

El modelo de Hopfield a partir de la función energía

---

Volvamos a la idea de una única memoria almacenada y miremos la distancia de Hamming entre el estado  $\vec{S}(t)$  y la memoria

$$d^1 = \frac{1}{4N} \sum_{i=1}^N (S_i - \xi_i^1)^2$$

$$d^1 = \frac{1}{4N} \sum_{i=1}^N (S_i^2 - 2S_i \xi_i^1 + (\xi_i^1)^2) = \frac{1}{4N} \cdot 2 \sum_i (1 - S_i \xi_i^1)$$

$$= \frac{1}{2N} \sum_{i=1}^N 1 - \frac{1}{2N} \sum_{i=1}^N S_i \xi_i^1$$

$$= \frac{1}{2} \left( 1 - \frac{1}{N} \sum_{i=1}^N S_i \xi_i^1 \right)$$

$$d^1 = \frac{1}{2} (1 - m^1)$$

$$\text{donde } m^1 = \frac{1}{N} \sum_{i=1}^N S_i \xi_i^1$$

$m^1$  es la "superficie" entre la memoria y el estado de la red  $\vec{S}(t)$

$$d^1(t) = \frac{1}{2} (1 - m^1(t))$$

$$d' = 0 \quad \Rightarrow \quad m' = 1$$


$$d' = 1 \quad \Rightarrow \quad m' = -1$$

$$d' = \frac{1}{2} \quad \Rightarrow \quad m' = 0$$

Nosotros usamos de ahora en más el parámetro  $m'(t)$  para medir el desempeño. Como no nos importa si se va a la memoria o a su negativo, en general nos ocuparemos de  $|m'|$ .

Si en el atractor  $|m'| = 1$  el sistema llegó a la memoria.

Definamos 
$$\frac{H}{N} = -\frac{1}{2} (m')^2$$



$$\begin{aligned}
H &= -\frac{N}{2} (m')^2 = -\frac{N}{2} \left( \sum_i s_i(t) \xi_i' \right) \left( \sum_j s_j(t) \xi_j' \right) \\
&= -\frac{N}{2} \frac{1}{N^2} \sum_i \sum_j \xi_i' \xi_j' s_i(t) s_j(t) \\
&= -\frac{1}{2} \sum_i \sum_j \frac{\xi_i' \xi_j'}{N} s_i(t) s_j(t) \\
&= -\frac{1}{2} \sum_i \sum_j \frac{\xi_i' \xi_j'}{N} s_i(t) s_j(t) + \\
&\quad \frac{1}{2} \sum_i \frac{\xi_i' \xi_i'}{N} s_i(t) s_i(t) \\
&= -\frac{1}{2} \sum_i \sum_j w_{ij} s_i(t) s_j(t) + \frac{1}{2}
\end{aligned}$$


Salvo una constante

$$H = -\frac{1}{2} \sum_i \sum_j w_{ij} s_i(t) s_j(t)$$

Vemos que  $H$  es mínima cuando  $m' = 1$  o  $m' = -1$  y máxima en  $m' = 0$ .  
 ¡Es justo lo que queremos!

$$\text{Si } P=2, \quad W_{ij} = \frac{1}{2} \left( \sum_i^1 \sum_j^1 + \sum_i^2 \sum_j^2 \right)$$

$$\frac{H}{2} = -\frac{1}{2} (m^1)^2 - \frac{1}{2} (m^2)^2$$



$$\text{Si } S_i = \sum_i^1, \text{ entonces } m^1 = 1$$

$$m^2 = 0 \left( \frac{1}{\sqrt{N}} \right)$$

$$S_i = \sum_i^2, \text{ entonces } m^1 = 0 \left( \frac{1}{\sqrt{N}} \right)$$

$$m^2 = 1$$

Se puede ver que

$$H(t) = -\frac{1}{2} \sum_{i=1}^2 \sum_{j=1}^2 \frac{1}{2} \left( \sum_i^1 \sum_j^1 + \sum_i^2 \sum_j^2 \right) S_i(t) S_j(t)$$

$$= -\frac{1}{2} \sum_{i=1}^2 \sum_{j=1}^2 W_{ij} S_i(t) S_j(t)$$


Ahora podemos generalizar esta expresión:

