

Modelos Conexionistas Auto-organizados y su Aplicación en Reconocimiento de Patrones

L. M. Seijas y E. C. Segura

Departamento de Computación, Facultad de Ciencias Exactas y Naturales,
Universidad de Buenos Aires, Ciudad Universitaria, P.B. Pab. I (1428) Buenos Aires
lseijas@dc.uba.ar – esegura@dc.uba.ar

Resumen

El trabajo en curso tiene por objeto desarrollar técnicas conexionistas para reconocimiento de patrones. A partir del sistema ya desarrollado por el grupo (que consiste básicamente en un modelo híbrido no supervisado -de tipo auto-organizado- seguido de una instancia supervisada) se estudia la introducción de innovaciones que incrementen su potencia y su eficiencia. Las investigaciones en curso giran alrededor de dos frentes: i) preprocesamiento de la entrada: se consideran opciones a la técnica inicialmente empleada (máscaras de Kirsch), entre ellas el uso de transformadas wavelet y la extracción de componentes principales; ii) estructura del módulo intermedio (no supervisado): analizamos posibles sofisticaciones orientadas a obtener una clasificación más especializada de acuerdo con las características de la distribución de los datos de entrada. La calidad y eficiencia de la propuesta resultante deberán ser luego comparadas con las de los métodos ya existentes.

1. Introducción

Las Redes Neuronales Artificiales son un paradigma de cómputo particularmente adecuado para el tratamiento de problemas de aproximación, identificación y reconocimiento en sistemas no lineales. En cuanto a reconocimiento de patrones, y de caracteres en particular, existe una vasta literatura basada en el uso de modelos conexionistas (cf. Sección 3).

Las aplicaciones son varias: procesamiento automático de correo, ingreso automático de datos para sistemas administrativos de gran envergadura, lectura de dispositivos para ciegos, identificación de patentes de automóviles en tiempo real, entre otras.

En nuestro grupo ya hemos desarrollado [21] un sistema neuronal híbrido, con una primera etapa no supervisada, basada en mapas auto-organizados, y una segunda donde se rotulan clases y que incluye un método probabilístico de (auto)evaluación de las respuestas. Esto confiere al método gran capacidad para explicar sus respuestas, además de su modularidad y paralelismo intrínseco. El modelo ya fue evaluado en reconocimiento de dígitos manuscritos sin restricciones, con resultados competitivos en relación con otras propuestas. El sistema realiza también un preprocesamiento de la información, con extracción de características basada en Máscaras de Kirsch.

Se intenta introducir mejoras al sistema propuesto, que aumenten al mismo tiempo su potencia (para resolver problemas de mayor complejidad) y su eficacia (en términos de la confiabilidad de las respuestas que provee). Investigamos potenciales extensiones en dos direcciones fundamentales: i) *Incorporación de otras técnicas de representación de la entrada*. El rendimiento de un sistema reconocedor de caracteres depende significativamente de las características definidas para representar cada patrón. El algoritmo propuesto en [21] utilizó originalmente detectores de bordes de Kirsch [18] como extractores de características direccionales, ya que permiten la detección localizada de segmentos de línea [15] [4]. Entre las opciones a considerar se incluyen:

- Transformadas wavelet: para extraer, de los patrones, características en multiresolución, ya que permiten obtener una interpretación invariante del carácter en distintas resoluciones. Los detalles de la imagen en diferentes niveles de resolución caracterizan diferentes estructuras físicas del patrón.
- Análisis de componentes principales (PCA) que, si bien provee un cambio de base de representación sin pérdida de información, permite jerarquizar la resolución con que se representa la entrada (en términos de la varianza total de las proyecciones sobre las componentes elegidas) pero no descompone la señal en características estructurales como lo hacen las wavelets.

El compromiso complejidad computacional / calidad del clasificador será evaluado para determinar la conveniencia de una u otra técnica de preprocesamiento de la entrada al sistema.

ii) *Modificaciones en la estructura del sistema de clasificación.* Actualmente analizamos la conveniencia de una estructura más sofisticada en el módulo intermedio no supervisado, de manera de obtener una clasificación más especializada de acuerdo a las características de la distribución de las entradas. De las experiencias realizadas surge que el principal obstáculo para el incremento de la eficiencia (en términos del porcentaje de respuestas correctas en la instancia de testeo) lo constituye una proporción minoritaria de elementos con una elevada dispersión respecto del valor medio de su clase. De aquí conjeturamos que una organización en sub-módulos permitiría procesar por separado los subconjuntos más representativos de cada clase, por un lado, y los menos representativos (más dispersos o “confusos”, como los denominamos por razones que se verán más adelante), por otro.

