

Determinación del Número óptimo de pasos de desaprendizaje en Memorias Asociativas

Jorge A. Horas* y Edgar A. Bea

Instituto de Matemática Aplicada (IMASL) - Universidad Nacional de San Luis
Ejército de Los Andes 950 - (5700) San Luis - Argentina

*e-mail: jhoras@unsl.edu.ar

La performance de una Memoria Asociativa implementada en una red neuronal artificial es mejorada notablemente al incorporar un proceso de desaprendizaje (desestabilización total o parcial de estados metaestables espúreos) que actúa sobre la matriz de conexiones sinápticas.

A fin de optimizar el proceso de desaprendizaje, se determina \mathcal{N}^* definido como el número óptimo de veces en que debe aplicarse tal proceso. Se muestran resultados usando ejemplos apropiados.

The performance of an Associative Memory implemented in an artificial neural network is improved by incorporating a process of unlearning which acts on the synaptic connections modifying it.

To optimize the unlearning process, we determine \mathcal{N}^* defined as the optimum number of times to apply such a process. Results using appropriate examples are showed.

I. Introducción

Se han estudiado modelos de redes neuronales artificiales actuando como memorias asociativas con acoplamientos sinápticos simétricos, que evolucionan hacia estados que son mínimos locales de una función energía global y luego permanecen estables en el tiempo.

Ya hemos mostrado, en otras redes con acoplamientos simétricos y en particular, en el caso de la Memoria Asociativa Bidireccional discreta [1] (BAM), que mediante un proceso de desaprendizaje se puede aumentar la capacidad crítica de estas redes, más allá de su conocido valor $\alpha_c^{(s)} \cong 0.14$. En particular existe un número óptimo de veces en que debe aplicarse el procedimiento de desaprendizaje.

Cualquier red neuronal simétrica en sus conexiones, no puede proveer asociaciones temporales. Es interesante investigar entonces la posibilidad de almacenar y recuperar secuencias temporales de estados predeterminados. La adición de conexiones asimétricas permite la recuperación de tales secuencias de patrones. Esto produce un conjunto controlado de transiciones entre estados de "cuasiequilibrio". El sistema se establece en un estado (o en su vecindad) por un período de tiempo finito y luego se hace la transición al próximo estado de "cuasiequilibrio" de la secuencia.

La performance de la red esta dada en este caso, tanto por el establecimiento de la secuencia grabada, como por la longitud de la misma. Determinándose que $\alpha_c^{(a)} \cong 0.1 < \alpha_c^{(s)} \cong 0.14$.

El primero de estos aspectos ha sido estudiado [2] y mejorado mediante la adición de una memoria dinámica lenta. El segundo, o sea el aumento de la limitada capacidad crítica en la longitud de las secuencias grabadas, es el objeto de este trabajo.

Para mejorar parcialmente la performance de la red, y en particular aumentar $\alpha_c^{(a)}$, se incorpora un proceso de desaprendizaje que actúa sobre la matriz de conexiones sinápticas. Determinándose el número óptimo de veces en que debe aplicarse el mismo.

II. Descripción del Modelo

Se considera una red neuronal consistente de N spines de Ising $\{S_i\}$, $i=1..N$, donde $S_i = \pm 1$. Los patrones embebidos son p estados $\{\xi_i^\mu\}$, $\mu=1..p$. Los patrones son aleatorios, cada ξ_i^μ toma los valores ± 1 con igual probabilidad. Los acoplamientos sinápticos entre neuronas se clasifican en dos tipos de conexiones. El primer tipo es simétrica

$$J_{ij}^{(s)} = \frac{1}{N} \sum_{\mu=1}^p \xi_i^\mu \xi_j^\mu \quad i \neq j \quad (1)$$

El segundo tipo es asimétrica y responsable de la generación de la secuencia, esta dada por

$$J_{ij}^{(a)} = \frac{\lambda}{N} \sum_{\mu=1}^q \xi_i^{\mu+1} \xi_j^\mu \quad i \neq j \quad (2)$$

con $\xi_i^{\mu+1} = \xi_i^1$ y $q < p$ es la longitud de la secuencia. La sinápsis asimétrica define un orden cíclico entre q patrones.