$$\begin{aligned}
 H(t) &= - \frac{1}{N} \sum_{\mu=1}^P (m^{\mu}(t))^2 \\
 &= - \frac{1}{N} \sum_{\mu=1}^P \left( \frac{1}{N} \sum_i \sum_{\mu}^M S_i(t) \right)^2 \\
 &= - \frac{1}{N} \sum_{\mu=1}^P \frac{1}{N^2} \sum_i \sum_{\mu}^M S_i(t) \sum_j \sum_{\mu}^M S_j(t) \\
 &= - \frac{1}{N} \frac{1}{N^2} \sum_i \sum_j \sum_{\mu}^M \sum_{\nu}^M S_i(t) S_j(t) \\
 &= - \sum_{i \neq j} \left( \frac{1}{N} \sum_{\mu}^M \sum_{\nu}^M \right) S_i(t) S_j(t) \\
 &\quad + \underbrace{\frac{1}{N} \sum_{\mu=1}^P \sum_{i=1}^N \underbrace{\sum_{\mu}^M \sum_{\nu}^M}_{+1} S_i(t) \underbrace{S_i(t)}_{+1}}_{\frac{NP}{N}} \\
 &= - \sum_{i \neq j} w_{ij} S_i(t) S_j(t) + P
 \end{aligned}$$

Como sumar un término constante no afecta a una definición de la energía, función que debemos "minimizar".

Este es un método para construir reglas.

Cuando tenemos más de dos neuronas la función energía tiene otros mínimos.



En el caso más general

$$H = -\frac{m_1^2}{2} - \frac{m_2^2}{2} - \dots - \frac{m_p^2}{2}$$

$$H(t) = -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N W_{ij} S_i(t) S_j(t)$$

con  $W_{ij} = \frac{1}{N} \sum_{\mu=1}^P \sum_i^M \sum_j^M$  ,  $W_{ii} = 0$

Ahora veremos que a medida que evoluciona la red,  $H(t)$  disminuye o se estaciona (no puede crecer).

Supongamos que actualizamos la neurona  $k$ .

$$S_k(t + \Delta t) = S'_k = -S_k(t) = -S_k$$

$$H(t + \Delta t) - H(t) = -\frac{1}{2} \sum_i \sum_j W_{ij} S'_i S'_j + \frac{1}{2} \sum_i \sum_j W_{ij} S_i S_j$$

$$\Delta H = -\frac{1}{2} \sum_{i \neq k} \sum_{j \neq k} \cancel{W_{ik}} (S'_i S'_j - S_i S_j) \quad = 0$$

$$- \frac{1}{2} \sum_{j \neq k} W_{kj} (S'_k S'_j - S_k S_j)$$

$$- \frac{1}{2} \sum_{i \neq k} W_{ik} (S'_i S'_k - S_i S_k)$$

Para  $i \neq k$  y  $j \neq k$   $S'_i = S_i$   $S'_j = S_j$

$$\Delta H = -\frac{1}{2} \sum_{j \neq k} W_{kj} (S'_k S'_j - S_k S_j)$$

$$- \frac{1}{2} \sum_{i \neq k} W_{ki} (S'_k S'_i - S_k S_i)$$

$$= - \sum_{i \neq k} W_{ki} S_i (S'_k - S_k)$$

$$= - (S'_k - S_k) \sum_{i \neq k} W_{ki} S_i$$

$$= + 2 S_k \sum_{i \neq k} W_{ki} S_i$$

$$= 2 S_k \underbrace{\sum_i W_{ki} S_i}_{\text{esto tiene el signo de } S'_k} - 2 \bar{W}_{kk}$$

Entonces, como  $S_k$  tiene signo opuesto a  $S'_k$

Entonces el primer término es negativo por definición, y es que

$$S'_k = \text{signo} \left( \sum w_{ki} S_i \right)$$

$$2 \quad S'_k S_k \leq 0$$

Luego, si se cambia el valor de  $S_k$ , la energía  $H$  disminuye. Si  $S_k = S_k$  queda inalterada. Así

$$\Delta H(t + \Delta t) \leq 0$$

Esto nos dice que la red evoluciona desde la configuración inicial decaiendo el valor de  $H$ . Si tenemos suerte, llegaremos al mínimo  $M^v = \pm 1$ .

