

MODELO DE HOPFIELD: Parte II

Repasemos lo definido hasta aquí

Tenemos N neuronas binarias $S_i(t)$

$$\left\{ \begin{array}{ll} S_i(t) = 1 & \text{disparo} \\ S_i(t) = -1 & \text{reposo} \end{array} \right.$$

con $i = 1, 2, \dots, N$.

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

La dinámica autónoma es

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

con
$$h_i(t) = \sum_{j \neq i} W_{ij} S_j(t)$$

Recordemos que

- los umbrales son todos nulos, $\mu_i = 0, \forall i$.
- No se permiten autointeracciones $W_{ii} = 0 \forall i$

Elegimos una dinámica secuencial, actualizando una neurona por vez, ya sea en forma ordenada, $i = 1, 2, 3, \dots, N$, o en forma aleatoria. Además:

$$\Delta t = \frac{1}{N}$$

con lo cual $\Delta t = 1$ después de N intentos de actualización.

Digo "intentos" pues puede suceder que la dinámica no cambie el estado de la neurona.

- El input es la condición inicial $\{S_i(0)\}$ o $\vec{S}(0)$, y el output es el atractor, si existe $\{\vec{S}_i^v\}$ o \vec{S}^v

$$\vec{S}(0) \longrightarrow \vec{S}^v$$

Pero pueden ser otros atractores indeseados.

Vimos que con una memoria (una única configuración almacenada), la regla era:

$$\left\{ \begin{array}{l} W_{ij} = \frac{1}{N} \sum_i x_i^1 \sum_j x_j^1 \quad \text{si } i \neq j \\ W_{ii} = 0 \quad \forall i \\ \mu_i = 0 \quad \forall i \end{array} \right.$$

Vimos que funcionaba bien.

MUCHOS PATRONES

Supongamos ahora que queremos almacenar $p > 1$ configuraciones. Entonces Hopfield

propuso

$$W_{ij} = \frac{1}{N} \sum_{\mu=1}^p \sum_i x_i^{\mu} \sum_j x_j^{\mu}$$

$$W_{ii} = 0$$

$$\mu_i = 0$$

La regla sigue siendo local, pues depende de i y j y no de otras neuronas. Es una regla tipo "Hebb".

Además es una regla aditiva: si ya almacenamos P memorias y queremos almacenar una más, la $P+1$, entonces

$$W_{ij}' \longrightarrow W_{ij} + \frac{1}{N} \sum_i^{P+1} \sum_j^{P+1}$$

ANÁLISIS DE ESTABILIDAD

Supongamos que preparamos a la red inicialmente en una de las p memorias almacenadas, a la que denotamos por la letra griega v .

$$\vec{S}(0) = \vec{\sum}^v$$

$$\begin{aligned} S_i(0+\Delta t) &= \text{signo} \left(h_i(0) \right) \begin{matrix} +1 \\ -1 \end{matrix} \\ &= \text{signo} \left(\sum_{j \neq i} W_{ij} S_j(0) \right) \\ &= \text{signo} \left(\sum_{j=1}^N W_{ij} S_j(0) - W_{ii} S_i(0) \right) \end{aligned}$$

Sumé y resté el término

$$w_{ii} = \frac{1}{N} \sum_{\mu=1}^P w_{i:}^{\mu} w_{i:}^{\mu} = \frac{1}{N} \sum_{\mu=1}^P 1 = \frac{P}{N}$$

$$S_i(t+\Delta t) = \text{signo} \left(\frac{1}{N} \sum_{j=1}^N w_{ij} S_j(t) - \frac{P}{N} S_i(t) \right)$$

w_{ij} $S_j(t)$ $S_i(t)$

Supongamos por ahora $P \ll N$, con lo cual $\frac{P}{N} \ll 1$. Por ahora lo despreciamos.

$$\begin{aligned}
 S_i(t+\Delta t) &= \text{signo} \left(\frac{1}{N} \sum_{j=1}^N \sum_{\mu \neq \nu} w_{i:}^{\mu} w_{j:}^{\mu} w_{j:}^{\nu} + \frac{1}{N} \sum_{j=1}^N w_{i:}^{\nu} w_{j:}^{\nu} w_{j:}^{\nu} \right) \\
 &= \text{signo} \left(w_{i:}^{\nu} + \frac{1}{N} \sum_{j=1}^N \sum_{\mu \neq \nu} w_{i:}^{\mu} w_{j:}^{\mu} w_{j:}^{\nu} \right) \\
 &= \text{signo} \left(w_{i:}^{\nu} + \frac{(w_{i:}^{\nu})^2}{N} \sum_{j=1}^N \sum_{\mu \neq \nu} w_{i:}^{\mu} w_{j:}^{\mu} w_{j:}^{\nu} \right) \\
 &= \text{signo} \left(w_{i:}^{\nu} \left(1 + \frac{w_{i:}^{\nu}}{N} \sum_{j=1}^N \sum_{\mu \neq \nu} w_{i:}^{\mu} w_{j:}^{\mu} w_{j:}^{\nu} \right) \right)
 \end{aligned}$$