El sistema evoluciona desde un estado inicial según la siguiente dinámica

$$S_i(t+1) = \text{sgn}(h_i(t)) \quad (3)$$

La actualización de los neurododos se realiza en paralelo y sincrónicamente. El campo local consiste de dos contribuciones

$$h_i(t) = h_i^{(s)}(t) + h_i^{(a)}(t) \quad (4)$$

* Autor a quien debe dirigirse la correspondencia.

donde

$$h_i^{(s)}(t) = \sum_{j=1}^N J_{ij}^{(s)} S_j(t) \quad (4a)$$

y

$$h_i^{(a)}(t) = \sum_{j=1}^N J_{ij}^{(a)} S_j(t) \quad (4b)$$

Entonces el campo local se expresa como

$$\begin{aligned} h_i(t) &= \sum_{j=1}^N \left(J_{ij}^{(s)} + J_{ij}^{(a)} \right) S_j(t) \\ &= \sum_{j=1}^N J_{ij} S_j(t) \end{aligned} \quad (5)$$

Con el fin de mejorar la performance del sistema, el modelo se completa incorporando un proceso de desaprendizaje sobre la matriz de conexiones sinápticas totales, de acuerdo a lo siguiente

1) **Iniciación al azar (Random Shooting).**

2) **Relajación:** el sistema evoluciona en una cierta cantidad fija de pasos de "tiempo" u_p , alcanzando un estado final $\eta_i^{(d)}$.

3) **Desaprendizaje:** la matriz de conexiones sinápticas total es modificada según

$$J_{ij}^{(d)} = J_{ij}^{(d-1)} - \frac{\epsilon}{N} \eta_i^{(d)} \eta_j^{(d)} \quad (6)$$

ϵ es el parámetro de desaprendizaje y d indica la iteración. El procedimiento es local, iterativo y puramente hebbiano.

Este modelo, similar al ya estudiado por Hopfield [3] con conexiones sinápticas asimétricas, también presenta al igual que en el caso simétrico, un número óptimo de pasos de desaprendizaje (ver fig. 2).

Se propone una relación funcional entre \mathcal{N}^* , el número óptimo de iteraciones del procedimiento de desaprendizaje, y los parámetros correspondientes, según lo siguiente

$$\mathcal{N}^*(N, p, \epsilon, \lambda, u_p) = C f_1(N) f_2(p) f_4(\epsilon) f_3(\lambda) f_5(u_p) \quad (7)$$

donde $C = \text{cte.}$

Se ha determinado la siguiente expresión mediante un estudio numérico (ver fig. 1)

$$\begin{aligned} \mathcal{N}^*(N, p, \epsilon, \lambda) &= 3.5 \cdot 10^{-10} \cdot (631.64 - 1.05 N) \cdot (0.1 p^2 + 1.6 p - 112) \\ &\cdot (13.65/\epsilon) \cdot (-275.56 \lambda^3 + 1843.81 \lambda^2 - 4303.73 \lambda + 3661.91) \end{aligned} \quad (8)$$

con $1.5 \leq \lambda \leq 4.75$.

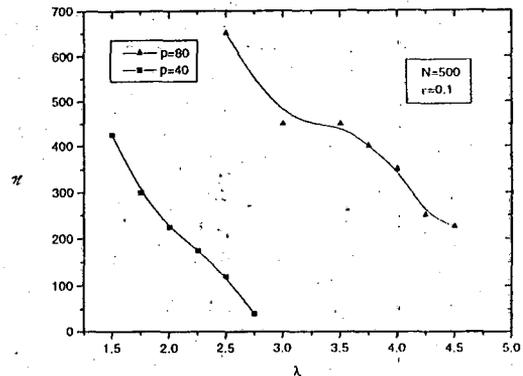


Figura 1: variación de \mathcal{N}^* con λ . Los otros parámetros se especifican en la gráfica.

III. Resultados Numéricos

En las figs. 2, 3 y 4 se muestran resultados positivos de la influencia del proceso de desaprendizaje sobre la performance de la red. Se observa claramente la recuperación de la secuencia de una longitud larga. Las gráficas corresponden a estados estacionarios en la red, despreciando la etapa transitoria.

IV. Conclusiones

En este trabajo se puede concluir lo siguiente:

- 1) Se muestra que el procedimiento de desaprendizaje, permite también como en el caso simétrico aumentar notablemente la capacidad de la red tanto para recuperar secuencias temporales.
- 2) Existe un número óptimo de pasos de desaprendizaje, el cual ha sido determinado.
- 3) El procedimiento es igualmente aplicable para la existencia de memorias dinámicas lentas en cada conexión.

Referencias

- 1- "Capacidad y Recuperación en Memorias Asociativas Bidireccionales (BAM) Discretas II", J. A. Horas y E. A. Bea. Enviado a publicar en Anales de la Asociación Física Argentina (A.F.A.), Vol. 8, 1996.
- 2- H. Sompolsky and I. Kanter, Phys. Rev. Lett. 57, 2861 (1986).
- 3- J. J. Hopfield, Proc. Natl. Acad. Sci. U.S.A. 79, 2554 (1982), and 81, 3088 (1984).