2. Metodología

Es bien conocida la poca confiabilidad de los métodos actuales para reconocimiento de patrones, a lo que se suma, en el caso de los de aprendizaje automático, el volumen de los conjuntos de entrenamiento necesarios para un aprendizaje satisfactorio. Proponemos explorar sistemas de reconocimiento que se valgan de técnicas eficientes para representar los datos de entrada y agruparlos en clases, enriqueciendo así la técnica propuesta por el grupo, que si bien es híbrida, se apoya fuertemente en modelos competitivos, a diferencia de las reportadas en la literatura, orientadas mayoritariamente hacia métodos supervisados (básicamente perceptrones multicapa).

Para evaluar las técnicas utilizamos la base de dígitos manuscritos de la Universidad de Concordia (Canadá), referente casi universal para comparar métodos de reconocimiento de caracteres y de patrones en general. También se planea adquirir y utilizar las bases del Laboratorio Electro-Técnico de Japón y la del Instituto de Investigaciones en Electrónica y Telecomunicaciones de Corea.

La implementación de las pruebas ha sido realizada utilizando programas desarrollados por el grupo en lenguaje C y algunas rutinas estadísticas de Matlab.

Evaluaremos y compararemos nuestros resultados con los métodos de la literatura, en términos de confiabilidad en la identificación y eficiencia en cuanto a costos computacionales.

3. Estado del arte

El Reconocimiento Óptico de Caracteres es uno de los tópicos más antiguos dentro del Reconocimiento de Patrones e incluye como problema esencial el reconocimiento de caracteres manuscritos. Una de las principales dificultades en el reconocimiento radica en que la varianza intraclase es grande, debido a las diferentes formas asociadas a un mismo patrón, generadas por el estilo particular de escritura de cada individuo. No existe ningún modelo matemático que pueda describir tales variaciones de formas [22]. Numerosas investigaciones y modelos se han presentado para este problema, pero ninguno ha logrado obtener un nivel de respuesta similar al humano.

La utilización de redes neuronales ha permitido obtener muy buenos resultados en reconocimiento de caracteres manuscritos. La mayoría de los trabajos publicados utilizan los métodos clásicos de reconocimiento, como las redes feed-forward (perceptrón) multicapa entrenadas con backpropagation. Esta arquitectura ha sido reconocida como una herramienta poderosa para la clasificación de patrones, dado su poder discriminativo y su capacidad de aprender y representar conocimiento implícito. Pero a la hora de resolver problemas reales este modelo presenta dificultades, como determinar el tamaño y la estructura de red apropiados para aproximar límites de decisión complejos y contrarrestar la pobre generalización causada por la alta dimensión de la entrada [1] [19]. Otra dificultad es la velocidad de convergencia y la existencia de mínimos locales cuando se utiliza la técnica de descenso por gradiente para ajustar los pesos [13] [15].

Es posible obtener resultados altamente competitivos en el reconocimiento de caracteres manuscritos, utilizando técnicas de aprendizaje no supervisado como los mapas auto-organizados de Kohonen [10][11], aun combinados con otras técnicas [3]. También se han propuesto métodos basados en aprendizaje no supervisado y en la estructura adaptativa de las redes [12] [20] [6] [4].

Otra de las cuestiones a tener en cuenta a la hora de diseñar una arquitectura de red, es definir si la extracción de características de los patrones de entrada se realizará en una etapa previa al aprendizaje (preprocesamiento), o se incluirá como una función propia de la red. En este último caso la arquitectura de red resulta más compleja y especializada, como puede verse en [7] [14] [8], mientras que en el primer caso el diseño es más sencillo y general [15] [16] [4].

