

Clasificación y Reconocimiento de Patrones utilizando Redes Neuronales

Lic. Laura Lanzarini¹, Ing. A. De Giusti²

*Laboratorio de Investigación y Desarrollo en Informática³
Departamento de Informática - Facultad de Ciencias Exactas
Universidad Nacional de La Plata*

Descripción

Desde la aparición de las computadoras digitales, en 1946, hasta fines de los 80, las aplicaciones de procesamiento de información han utilizado el mismo estilo: *computación programada*. Esto implica el desarrollo de un algoritmo o un conjunto de reglas que permitan arribar a la solución del problema, para luego codificarlo adecuadamente.

Sin embargo, existen situaciones en que dicho algoritmo es desconocido, y por lo tanto su desarrollo como su implementación, insumen mucho tiempo y dinero.

Básicamente, este estilo presenta dos grandes problemas:

- En primer lugar, es difícil generalizar las soluciones ad-hoc, obligando a pensar cada problema en forma independiente, dificultando la reusabilidad de experiencias y soluciones encontradas.
- El segundo tiene que ver con la gran cantidad de información involucrada en un problema del mundo real, que generalmente, no puede ser resuelto utilizando hardware convencional, exigiendo su paralelización.

Como solución a esto, muchos investigadores han trabajado sobre un nuevo estilo de procesamiento de la información, llamado *neurocomputación* [Hetch 90], que permite desarrollar en algunas áreas (procesamiento de sensores, reconocimiento de patrones, análisis de datos y control) capacidades de procesamiento de la información para las que no se conoce el algoritmo solución.

Esta nueva tendencia se basa en la forma en que trabaja el cerebro humano, utilizando diferentes arquitecturas, basadas en neuronas simples que funcionan en grupos locales. El esfuerzo conjunto, en paralelo, de todos estos grupos es lo que permite alcanzar el objetivo global.

Las redes neuronales se caracterizan principalmente, por su capacidad para generalizar la información y por su tolerancia al ruido. Por este motivo y por el hecho de ser fácilmente paralelizables, una de las áreas informáticas que más las utiliza es la de Reconocimiento de Patrones. En particular, en esta presentación, nos centraremos en el reconocimiento de patrones ubicados en una imagen color 2D.

Antes de comenzar a discutir las características que debería tener la arquitectura a utilizar, es importante analizar la forma en que los patrones son obtenidos. Dado que el tipo

¹ Profesor Adjunto Dedicación Exclusiva. Dpto. de Informática, Facultad de Ciencias Exactas. Universidad Nacional de La Plata. E-mail: laural@info.unlp.edu.ar

² Investigador Principal del CONICET. Profesor Titular Dedicación Exclusiva. Dpto. de Informática, Facultad de Ciencias Exactas. Universidad Nacional de La Plata. E-mail: degiusti@info.unlp.edu.ar

³ Calle 50 y 115 1er Piso, (1900) La Plata, Argentina, TE/Fax +(54)(221)422-7707. <http://lidi.info.unlp.edu.ar>

de problema a resolver trabaja sobre elementos de muestras histológicas, la obtención de dichos patrones se basa en un proceso de segmentación de la imagen.

Obtención automática de los patrones a reconocer

Si bien existe una amplia bibliografía acerca de este tema [Jain 89] [Gonz 92]; se enunciará a continuación los métodos más utilizados en segmentación de imágenes médicas:

- Técnicas basadas en contornos: Las técnicas basadas en contornos utilizan las discontinuidades en la intensidad o color de la imagen. Este tipo de técnicas se utiliza cuando se trata de regiones suficientemente homogéneas.
- Técnicas de Agrupamiento (Clustering): El agrupamiento es un proceso que mapea un vector de características, $V_i \in R^p$, con $i = 1..n$ en una de k clases, donde $k \ll n$. Cada clase está representada por su centroide, es decir, por el vector que se encuentra a menor distancia de todos los vectores de la clase. Existen varios trabajos que resuelven el problema del agrupamiento, desde las aplicaciones convencionales tipo k-medias hasta el uso de redes neuronales difusas [Simp 92] [Mega 98], [Shie 95].
- Técnicas de satisfacción de restricciones: Este tipo de técnicas buscan minimizar una función energía. La función es formulada de tal forma que su mínimo corresponde a una buena segmentación de la imagen [Poli 96]. Los algoritmos de agrupamiento pueden ser vistos como una técnica de minimización de una función, ya que se busca minimizar la distancia entre los vectores de características y el centroide de cada clase.
- Técnicas que utilizan Redes Neuronales: Existe fuerte tendencia a intentar segmentar una imagen directamente a través de una red neuronal [Valli 98] [Cagn 93]