$$S_i(t+\Delta t) = \text{signo}(\xi_i^v) \text{signo} \left(1 + \frac{\xi_i^v}{N} \sum_{j=1}^N \sum_{\mu \neq v} \xi_i^\mu \xi_j^\mu \xi_j^v \right)$$

Hasta ahora no hemos hecho ninguna suposición sobre las p configuraciones. A partir de ahora asumiremos que son aleatorias y que:

$$\xi_i^\mu = \begin{cases} +1 & \text{con probabilidad } \frac{1}{2} \\ -1 & \text{con probabilidad } \frac{1}{2} \end{cases}$$

Además por ser independientes tenemos que

$$P(\xi_1^1, \xi_2^1, \dots, \xi_{N_1}^1, \xi_1^2, \dots, \xi_1^p, \dots, \xi_N^p) = \prod_{i=1}^N \prod_{\mu=1}^p P(\xi_i^\mu)$$

$$P(\xi_i^\mu = +1) = \frac{1}{2}$$

$$P(\xi_i^\mu = -1) = \frac{1}{2}$$

Nosotros queremos que \vec{z}^v sea un atractor de la dinámica, o sea,

$$S(t+\Delta t) = \text{signo}(\vec{z}_i^v) = \vec{z}_i^v$$

para lo cual deseamos que

$$\text{signo} \left(1 + \vec{z}_i^v \frac{1}{N} \sum_{j=1}^N \sum_{\mu \neq v} \vec{z}_i^\mu \vec{z}_j^\mu \vec{z}_j^v \right) = 1$$

Para ello

$$\vec{z}_i^v \frac{1}{N} \sum_{j=1}^N \sum_{\mu \neq v} \vec{z}_i^\mu \vec{z}_j^\mu \vec{z}_j^v$$

debe ser mayor que -1 .

Esta cantidad es una variable aleatoria, suma de $N \times (P-1)$ términos que pueden valer $+1$ o -1 con probabilidad $1/2$.

Definimos

$$C_i^v = - \sum_{i=1}^N \frac{1}{N} \sum_{j=1}^N \sum_{\mu \neq v} \sum_{i=1}^M \sum_{j=1}^M \sum_{\nu=1}^M$$

termino crosstalk

$$P(C_i^v) > 1$$

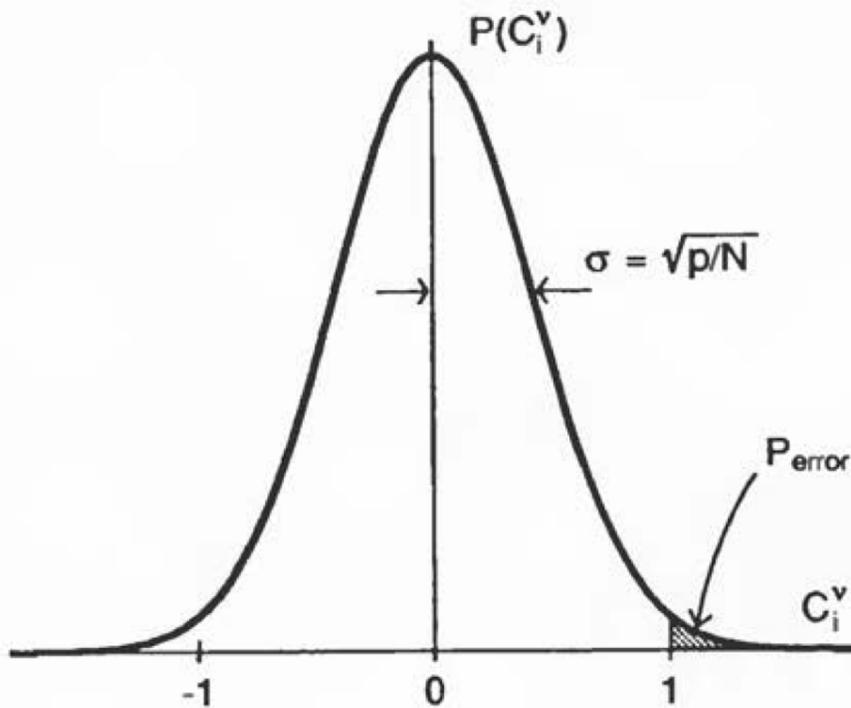


FIGURE 2.5 The distribution of values for the crosstalk C_i^v given by (2.13). For p random patterns and N units this is a Gaussian with variance $\sigma^2 = p/N$. The shaded area is P_{error} , the probability of error per bit.

