


Redes Recurrentes

- No hay una organización jerárquica de los neuronas
- Todos los neuronas pueden procesar información en todas las etapas
- Los neuronas son del tipo McCulloch and Pitts
- Pueden loops e incluso puede haber intercambios recíprocos entre los neuronas



- La red tiene N neuronas

¿ a cada una le asignamos una variable $S_i(t)$. El estado de la red es un vector de N componentes



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

• Tenemos una matriz de acoplamiento sináptico

$$W = \begin{pmatrix} W_{11} & W_{12} & \dots & W_{1N} \\ W_{21} & W_{22} & & W_{2N} \\ & & & \\ & & & W_{NN} \end{pmatrix}$$

• la red debe asociar estados iniciales $\vec{S}(t=0)$ con estados finales $\vec{S}(t=\infty)$

• $S(t=\infty)$ puede ser un punto fijo, una oscilación periódica, o un atractor caótico



La red cambia de estado cuando actualizo una vez cada neurona.

Δt : es el tiempo en que actualizo N neuronas

Vamos a suponer que

$$S_i(t) = \begin{cases} +1 & \text{si dispara} \\ -1 & \text{si no dispara} \end{cases}$$

Como son neuronas McCulloch & Pitts

- calcula


$$h_i(t) = \sum_{j=1}^N w_{ij} S_j(t)$$

- Compara $h_i(t)$ con el umbral θ

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


$W_{ij} > 0$	excitatoria	} simples
$W_{ij} = 0$	neutra	
$W_{ij} < 0$	inhibidora	


Son especialmente útiles para memoria asociativa.



La red tiene 2^N posibles estados.

Los estados se pueden representar como en hiper cubo





Memoria asociativa

De entre los 2^N posibles configuraciones \vec{z} de la red, queremos elegir P configuraciones $\left\{ \vec{z}_i^k \right\}_{i=1, \dots, N}^{k=1, \dots, P}$ que sean atractores de la dinámica.

En concreto, buscamos la matriz W y los umbrales θ_i que lo logren.

$$\vec{\Sigma}^1 = (\Sigma_1^1, \Sigma_2^1, \dots, \Sigma_N^1)$$

Si $S(t) = \vec{\Sigma}^1$, quiero que se quede

$$\text{allí } \Sigma_i^1 = \pm 1 \quad \forall i$$

lo mismo para M

$$\vec{\Sigma}^M = (\Sigma_1^M, \Sigma_2^M, \dots, \Sigma_N^M)$$

$$\exists \Sigma_i^M = \pm 1 \quad \forall i \text{ y } \forall M.$$

En 1982 un físico norteamericano propuso el problema y dio una solución. Se llamó John Hopfield.

El modelo de Hopfield

Tenemos N neuronas $S_i = \pm 1$

Tenemos N umbrales nulos $\Theta_i = 0 \quad \forall i$

Tenemos una matriz $W_{N,N}$ simétrica

$$W_{ij} = W_{ji}$$

con diagonal nula

$$W_{ii} = 0 \quad \forall i$$

- la actualización es recurrente,
• sea, actualiza una por una

$$S_i(t + \Delta t) = \text{signo} \left(\sum_{j \neq i} W_{ij} S_j(t) \right)$$

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

Case 1 . Tempo $P=1$ y además,

$$\sum_i^1 = +1 \quad \forall i$$

Entonces puedo hacer $W_{ij} = 1 \quad \forall i \neq j$
 $W_{ii} = 0 \quad \forall i$


$$S_i(t + \Delta t) = \text{signo} \left(\sum_{j \neq i} 1 S_j(t) \right) \leftarrow$$

Si en t la mayoría son $+1$

$$S_i(t+\Delta t) = 1$$

Si en t la mayoría son -1

$$S_i(t+\Delta t) = -1$$



• Caso 2 $P=1$ pero \sum_i^1 es una configuración aleatoria

$$\sum_i^1 = \begin{cases} +1 & \text{con prob. } +\frac{1}{2} \\ -1 & \text{" " } +\frac{1}{2} \end{cases}$$

$$\boxed{\begin{aligned} W_{ij} &= \frac{\sum_i^1 \sum_j^1}{N} \\ W_{ii} &= 0 \end{aligned}}$$