Arquitectura

Con la idea de ganar generalidad se pretende trabajar sobre una arquitectura no supervisada que sea capaz de adaptarse a cambios en los patrones de entrada. Puede utilizarse una arquitectura tipo ART (Adaptive Resonance Theory), ya que tiene posibilidad de clasificar patrones espaciales formando categorías estables. El mayor problema de esta arquitectura radica en su imposibilidad de clasificar patrones embebidos y es por esto que la imagen es segmentada previamente.

Además, como forma de acelerar el aprendizaje inicial se propone utilizar una modificación de ART 1 propuesta por Baxter [Baxt 91]. Por otro lado, dado que ART1 trabaja sobre entradas binarias, se realizará una modificación en la primer capa, F1, utilizando intersección difusa entre el vector de entrada, I , y el vector calculado en forma descendente, $V(j)$.

Objetivo del Proyecto

Uno de los mayores problemas que presenta el diagnóstico médico, en general, es la subjetividad del especialista. Puede notarse, principalmente en tareas de reconocimiento de patrones, que la experiencia del profesional tiene una estrecha relación con su diagnóstico final. Esto se debe a que el resultado no depende de una solución sistematizada sino de la interpretación realizada sobre la señal del paciente.

Por ejemplo, en el caso del diagnóstico de alteraciones del equilibrio, es necesario analizar la señal correspondiente al movimiento ocular del paciente. En ella se presenta un patrón denominado nystagmus cuya frecuencia en diferentes pruebas, determina el tipo de lesión. La forma de este patrón tiene una estrecha relación con el tipo de señal y es diferente en cada paciente. [Lan 97]

Algo similar ocurre en el conteo celular. En general, toda muestra histológica tiene asociados ciertos parámetros de normalidad que caracterizan a las poblaciones celulares que la constituyen. Esto le permite al especialista, en base a la agrupación de células con iguales características, realizar una primera clasificación del tejido que está observando, como *normal* o *patológico*.

Los métodos que permiten determinar la proporción de células que poseen características similares, constituyen una tarea muy rutinaria, pesada y sujetas a errores del observador por su carácter eminentemente subjetivo, por lo que resulta de sumo interés poder establecer dicha proporción con la mayor objetividad posible, para un diagnóstico y pronóstico más exactos.

Todo método que permita contabilizar células con características similares, constituye una herramienta muy importante para poder distinguir, a priori, lo normal de lo patológico y en una etapa posterior patologías específicas [Lan 95] [Lan 98].

Problemas como los aquí mencionados requieren trabajar con herramientas que no utilicen un algoritmo para hallar la solución sino que sean capaces de comportarse de acuerdo a los datos del problema. En esta dirección las *redes neuronales* resultan de suma utilidad, ya que no sólo son capaces de reconocer patrones con la ayuda del experto sino que por si mismas pueden generalizar la información contenida en los datos de entrada mostrando relaciones que a priori resultan complejas.

Actualmente se está trabajando en el reconocimiento automático de los elementos que intervienen en una muestra histológica entendiendo que este tipo de solución puede aplicarse a numerosos problemas de diagnóstico.

Los resultados mostrados en la sección siguiente corresponden a muestras de tejido hepático. Esta selección se basa no solo en su diversidad celular sino en la variación de tamaños y formas que se presentan dentro de un mismo tipo de célula.

Resultados obtenidos

El sistema actual recibe la imagen a través de una cámara colocada en el microscopio. Para calcular la proporción celular de un preparado es necesario recorrerlo en forma de "guarda griega", dando lugar aproximadamente, a 120 imágenes color de 640x420 pixels. Es importante considerar la magnitud de los cálculos a realizar y la necesidad de acelerar el proceso de clasificación.

