métodos de monitoreo y diagnóstico en medicina. La clasificación de las series temporales obtenidas a partir de estudios funcionales del cerebro, son un ejemplo de abordaje multidisciplinario, donde uno de sus aspectos fundamentales es el de reconocimiento de patrones. La aplicación, adaptación y adecuada selección de kernels de SVM a series temporales es un tema de investigación actual [14][15]. Las series pueden ser unidimensionales o multidimensionales con correlación tanto temporal como espacial. En el último caso se plantea un problema de reconocimiento de patrones. Entre los temas actuales de investigación que involucran los conceptos anteriores podemos citar estudios en neurociencias por medio de resonancia magnética funcional (fMRI), electroencefa-

logramas (EEGs) y magnetoencefalogramas (MEGs) [16][17].

Los métodos espectrales de agrupamiento explotan la estructura de autovalores de la matriz de semejanza u otras matrices derivadas, generando una partición en agrupamientos disjuntos. El primer paso en la construcción de un algoritmo de clustering basado en teoría espectral de grafos es definir la matriz de similitud basada en los pesos de las aristas entre nodos [18]. En segundo término se construye el laplaciano del grafo y luego se realiza el correspondiente análisis de autovalores y autovectores [19]. En esta línea de I/D se investigan tres aspectos fundamentales, la construcción de la matriz de semejanza, el análisis de métodos de segmentación [20][30] y el estudio de alternativas para reducir la complejidad computacional para casos particulares [21]. El tercer tema central de la línea de I/D descrita en este artículo es el de reducción de dimensión, asociado directamente con problemas que presentan alta dimensión en sus patrones con respecto al número de muestras en el conjunto de diseño y los problemas en el que el número de parámetros es relativamente alto con respecto al número de patrones disponibles para el diseño del sistema de clasificación. Se consideran dos abordajes para resolver el problema de reducción de dimensión, extracción de características y selección de características. Se estudian dos tipos de problemas supervisados y no supervisados, y transformaciones lineales y no lineales del espacio de características [22][31].

1.2 Generación de Características

Un patrón es una entidad que podemos describir mediante un conjunto de características. Esta línea de investigación estudia no solo la adquisición directa del conjunto de características denominado descriptor sino los métodos de generación de características indirectos obtenidos a partir del análisis de distinto tipo de señales. El segundo objetivo es caracterizar la calidad de los mismos

mediante cinco parámetros principales: unicidad, congruencia, invariancia, abstracción y sensibilidad. La naturaleza de las imágenes digitales analizadas es amplia desde imágenes naturales obtenidas por reflexión o transmisión, imágenes multi-espectrales, imágenes de resonancia magnética o resonancia magnética funcional [23] como también imágenes de rango obtenidas mediante cámaras de tiempo de vuelo [24][25]. A pesar de trabajar en esta línea de investigación con imágenes generadas por distintos fenómenos y que representan problemas diferentes podemos identificar una metodología común. Es necesario segmentar la imagen, dividirla en sus partes constitutivas u objetos que la componen donde el nivel de segmentación depende del problema analizado. Una vez determinados los elementos de la imagen que componen los objetos de interés y el fondo es posible investigar que método, o proponer un nuevo método que permita obtener un descriptor [26][27]. En el caso de imágenes digitales podemos clasificarlos en externos, internos y mixtos según sean generados a partir de la frontera, la región del objeto de interés o ambas. El tipo de información que se utiliza es muy dependiente del problema abordado. Los principales métodos utilizados tienen en cuenta características como el color, la textura, el espectro de frecuencias, propiedades geométricas y análisis en distintas escalas. Se investigan métodos de generación de características que además de mejorar el rendimiento con respecto a los parámetros anteriores puedan también satisfacer restricciones temporales [28] para problemas específicos, como interfaces hombre-máquina no convencionales [29].

2. LINEAS DE INVESTIGACION y DESARROLLO

- Clasificación supervisada. Discriminadores lineales y no lineales.
- Métodos de estimación de parámetros para clasificadores Bayesianos.
- Clasificación no supervisada. Técnicas de agrupamiento (clustering).

- Selección y extracción de características.
- Métricas, pseudométricas y distancias ultramétricas en clasificación supervisada, no supervisada y selección de características.
- Criterios de evaluación de desempeño en sistemas de clasificación automática.
- Criterios y algoritmos para combinación de clasificadores.
- Estudio de métodos para el tratamiento de datos en cámaras basadas en tiempo de vuelo.

- Máquinas de soporte vectorial. Kernels y algoritmos de optimización.
- Clasificación de series temporales y clasificación contextual.
- Generación de características para Interfaces Basadas en Visión

- Análisis de Señales Digitales

3. RESULTADOS OBTENIDOS /ESPERADOS

- Desarrollar modelos y optimizar algoritmos particulares de clasificación supervisada y no supervisada.
- Evaluación de los métodos de análisis de desempeño y su aplicación sobre los clasificadores y conjuntos de datos propuestos.
- Construcción de una mesa multi-táctil basada en visión por computador para su uso en educación especial [29].
- Se estudiaron y propusieron métodos para detección en series temporales de fMRI [23]
- Se realizó la evaluación de rendimiento en sistemas de reconocimiento de patrones supervisados y de clasificación binaria [16].
- Se propuso un método de segmentación de imágenes de rango [20][30].
- Obtener mejoras y adecuar las técnicas de selección y extracción para el tratamiento de datos en espacios multidimensionales [31].

4. FORMACION DE RECURSOS HUMANOS

En el marco de esta línea de investigación alumnos de grado y postgrado tienen la posibilidad de realizar tesinas y tesis en temas específicos. Actualmente hay dos investigadores realizando su doctorado y tres alumnos realizando tesinas relacionadas a aspectos particulares en sistemas automáticos de reconocimiento de patrones y análisis de imágenes.