Noten que si $C_i^v > 1$ entonces

$$\text{signo}(1 - C_i^v) = -1$$

de aquí

$$S_i(t + \Delta t) = -\xi_i^v$$

O sea, ese crosstalk término desestabiliza el fotón v .

$$P_{\text{error}} = \text{Prob}(C_i^v > 1).$$

C_i^v tiene una distribución binomial
y si $N \times (P-1) \gtrsim 30$ podemos
aproximarlo por una gaussiana,
con la misma media que la
binomial (cero) y con una
varianza

$$\sigma^2 = \frac{P-1}{N} \approx \frac{P}{N}$$

pues habíamos asumido $P \ll N$.

$$P(C_i^v) = \frac{1}{2\pi\sqrt{\frac{P}{2}}} e^{-\frac{(C_i^v)^2}{(2P/2)}}$$

¿Cuál es la probabilidad de que la neurona i se desestabilice si $\vec{G}(0) = \sum v_i^v$?

$$P_{\text{error}} = P(C_i^v > 1)$$

$$= \int_1^{\infty} P(x) \cdot dx$$

$$= \frac{1}{2\pi\sigma} \int_1^{\infty} e^{-\frac{x^2}{2\sigma^2}} dx$$

$$= \frac{1}{2} \left[1 - \operatorname{erf} \left(\frac{1}{\sqrt{2\sigma^2}} \right) \right]$$

$$P_{\text{error}} = \frac{1}{2} \left[1 - \operatorname{erf} \left(\sqrt{\frac{N}{2P}} \right) \right]$$

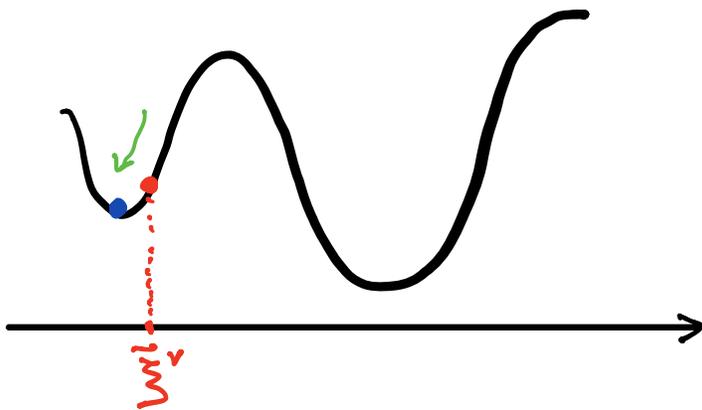
La función erf (error) se define como

$$\operatorname{erf}(x) = \frac{2}{\sqrt{\pi}} \int_0^x e^{-t^2} dt.$$

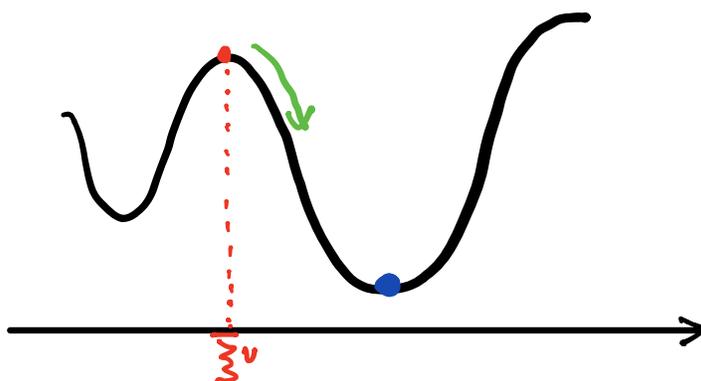
Podemos hacer una tabla que nos dice cual es el máximo P que podemos almacenar para un cierto tolerancia P_{error} .

P_{error}	P_{max}/N
0.001	0.105
0.0036	0.138
0.01	0.185
0.05	0.37
0.1	0.61

Pero esto solo habla de la estabilidad inicial. Si $P/N > 0$, nos dice que una fracción de las neuronas se apartarán de la memoria almacenada. Pero no sabemos si se "detiene" en una configuración cercana a $\vec{\xi}^v$ o si se va a una configuración alejada y descorrelacionada de $\vec{\xi}^v$.