Actualmente, la segmentación es semi-automática ya que es necesario que el operador, luego del proceso de agrupamiento, identifique la clase realmente útil. Como no se trata de colores uniformes, la automatización de esta etapa es muy costosa en tiempo. Por otro lado, el operador sólo interviene una vez, de donde no se considera a esta solución como una pérdida de objetividad en la resolución del problema.

Para lograr una clasificación adecuada es necesario realizar el entrenamiento con muestras de tejido normal de manera que se verifiquen las proporciones estadísticas conocidas.

Bajo estas restricciones, la clasificación es correcta, con un error menor al 10%.

Sería deseable comparar los resultados obtenidos con algún clasificador estadístico como el bayesiano. Obviamente, el mayor problema es la estimación de la *fdp* de cada clase.

Aspectos aún no resueltos

- Esta solución presenta serios problemas con la rotación de los patrones. En este caso particular, como en la mayoría de las muestras histológicas, los elementos a clasificar son circulares; pero si se piensa en una herramienta general se necesitaría construir un patrón de características y no basado en el color como lo aquí presentado.
- No se ha considerado el caso de patrones embebidos. Existen células que en su interior presentan ciertas "*manchas*" características. Estos podría afectar el resultado de la etapa de clasificación. Para solucionar este problema será necesario cambiar de arquitectura. Existen trabajos en esta dirección, como la arquitectura SONNET [Nigr 93].

Bibliografía

- [Baxt 91] *Supervised Adaptive Resonance Networks*. Baxter. Center for Adaptive Systems. Boston University. 1991
- [Cagn 93] *Neural Network Segmentation of Magnetic Resonance Spin Echo Images of the Brain*. Cagnoni, Coppini, Rucci, Caramella, Valli. Journal of Biomedical Engineering, V 15, pp.355-362. 1993
- [Gonz 92] *Digital Image Processing*. Gonzalez y Woods. Addison-Wesley. 1992
- [Hecht 90] *Neurocomputing*. Robert Hecht-Nielsen. Addison-Wesley. 1990
- [Jain 89] *Fundamentals of Digital Image Processing*. Anil Jain. Prentice Hall. 1989
- [Lanz 95] *Caracterización de los Elementos de una Muestra Histológica utilizando Khoros*. Lanzarini, Castañeda, Badrán, De Giusti. II International Congress on Information Engineering. Buenos Aires. 1995.
- [Lanz 97] *Real Time Analysis of the Nystagmus and Movement Patterns in Balance Disturbances*. Lanzarini, Vargas, Estelrich, De Giusti. 19th International Conference Information Technology Interfaces. Croatia. 1997
- [Lanz 98] *Reconocimiento y Clasificación de los elementos de una muestra de sangre utilizando Redes Neuronales*. Lanzarini, Vargas, Badrán, De Giusti. 6º Congreso Internacional de Nuevas Tecnologías y Aplicaciones Informáticas. Cuba. 1998
- [Mega 98] *Fuzzy Neural Network for Classification and Detection of Anomalies*. Meneganti, Saviello y Tagliaferri. IEEE Transactions on Neural Networks, Vol.9, nº 5 Septiembre 1998
- [Nigr 93] *Neural Networks for Pattern Recognition*. Albert Nigrin. MIT Press 1993
- [Poli 96] *Optimum Segmentation of Medical Images with Hopfield Neural Networks*. Poli y Valli. CSRP-95-12. School of Computer Science. The University of Birmingham.
- [Shie 95] *A method for fuzzy rules extraction directly from numerical data and its application to pattern recognition*. Shiego Abe and Ming-Shong Lan. IEEE Trans.on Fuzzy Systems, Vol.3, nº 1, Febrero 1995.
- [Simp 92] *Fuzzy min-max neural networks - Part1 : Clasificación*. P.Simpson. IEEE Trans.Neural Networks, Vol3, pp 776-786,1992
- [Valli 98] *Neural Networks and Prior Knowledge Help the Segmentation of Medical Images*. Valli, Poli, Cagnoni and Coppini. Journal of Computing and Information Technology, Vol.6 Nº 2. 1998