6. BIBLIOGRAFIA

1. Batagelj V, Bock H, Ferligoj A. "Data Science and Classification". Springer, (2006).
2. Fukunaga K. "Introduction to Statistical Pattern Recognition". Second Edition. Academic Press, (1990).
3. Devijer P, Kittler, J. "Pattern Recognition: theory and applications". Springer, (1986).
4. Anke Meyer-Base. "Pattern Recognition for Medical Imaging". Academic Press, (2004).
5. Kim H.Y., Giacomantone J. O., Cho, Z. H. Robust Anisotropic Diffusion to Produce Enhanced Statistical Parametric Map, Computer Vision and Image Understanding, v.99, pp.435-452 (2005).
6. Kim H.Y., Giacomantone J. O., A New Technique to Obtain Clear Statistical Parametric Map by Applying Anisotropic Diffusion to fMRI, IEEE, International Conference on Image Processing. Proceedings, Genova, Italy, v.3, pp.724-727 (2005).
7. Cortes C, Vapnik V, Support vector networks. Machine Learning v.20, pp.273-297 (1995).
8. Vapnik, V. The Nature of Statistical Learning Theory. N. Y. Springer (1995)
9. Li S., Fevens L., Krzyzak A., Li S. Automatic Clinical Image Segmentation Using Pathological Modelling, PCA and SVM, MLDN, LNAI 3587 pp.314-324, (2005).
10. Lei Z., Yang Y., Wu Z.. Ensembles of Support Vector Machine for Text-Independent Speaker Recognition, IJCSNS v.6 n.5A pp. 163-167, (2006).

11. Boekhorst R., Abnizova I., Wernich L. Discrimination of regulatory DNA by SVM on the basis of over and under-represented motifs, ESANN pp. 481-486 (2008).
12. Vossen Anselm. Support Vector Machines in High Energy Physics, CERN, Geneva, Switzerland, pp.23-33 (2005).
13. Wang L., Chang M., Feng J.. Parallel and Sequential Support Vector Machines for Multi-label Classification, International Journal of Information Technology, v.11 n.9 pp. 11-18, (2005).
14. Rüping S., SVM kernels for time series analysis, G1-Workshop-Woche Lernen-Lehren-Wissen-Adaptivitet, pp.43-50 (2001).
15. Yang K., Shahabi C. A pca-based kernel for kernel pca on multivariate time series, IEEE Intern. Conf. on Data Mining (2005).
16. Giacomantone J., De Giusti A., ROC performance evaluation of RADSPM technique, XIV Congreso Argentino de Ciencias de la Computación (CACIC), Chilecito (2008).
17. Chaovalitwongse W., Pardalos P. On the Time Series Support Vector Machine using Dynamic Time Warping Kernel for Brain Activity Classification, Cybernetics and Systems Analysis v.44 pp.125-138 (2008).
18. Von Luxburg U. A Tutorial on Spectral Clustering. Statistics and Computing, 17(4), (2007).
19. Shi J., Malik J. Normalized cuts and image segmentation. IEEE Transactions on Pattern Analysis and Machine Intelligence 22(8), 888-905, (2000).
20. Lorenti L., Manresa-Yee C., Giacomantone J. Segmentación de objetos parcialmente ocluidos utilizando cámaras TOF. X Workshop Computación Gráfica, Imágenes y Visualización. pp. 387-395. Bahía Blanca, Buenos Aires, Argentina, Octubre, (2012).
21. Zare H., Shooshtari P., Grupta A., Brinkman R. Data reduction for spectral clustering to analyse high throughput flow cytometry data. Bioinformatics, 11-403, (2010)
22. Han Y., Feng X., Baciú G. Variational and PCA based natural image segmentation. Pattern Recognition 46, pp. 1971-1984 (2013).
23. Giacomantone J., Tarutina T. Diffuse Outlier Detection Technique for Functional Magnetic Resonance Imaging. Computer Science and Technology Series. XVI Argentine Congress of Computer Science Selected Papers. pp. 255-265 (2011).
24. Penne et al. Robust real time 3-D respiratory motion detection using time of flight cameras. International Journal of Computer Assisted Radiology and Surgery v.3 pp.427-431. (2008).
25. Kollors, A., Penne, J., Hornegger, J., Barker A. Gesture Recognition with a Time-of-Flight camera. International Journal of Intelligent Systems Technologies and Applications, v. pp.334-343, (2008).
26. Li J., Wang Y. Visual tracing and learning using speeded up robust features. Pattern Recognition Letters 33, pp. 2094-2101 (2012)
27. Prato M., Zanni L. A practical use of regularization for supervised learning with kernel methods. Pattern Recognition Letters 34, pp. 610-618 (2013).
28. Antunez E., Marfil R., Bandera A. Combining boundary and región features inside the combinatorial pyramid for topology preserving perceptual image segmentation. Pattern Recognition Letters 33, pp. 2245-2253 (2012).
29. Cristina Manresa-Yee, Ramón Mas, Gabriel Moyá, María J. Abásolo, Javier Giacomantone. Interactive multi-sensory environment to control stereotypy behaviours. Computer Science & Technology, pp. 121-128, (2012).
30. Lorenti L., Giacomantone J. Segmentación espectral de imágenes utilizando cámaras de tiempo de vuelo. XI Workshop Computación Gráfica, Imágenes y Visualización. pp. 430-439. Mar del Plata, Argentina, (2013).
31. Lorenti L., Violini L., Giacomantone J. Selección sub-óptima del espectro asociado a la matriz de afinidad. IV Workshop Procesamiento de Señales y Sistemas de Tiempo Real. pp. 1417-1425. Mar del Plata, Argentina, (2013).