El rendimiento de un sistema reconocedor de caracteres depende altamente de las características definidas para representar cada patrón. Los detectores de bordes de Kirsch [18] han sido utilizados como extractores de características direccionales para caracteres manuscritos [15] [4], ya que permiten la detección localizada de segmentos de línea. Existen también aplicaciones de transformadas Wavelet, aprovechando el hecho de que los detalles de la imagen en diferentes niveles de resolución caracterizan diferentes estructuras físicas del carácter [22] [16] [9] [5] [2]. Asimismo, se ha explorado la conveniencia de un cambio de base de representación mediante PCA [17][23] que permite, sin pérdida de información, jerarquizar la resolución con que se representa la entrada (en términos de la varianza de las proyecciones sobre las componentes) pero no descompone la señal en características estructurales como lo hacen las wavelets.

4. Descripción del proyecto en curso

El trabajo en desarrollo se basa en el modelo propuesto por el grupo [21], cuyo diseño se observa en la figura 1. El reconocedor está compuesto por dos niveles. El primero está conformado por un conjunto de mapas auto-organizados de Kohonen bidimensionales e independientes, cada uno dedicado a una característica direccional diferente, extraída del patrón de entrada utilizando las máscaras de Kirsch. El segundo nivel consiste en un módulo analizador encargado de definir y explicar la salida del sistema, e integrado por los siguientes elementos: la *tabla de confiabilidad*, y dos parámetros ajustables durante la utilización del sistema. Cada red Kohonen de la primera capa, emite una respuesta frente a un patrón ingresado, como si fuera un juez que, basándose solamente en el análisis de la característica que le corresponde, decide a qué clase pertenece el patrón. La conexión entre la primera y la segunda capa del sistema se realiza a través de esta nueva representación del patrón, constituida por las respuestas o votos de los "jueces". La función de la tabla de confiabilidad es reflejar cuán confiable es la respuesta dada por cada mapa Kohonen. Utilizando estos elementos, el módulo analizador de la segunda capa deberá producir la respuesta final. El sistema puede explicar las respuestas dadas, indicando a qué clase se pareció más el patrón de entrada para cada característica, a través de la observación de los votos de cada red/juez, y el peso asignado a cada uno. Como parte de la explicación, si un patrón es confuso para el sistema, podremos saber con qué otros dígitos podría confundirse (i.e. con qué clases comparte la mayor cantidad de características).

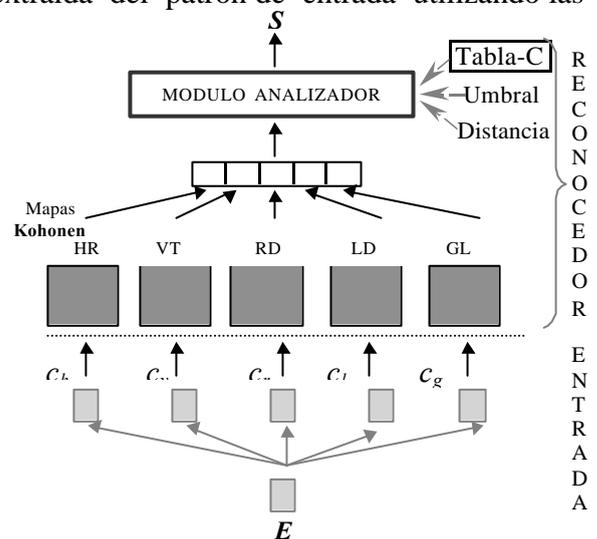


Figura 1: Estructura del sistema reconocedor [21]; aplicación al clasificador de dígitos manuscritos sin restricciones

Cada mapa está asociado a una característica direccional (HR-horizonta; VT-vertical; RD-diag.derecha; LD-diag.izquierda; GL-global). En el módulo analizador: Tabla-C. Tabla de confiabilidad - Parámetros: Umbral de confiabilidad y Distancia mínima

Las extensiones potenciales del modelo que investigamos actualmente inciden sobre la representación de la entrada (preprocesamiento) y sobre la estructura del sistema clasificador, como formas de mejorar la clasificación y la calidad del sistema en general.

La estructura general del sistema con las posibles modificaciones que mencionaremos para las etapas de preprocesamiento / clasificación, puede observarse en la figura 2.

