

Capacidad y Recuperación en Memorias Asociativas Bidireccionales (BAM) Discretas II

J.A. Horas y E.A. Bea

Universidad Nacional de San Luis - Facultad de Ciencias Físico-Matemáticas y Naturales
Departamento de Física - Instituto de Matemática Aplicada (IMASL)
Ejército de los Andes 950 - (5700) San Luis - Argentina
e-mail: jhoras@unsl.edu.ar

Se analiza la performance de una red neuronal usada como memoria asociativa bidireccional (BAM) discreta en la cual las conexiones entre neuronas son modificadas también mediante un procedimiento de desaprendizaje. En particular se estudia el mejoramiento en la capacidad y recuperación de diversos tipos de patrones, obteniéndose interesantes resultados.

Se muestra la influencia sobre la performance de diversas formas de aplicación del proceso de desaprendizaje. El número y distribución de estados espurios es también analizado.

We analyze the performance of a discrete bidirectional associative memory (BAM) in which the synapses are also modified by means of an unlearning procedure. We study the improvements of the capacity and recovery of several types of patterns and the influence on the performance using that procedure obtain interesting results.

We also analyze the number and distribution of spurious states.

I. Introducción

La capacidad de actuar como memoria asociativa direccionable por su contenido (CAM) es una de las importantes capacidades de las redes neuronales artificiales[1,2]. Entre los muchos modelos de memorias asociativas se encuentra la memoria asociativa bidireccional (BAM)[3] cuya importancia es su capacidad de lograr heteroasociación con una pequeña matriz de correlación. Sin embargo su performance adolece de los mismos problemas que la red de Hopfield (i.e. escasa capacidad, reducido tamaño de las cuencas de atracción, etc.). Como una forma de aliviar parcialmente estos problemas hemos mostrado en una presentación anterior[4], que la aplicación de un procedimiento de desaprendizaje[2] (o desestabilización parcial de estados metaestables espurios (EME))[5] tiene efectos positivos sobre la BAM. A ésta, con desaprendizaje se la denomina uBAM.

El objetivo de este trabajo, además de mostrar el positivo resultado de la aplicación del proceso de desaprendizaje, es lograr una mejor comprensión de la influencia de éste sobre la cantidad de estados metaestables espurios. Dado que existe una función energía que asegura la convergencia de la uBAM, tratamos de comprender mejor el paisaje energético mientras tiene lugar el proceso de desaprendizaje.




Figura 1: arquitectura de la BAM.

II. El modelo

La idea básica de la BAM (fig. 1) es:

Grabación

Como hay dos capas en la BAM, una de ellas se denota como campo f_x y tiene L_x neuronas correspondientes al patrón X , y la otra se denota como campo f_y y tiene L_y neuronas correspondientes al patrón Y . La matriz de conexiones o de acoplamientos sinápticos está dada por

$$W = \frac{1}{\frac{1}{2}(L_x + L_y)} \sum_{i=1}^M Y^{(i)} X^{(i)T} \quad (1)$$

donde los M pares de patrones a grabar $(X^{(1)}, Y^{(1)}), \dots, (X^{(M)}, Y^{(M)})$ son bipolares, de L_x (o L_y) componentes +1 o -1.

Recuperación

Luego de la presentación de un patrón inicial o de prueba X (o Y) la BAM comienza a evolucionar desde ese estado

Investigador del CONICET.

inicial y recupera un cierto par de patrones de acuerdo a la siguiente dinámica

$$Y' = \text{sgn}(WX) = \text{sgn}\left(\sum_{i=1}^M (Y^{(i)} X^{(i)T}) X\right) \quad (2)$$

$$X' = \text{sgn}(W^T Y) = \text{sgn}\left(\sum_{i=1}^M (X^{(i)} Y^{(i)T}) Y\right) \quad (3)$$

La convergencia de este proceso está asegurada puesto que la red siempre llega, después de un tiempo finito, a un estado estable o punto fijo que es uno de los mínimos del Hamiltoniano o energía de la red, dada por

$$H(X, Y) = -Y^T WX = -X^T W^T Y \quad (4)$$

Desafortunadamente la codificación dada por (1) no puede garantizar el ideal de que cada par nominal sea un punto fijo, aún cuando el número de pares a grabar sea pequeño. A fin de moderar este problema, manteniendo el mismo esquema de codificación, el modelo se completa con un proceso de desaprendizaje sobre la matriz de conexiones sinápticas, de acuerdo a lo siguiente:

1) Inicialización al azar (Random Shooting).

2) Relajación: el sistema debe relajar a una configuración estacionaria debido a la existencia de una función energía.