Si para esto tenemos suerte.



Si para esto estamos perdidos.

Vemos que si $P < 0,138 \times N$, los atractores son muy parecidos a los memoria almacenados, pero que para $P > 0,138 \times N$ se produce una avalancha que aleja al atractor de Σ^v .

UN ENFOQUE ALTERNATIVO

Si deseamos que no haya errores, la cuenta anterior requiere que N crezca de forma tal que $\frac{P}{N} \rightarrow 0$.

Miremos ahora el caso en que requerimos que para toda la configuración almacenada se cumpla que la probabilidad de recuperarla bien sea mayor a 0,99.

$$(1 - P_{\text{error}})^N > \underline{\underline{0,99}}$$

$$(1 - P_{\text{error}})^N = \sum_{n=0}^N \binom{N}{n} 1^{N-n} P_{\text{error}}^n$$

$$\approx 1 - \binom{N}{1} P_{\text{error}} = 1 - N P_{\text{error}}$$

Con esto

$$(1 - P_{\text{error}})^N > 0,99 \Rightarrow 1 - N P_{\text{error}} > 0,99$$

$$(1 - 0,99) > N \cdot P_{\text{error}}$$

$$P_{\text{error}} < \frac{0,01}{N}$$

Esto nos acota P_{error} , de donde podemos
ver la cota P_{max} .

Miremos P_{error} .

$$P_{\text{error}} = \frac{1}{2} \left[1 - \text{erf} \left(\sqrt{\frac{N}{2P}} \right) \right]$$

$$\text{Si } x \rightarrow \infty \quad 1 - \operatorname{erf}(x) \rightarrow \frac{e^{-x^2}}{x\sqrt{\pi}}$$

$$\ln(\text{Perror}) = \ln \left[\frac{1}{2} \left[1 - \operatorname{erf} \left(\sqrt{\frac{N}{2P}} \right) \right] \right]$$

$$\approx \ln \left[\frac{1}{2} \frac{e^{-\frac{N}{2P}}}{\sqrt{\frac{N}{2P}} \cdot \sqrt{\pi}} \right]$$

$$\approx \ln\left(\frac{1}{2}\right) + \ln\left(e^{-\frac{N}{2P}}\right) + \ln\left(\frac{1}{\sqrt{\frac{N}{2P}}}\right) + \ln\left(\frac{1}{\sqrt{\pi}}\right)$$

$$\approx -\ln(2) - \frac{N}{2P} - \frac{1}{2} \ln\left(\frac{N}{2P}\right) - \frac{1}{2} \ln(\pi)$$

Donde hemos usado

$$\ln(a \cdot b) = \ln(a) + \ln(b)$$

$$\ln(a^z) = z \ln(a)$$

En particular

$$\ln\left(\frac{1}{a}\right) = -\ln(a)$$

Volramos a la expresión

$$P_{\text{error}} < 0,01 \cdot N$$

$$\ln(P_{\text{error}}) < \ln(0,01) - \ln(N)$$

$$-\ln(2) - \frac{N}{2P} - \frac{1}{2} \ln(\pi) - \frac{1}{2} \ln\left(\frac{N}{2P}\right) < \ln(0,01) - \ln(N)$$

Si $N \rightarrow \infty$ solo sobreviven pocos términos

$$\frac{N}{2P} > \ln(N)$$

Esto nos da una cota, con $N \gg 1$

$$P_{\text{MAX}} = \frac{N}{2 \ln(N)} \quad \leftarrow \text{OJO}$$

Si $N = 10000$, $\ln(N) \approx 6,9$, y

$$P_{\text{MAX}} = 74$$

$$\text{Si } N = 10^{11} \quad P_{\text{max}} \sim 2 \times 10^{-9}$$

Ahora podemos pedir más. Pedimos que la red ande bien para los p patrones almacenados

$$(1 - P_{\text{error}})^{Np} > 0,99$$

$$1 - Np P_{\text{error}} > 0,99$$

$$P_{\text{error}} < \frac{0,01}{Np}$$

Haciendo la misma cuenta

$$P_{\text{max}} = \frac{N}{4 \ln(N)}$$

Nota Si tomamos los valores de los neuronas ξ_i^μ como igualmente probables e independientes

$$\frac{1}{N} \sum_i \xi_i^\mu \xi_i^\nu = O\left(\frac{1}{\sqrt{N}}\right) \text{ si } \mu \neq \nu$$

Pero los podemos elegir también ortogonales

$$\sum_i \sum_i^u \sum_i^v = \delta_{\mu\nu}$$

En este caso se puede ver que no hay "ruido"

$$\text{y } P_{\max} = N$$