Para el preprocesamiento, realizamos experiencias aplicando a los patrones extraídos de la base de datos de la Universidad de Concordia, normalizados en tamaño, la transformada wavelet de Haar y wavelet à trous, obteniendo una nueva representación del patrón en cuatro subbandas en un primer nivel de resolución y cuatro subbandas en un segundo nivel de resolución, y dedicando un mapa auto-organizado a cada subbanda. Investigamos hasta qué punto incide la forma de los patrones en la performance del algoritmo. Por ejemplo, el afinamiento del trazo del patrón ha permitido mejorar resultados cuando la entrada fue preprocesada mediante la utilización de la wavelet de Haar.

Otra línea de investigación relacionada con la representación de la entrada, consiste en disminuir la dimensión del patrón, a través de la aplicación de PCA. Realizamos pruebas entrenando mapas (patrón completo / característica global) con patrones representados utilizando 128, 64 y 8 componentes principales. En cada caso se ha retenido el 93, 83 y 51 % de la varianza total. Hemos logrado reducir la dimensión de la entrada (256 en el modelo original), obteniendo resultados muy cercanos a los ya presentados disminuyendo el costo computacional. Queda pendiente

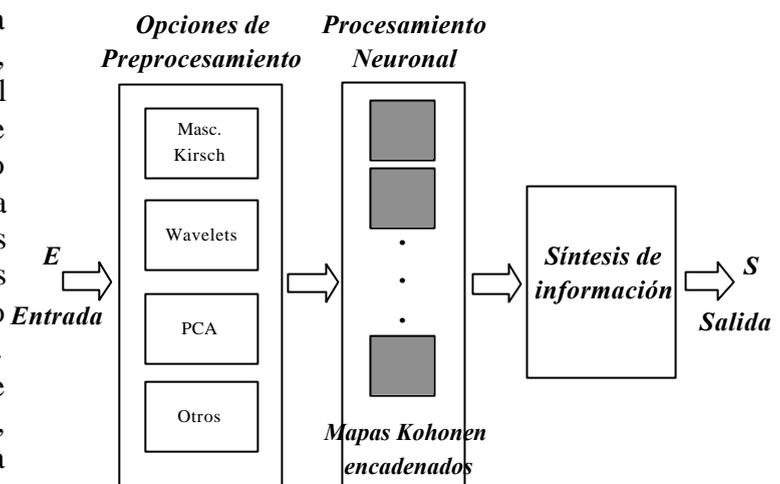


Figura 2: Nueva estructura del sistema reconocedor: opciones bajo estudio

la aplicación de PCA a las características direccionales extraídas con las máscaras de Kirsch.

Con respecto a la estructura del sistema reconocedor, pensamos que una organización en submódulos permitirá obtener una clasificación más especializada de acuerdo a las características de la distribución de la entrada. De esta forma, los patrones de entrenamiento son separados en un subconjunto de elementos más representativos de cada clase (elementos cercanos a la media de la clase) y otro subconjunto de elementos más dispersos. Éstos últimos los denominaremos “patrones confusos”, ya que las distorsiones que presentan dificultan su correcta clasificación (al estar alejados de la media de su clase es fácil que el sistema los identifique como pertenecientes a otra clase, con una media un poco más cercana). Luego, utilizamos cada subconjunto para entrenar distintos mapas auto-organizados. En la etapa de clasificación, el reconocedor deberá decidir si un patrón de entrada es confuso o no (esto ya lo resolvía el modelo propuesto de la figura 1), y en caso afirmativo, las redes dedicadas a patrones confusos responderán a qué clase pertenece el patrón.

Actualmente estamos estudiando la posibilidad de utilizar redes de menor dimensión para el tratamiento de patrones confusos (con el objeto de evitar el sobre-entrenamiento), eventualmente valiéndonos de características especiales provistas por los métodos de extracción de características.

En base a las líneas de investigación presentadas, esperamos obtener un sistema reconocedor que conserve las propiedades destacables del modelo original, como su modularidad y poder explicativo y que, además, mejore la calidad de la clasificación y disminuya el costo computacional.

5. Referencias

- [1] E. B. Baum y D. Haussler. What size net gives valid generalization? *Neural Computation* 1, 151-160. 1989.