Pero yo les dije, y más adelante lo mostraremos, que si  $P > 2$  (si guardamos más de 2 configuraciones) se generen mínimos.

Pensemos un poco sobre las consecuencias de estos nuevos mínimos.

- Si son mínimos locales no es grave, pero si son globales sí, pues cuanto más profundo es el mínimo, mayor es su "cuencia".
- Estos mínimos pueden estar totalmente descorrelacionados de las memorias y sus negativos. Estos mínimos serán estados de **NO MEMORIA**.
- Estos mínimos pueden estar correlacionados con una o más memorias almacenadas. Estos serán estados de **CONFUSIÓN**.

Los parámetros fundamentales aquí son los  $m^i$ , o sea, el vector de parámetros

$$\vec{m} = (m^1, m^2, m^3, \dots, m^p)$$

Nosotros "presentamos" a la red una configuración inicial inicial


$$\vec{S}(0) = (S_1(0), S_2(0), \dots, S_N(0))$$

y la dejamos evolucionar con la dinámica de Hopfield hasta que se "clave", o sea, se estacione en un mínimo de  $H$ . Recuerden que  $H$  depende de  $\vec{S}(t)$  y de la matriz  $W_{ij}$ .

En el mínimo medimos  $\vec{m}$ .

Si llegó a una de las memorias almacenadas  $\bar{m}$  al final será

$$\bar{m}(\infty) = (0, 0, \dots, \pm 1, \dots, 0)$$

  
 $\mu=1$        $\mu=2$        $\mu=v$        $\mu=P$

Si para esto, decimos que la red asoció  $\bar{S}(0)$  con la memoria  $v$ , pues si  $m^v(\infty) = \pm 1$  la configuración final estacionaria será la memoria  $v$  (si es  $+1$ ) o su negativo (si es  $-1$ ).

A este estado por abajo,  $\mathcal{J}$  deuce en el tiempo, lo cual nos garantiza que en un tiempo finito se "clavará" en algún mínimo.

Ahora bien, una solución de la forma:

$$\vec{m}(\infty) = (0, 0, \dots, \pm 1, \dots, 0)$$

solo es posible si las memorias son ortogonales

$$\frac{1}{N} \sum_{i=1}^N \sum_{\mu}^{\mu} \sum_{\nu}^{\nu} = \delta^{\nu\mu} = \begin{cases} 1 & \text{si } \mu = \nu \\ 0 & \text{si } \mu \neq \nu \end{cases}$$

Pero como son aleatorias las memorias, entonces

$$\frac{1}{N} \sum_{i=1}^N \sum_{\mu}^{\mu} \sum_{\nu}^{\nu} = O(1/\sqrt{N})$$

Esto dice que las soluciones serán de la forma

$$\vec{m}(\infty) = (m^1(\infty), m^2(\infty), \dots, \pm 1, \dots, m^P(\infty))$$

Por ejemplo, si  $N = 1000$ ,  $\sqrt{N} = 100$   
y  $1/\sqrt{N} = 0,01$ . Una solución  
puede ser

$$\bar{m}(x) = (0,01, -0,02, \dots, \underset{\substack{\downarrow \\ \mu = \nu}}{1}, \dots, -0,015)$$

O sea, esperamos  $m^k = O(1/\sqrt{N})$  si  
 $\mu \neq \nu$


# Neuronas Aleatorias.

Vimos que la dinámica

$$S_i(t + \Delta t) = \text{signo}(h_i(t))$$

hace que baje siempre  $H$ , o quede constante, si  $S_i(t + \Delta t) = S_i(t)$ .

Para evitar que el sistema se quede "fijo" en un mínimo local, usamos la familia "eventualmente" que la dinámica incrementa el valor de  $H$ .



Este método permite saltar por los mínimos locales.