3) Desaprendizaje: la matriz de conexiones es actualizada según

$$W^{(d)} = W^{(d-1)} - \frac{\varepsilon}{\frac{1}{2}(L_x + L_y)} Y^{(d)} X^{(d)T} \quad (5)$$

El procedimiento es local, iterativo y puramente Hebbiano. Puede obtenerse[2], para el número óptimo de iteraciones del procedimiento

$$D_{\text{optimo}} = \frac{M}{\varepsilon} \left[c_0 + \frac{c_1}{\frac{1}{2}(L_x + L_y)} \right] \quad (6)$$

con $\varepsilon=0.01$, $c_0=0.28$ y $c_1=10$.

La BAM también puede verse como L perceptrones independientes embebidos en cada capa, entonces la (5) expresa un paso en el procedimiento de desestabilización parcial realizada por los perceptrones[5].

III. Resultados numéricos

En las gráficas los puntos son promedios sobre 20 redes y las barras corresponden a la desviación estándar.

En los casos que corresponda se ha procedido según la convención de contabilizar como patrón cualquier estado cuyo correspondiente overlap es mayor que 0.95, siendo espurio en otro caso.

Performance

Resultados para la BAM y la uBAM se estudian comparativamente mediante curvas de capacidad (fig. 2) y de tamaño de cuencas de atracción (fig. 3). Las condiciones de operación se explicitan en cada figura tomándose el mismo número de neurodos en ambas capas sin pérdida de generalidad.

Es conveniente definir una medida de similaridad entre estados u overlap como

$$m^{(i)} = \frac{1}{2} (m_x^{(i)} + m_y^{(i)}) = \frac{1}{2} \left(\frac{X^{(i)} X}{L_x} + \frac{Y^{(i)} Y}{L_y} \right) \quad (7)$$

Promediando sobre patrones la (7) resulta

$$m = \frac{1}{M} \sum_{i=1}^M m^{(i)} \quad (7a)$$

La capacidad de almacenamiento se define como

$$\alpha = \frac{M}{\frac{1}{2}(L_x + L_y)} \quad (8)$$




Figura 2: overlap vs. capacidad de almacenamiento. Se inicializa cada red sobre cada patrón nominal, y se evalúa el overlap correspondiente de cada estado metaestable al que relaja.

Para cuantificar el tamaño de las cuencas de atracción, determinamos el radio de las mismas definido por

$$R = 1 - m_c \quad (9)$$

donde m_c es un overlap crítico, o sea el valor correspondiente del overlap inicial m_0 , de forma tal que la curva $m(m_0)$ corte a la recta $m=0.95$.




Figura 3: radio de las cuencas de atracción vs. capacidad de almacenamiento. Las barras de error corresponden a la diferencia entre los overlaps críticos de las curvas $m(m_0)$ y $[m+\Delta m](m_0)$.




Figura 4: nro. de espurios vs. nro. relativo de pasos de desaprendizaje. Se inicializa cada red sobre cada patrón nominal, y se calcula el overlap correspondiente con cada estado metaestable al que relaja.




Figura 5: energía vs. overlap de los estados metaestables. Se inicializa cada red sobre un patrón de referencia, y se evalúa la energía y el overlap correspondiente de cada estado metaestable al que relaja.




Figura 6: energía de los estados metaestables vs. nro. relativo de pasos de desaprendizaje. Se inicializa cada red con versiones ruidosas de un patrón nominal de referencia con overlap inicial $m_0=0.9$, y se evalúa la energía de cada estado metaestable al que relaja.

IV. Conclusiones

En este trabajo se ha mostrado:

- que el proceso de desaprendizaje aplicado a una BAM produce mejoras en la performance. Como se muestra en las figs. 2 y 3.
- que los estados metaestables espurios accesibles desde un patrón se minimizan con el número óptimo de veces de aplicación del procedimiento de desaprendizaje. Según puede verse en las figs. 4 y 5.
- que los estados metaestables espurios accesibles desde las cercanías de un patrón tienen la misma energía que éste. Se observa también que el paisaje energético alrededor de un patrón es notablemente plano luego de aplicar el procedimiento de desaprendizaje un número óptimo de veces. Esto puede verse en la fig. 6.

Referencias

- 1 - J.A. Freeman and D.M. Skapura, *Neural Networks: Algorithms, Applications, and Programming Techniques*. Addison-Wesley, 4 127-141 (1991).
- 2 - E. Domany, J.L. van Hemmen and K. Schulten, *Models of Neural Networks*. Berlin: Springer-Verlag, 1 55-85 (1991).
- 3 - B. Kosko, *IEEE Trans. Syst. Man, Cybern.*, 18 49-60 (1988). B. Kosko, *App. Opt.*, 26 4947-4960 (1987).
- 4 - J.A.Horas y E.A.Bea, *Capacidad y Recuperación en Memorias Asociativas Bidireccionales (BAM) Discretas*. Aceptado para su publicación en *Anales AFA'95*.
- 5 - J.A.Horas y P.M.Pasinetti, *Influencia de un Procedimiento de Desaprendizaje sobre la Performance como Memoria Asociativa de Redes Neuronales*. Enviado a publicar en *Anales AFA'96*.