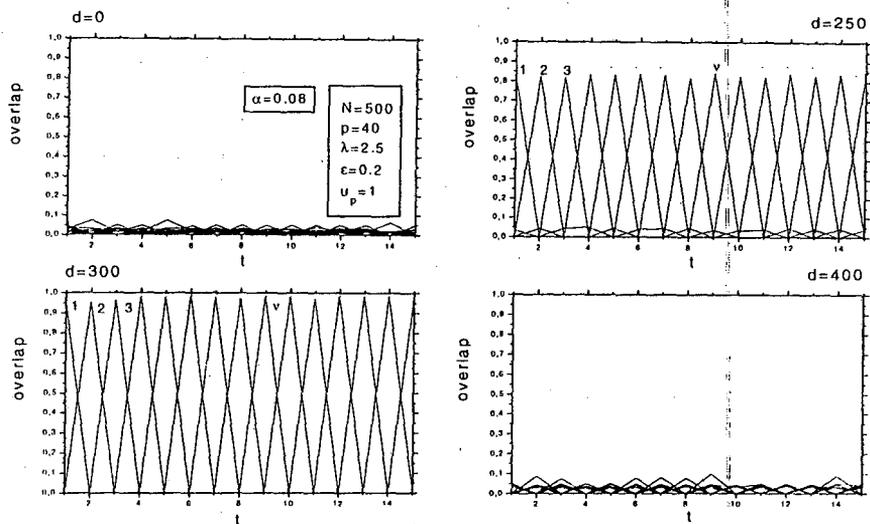


Figura 2: overlap con los patrones vs. el tiempo (t). El indice (v) indica el nro. de patrón y (d) el nro. de pasos de desaprendizaje.

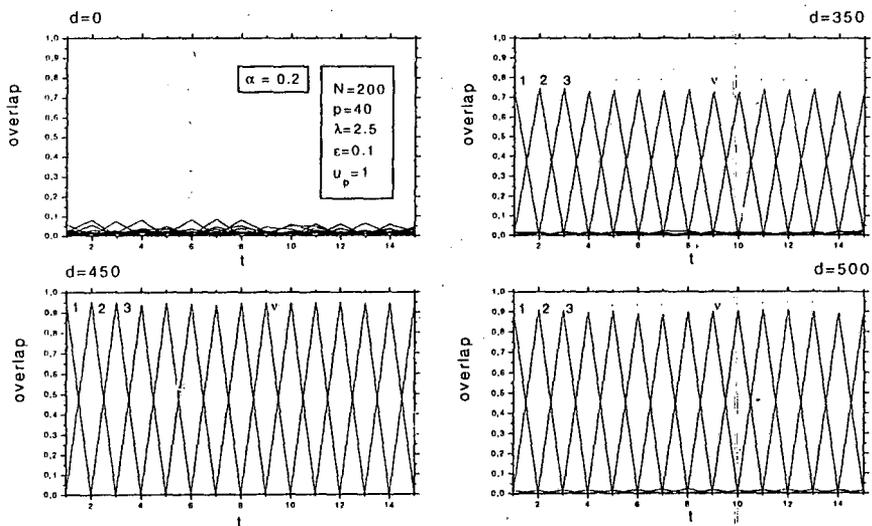


Figura 3: Idem fig. 2. Para $\alpha^{(n)}=0.2$.

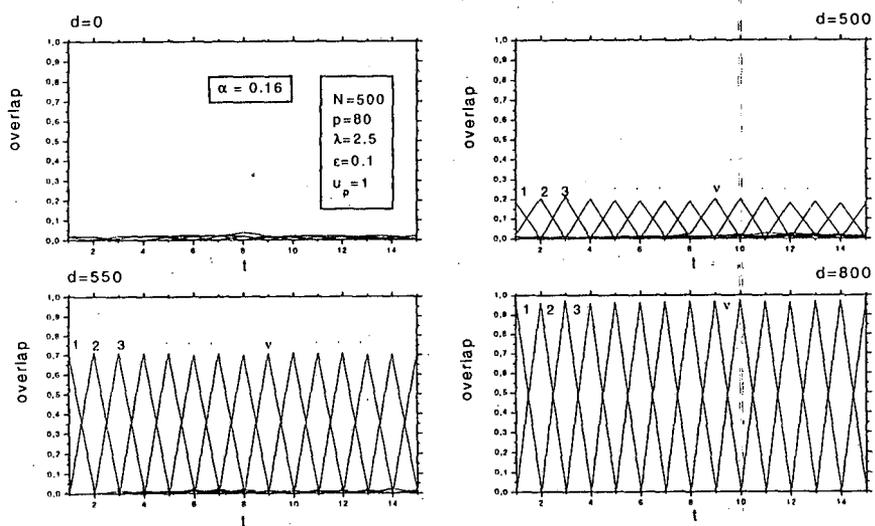


Figura 4: Idem fig.2. Para $\alpha^{(n)}=0.16$.