Recordemos los neuronas biológicas.  
Tres elementos de ~~electricidad~~ importantes  
son

- el número de vesículas en el axón.
- el número de neurotransmisores en la vesícula
- el número de neurotransmisores que llegan a la dendrita post-sináptica

Entonces  $h_i$  es una variable aleatoria cuyo valor medio es

$$\bar{h}_i(t) = \sum_j w_{ij} S_j(t)$$

en tiempo  $t$ , y con varianza  $\sigma^2$

Como son muchos los dendritos la distribución de probabilidades es gaussiana con buena aproximación.

$$P(h_i = h) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(h-\bar{h})^2}{2\sigma^2}}$$

le neurone dispara se  $h_i > 0$

$$P(S_i(t+\Delta t) = +1) = \frac{1}{\sqrt{2\pi\sigma^2}} \int_0^{\infty} e^{-\frac{(h-h_i)^2}{2\sigma^2}} dh$$

$$\text{Si } u = \frac{h-h_i}{\sqrt{2\pi\sigma^2}} \quad du = \frac{dh}{\sqrt{2\pi\sigma^2}}$$

$$P(S_i(t+\Delta t) = +1) = \int_{\frac{h_i}{\sqrt{2\sigma^2}}}^{\infty} \frac{e^{-u^2}}{\sqrt{\pi}} du$$

$$P(S_i(t+\Delta t)=+1) = \frac{1}{2} \left[ 1 + \operatorname{erf} \left( \frac{\bar{h}_i}{\sqrt{2} \delta} \right) \right]$$

$$P(S_i(t+\Delta t)=-1) = \frac{1}{2} \left[ 1 - \operatorname{erf} \left( \frac{\bar{h}_i}{\sqrt{2} \delta} \right) \right]$$

$\delta$ , mejor

$$P(S_i(t+\Delta t)=\pm 1) = \frac{1}{2} \left[ 1 \pm \operatorname{erf} \left( \frac{\bar{h}_i}{\sqrt{2} \delta} \right) \right]$$

$\operatorname{erf}(x)$  es muy bien aproximada,  
con error menor a 1%, por la función  
 $\tanh(x)$ .

$$P(S_i(t + \Delta t) = \pm 1) = \frac{1}{2} \left[ 1 \pm \tanh(\beta h_i) \right]$$

$$\text{con } \beta = \frac{1}{2\sqrt{2}J} = \frac{1}{T}$$

or

$$P(S_i) = \frac{1}{2} \left[ 1 + S_i \tanh(\beta h_i) \right]$$

$$P(S_i) = \frac{1}{2} \left[ 1 + \tanh(\beta h_i S_i) \right]$$

$$S_i \quad T \rightarrow 0^+, \quad \beta \rightarrow \infty, \quad \frac{1}{2} \left[ 1 + \tanh(\beta h_i S_i) \right] \rightarrow \text{sgn}(h_i)$$

$$S_i \quad T \rightarrow \infty, \quad \beta \rightarrow 0^+, \quad \frac{1}{2} \left[ 1 + \tanh(\beta h_i S_i) \right] \rightarrow \frac{1}{2}$$

# Estados Espurios

Pueden surgir, cuando  $p$  aumenta, que se creen estados espurios, o sea, mínimos de  $H$ , o si fueran, atractores de la dinámica de la red, que no coinciden con ninguna memoria. Esto pueden ser mínimos no correlacionados con memoria alguna

$$\bar{m} = (0, 0, 0, \dots, 0)$$

o que mezclen varias memorias

$$\bar{m} = (m_1, m_2, m_3, 0, \dots, 0)$$

En este caso podemos decir que el atractor está confiado entre los 3 primeros miembros.

Ahora tenemos una dinámica aleatoria regida por un parámetro  $\beta$ . En física,  $\beta = \frac{1}{T}$ . Si  $T=0$   $\beta = \infty$ , recuperamos la dinámica discreta. El sistema puede "subir" por la función energía con cierta probabilidad.

Calculamos el valor medio de  $S_i$

$$\langle S_i \rangle = \text{Prob}(+1) \cdot 1 + \text{Prob}(-1) \cdot (-1)$$

$$= \frac{1}{1 + e^{-2\beta h_i}} - \frac{1}{1 + e^{2\beta h_i}}$$

$$= \frac{e^{\beta h_i}}{e^{\beta h_i} + e^{-\beta h_i}} - \frac{e^{-\beta h_i}}{e^{\beta h_i} + e^{-\beta h_i}}$$

$$= \tanh(\beta h_i)$$