- [2] G. Y. Chen, T. D. Bui y A. Krzyzak. Contour-based Handwritten Numeral Recognition using Multiwavelets and Neural Networks. *Pattern Recognition* 36, 1597-1604. 2003.
- [3] Z. Chi y H. Yan. Handwritten Numeral Recognition Using a Small Number of Fuzzy Rules With Optimized Defuzzification Parameters. *Neural Networks*, 8(5), 821-827. 1995.
- [4] S. B. Cho. Self-Organizing Map with Dynamical Node Splitting: Application to Handwritten Digit Recognition. *Neural Computation* 9, 1345-1355. 1997.
- [5] S. Correia y J. de Carvalho. Recognition of Unconstrained Handwritten Numerals Using Biorthogonal Spline Wavelets., 2000. Proceedings XIII Brazilian Symposium on Computer Graphics and Image Processing, p. 338. 2000.
- [6] B. Fritzke. Growing cell structures - A Self-organizing Network for Unsupervised and Supervised learning. *Neural Networks* 7(9), 1441-1460. 1994.
- [7] K. Fukushima. Neural network model for selective attention in visual pattern recognition and associative recall. *Applied Optics* 26(23), 4985-4992. 1987.
- [8] K. Fukushima y N. Wake. Handwritten Alphanumeric Character Recognition by the Neocognitron. *IEEE Transactions on Neural Networks* 2(3), 355-365. 1991.
- [9] Y. Hamamoto, S. Uchimura, M. Watanabe, T. Yasuda, Y. Mitani, S. Tomita. A Gabor Filter-based Method for Recognizing Handwritten Numerals. *Pattern Recognition* 31(4), 395-400. 1998.
- [10] T. Kohonen. Self-organized formation of topologically correct feature maps. *Biological Cybernetics* 43, 59-69. 1982.
- [11] T. Kohonen. The Neural Phonetic Typewriter, *IEEE Computer* 21(3), 11-22. 1988.
- [12] P. Koikkalainen y E. Oja. Self-organizing hierarchical feature maps. *Proceedings International Joint Conference Neural Networks*, 279-284. San Diego, CA. 1990.
- [13] A. Krzyzak, W. Dai y C.Y. Suen. Unconstrained handwritten character classification using modified backpropagation model. *Proceedings of 1st. International Workshop on Frontiers in Handwritten Recognition*, Montreal, Canadá, 155-166. 1990.
- [14] Y. Le Cun, B. Boser, J. S. Denker, D. Henderson, R. E. Howard, W. Hubbard, L. D. Jackel. Backpropagation Applied to Handwritten Zip Code Recognition *Neural Computation* 1, 541-551. 1989.
- [15] S. W. Lee. Multilayer Cluster Neural Network for Totally Unconstrained Handwritten Numeral Recognition. *Neural Networks*, 8(5), 783-792. 1995.
- [16] S. W. Lee, C. Kim, H. Ma y Y. Tang. Multiresolution Recognition of Unconstrained Handwritten Numerals with Wavelet Transform and Multilayer Cluster Neural Network. *Pattern Recognition*, 29(12), 1953-1961. 1996.
- [17] E. López-Rubio, J. Muñoz-Pérez and J. A. Gómez-Ruiz. A principal components análisis self-organizing map. *Neural Networks* 17(2), 261-270. 2004
- [18] W. K. Pratt . *Digital image processing*, New York, Wiley. 1978.
- [19] S. Raudys y A.K. Jain. Small sample size problems in designing artificial neural networks, en *Artificial Neural Networks and Statistical Pattern Recognition*. I.K. Sethi y A.K. Jain (Eds.). Amsterdam, North-Holland. 1991.
- [20] T. D. Sanger. A tree-structured adaptive network for function approximation in high-dimensional spaces. *IEEE Transactions on Neural Networks* 2(2), 285-293. 1991.
- [21] L. M. Seijas y E. C. Segura. Un clasificador neuronal que explica sus respuestas: aplicación al reconocimiento de dígitos manuscritos. *Proc. IX Congreso Argentino de Ciencias de la Computación*, La Plata. 2003.
- [22] P. Wunsch y A. Laine. Wavelet Descriptors for Multiresolution Recognition of Handprinted Characters. *Pattern Recognition*. 28(8), 1237-1249. 1995.
- [23] B. Zhang, M. Fu and H. Yan. A nonlinear neural network model of mixture of local principal component analysis: application to handwritten digits recognition. *Pattern Recognition* 34(2): 203-214. 2001.