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

Supongamos que en n neuronas no coincide $S(0)$ con \sum_i^1 y en $N-n$

s_i coinciden

$$S_i(t+\Delta t) = \text{sgno} \left(\sum_i' \frac{1}{2} \sum_{j \neq i}^N \sum_j' s_j(0) \right) \\ = \text{sgno} \left(\sum_i' \frac{1}{2} \left[-n + [N-1-n] \right] \right)$$

Suponemos $N \gg 1$

$$= \text{sgno}(\sum_i') \text{sgno}\left(\frac{1}{2}\right) \cdot \text{sgno}[N-2n] \\ = \text{sgno}(\sum_i') \text{sgno}[N-2n]$$

si $n > \frac{1}{2}N$

$$S_i(t+\Delta t) = -\text{sgno}(\sum_i') = -\sum_i'$$

$n < \frac{1}{2}N$

$$S_i(t+\Delta t) = \text{sgno}(\sum_i') = \sum_i'$$

Morente: $w_{ij} = \frac{1}{2} \sum_i' \sum_j'$

hace 2 estructuras: \sum_i' y $-\sum_i'$

le red le da a una conf. inicial

al atrechoz más parecido

Caso 3: se puede ver que si
quiero tener los atrechos
aleatorios $\vec{\Sigma}^1$ y $\vec{\Sigma}^2$ puedo usar

$$W_{ij} = \frac{\Sigma_i^1 \Sigma_j^1 + \Sigma_i^2 \Sigma_j^2}{2}$$

Para tener 4 atrechos

$$\vec{\Sigma}^1, -\vec{\Sigma}^1, \vec{\Sigma}^2, -\vec{\Sigma}^2$$

- Es una regla local y hebbiana
- Supuro que si tenemos p
configuraciones debemos hacer

$$W_{ij} = \frac{1}{2} (\Sigma_i^1 \Sigma_j^1 + \Sigma_i^2 \Sigma_j^2 + \dots + \Sigma_i^p \Sigma_j^p)$$

$$W_{ij} = \frac{1}{2} \sum_{k=1}^p \Sigma_i^k \Sigma_j^k$$

$$W_{ii} = 0$$

Regla
de
Hopfield


Una forma canónica de verber esto es la siguiente.

$$d = \frac{1}{N} \sum_i^N \frac{(S_i - \bar{S})^2}{4}$$

Para cada $\mu=1, \dots, P$ calculámonos las distancias

$$d^\mu = \frac{1}{N} \sum_i^N \frac{(S_i(\mu) - \bar{S}_i^\mu)^2}{4}$$

y buscámonos $\bar{S}(\mu)$ en el μ tal que d^μ sea mínimo.



híper cubo
de los
 2^N posibles
estados

Análisis de estabilidad

Supongamos que $S(0) = \sum_j^v$
 el estado inicial es la memoria \sum_j^v

\sum_j^v : memoria v

$$h_i^{(v)} = \sum_j \omega_{ij} S(0) = \sum_j \omega_{ij} \sum_j^v$$

$$= \sum_j \left[\frac{1}{2} \sum_{\mu=1}^p \sum_{i'} \omega_{i'j}^{\mu} \sum_{j'} \omega_{ij'}^{\mu} \right] \sum_j^v$$

$$= \frac{1}{2} \sum_{\mu=1}^p \sum_{i'} \omega_{i'j}^{\mu} \sum_{j'} \omega_{ij'}^{\mu} \sum_j^v$$

$$= \frac{1}{2} \left[\sum_{i'} \omega_{i'j}^v \left(\sum_{j'} \omega_{ij'}^v + \sum_{\mu \neq v} \sum_{j'} \omega_{ij'}^{\mu} \right) \right] \sum_j^v$$

$$h_i^{(v)} = \frac{1}{2} \left[2 \sum_{i'} \omega_{i'j}^v + \sum_{\mu \neq v} \sum_{i'} \omega_{i'j}^{\mu} \sum_{j'} \omega_{ij'}^{\mu} \right] \sum_j^v$$

$$h_i^{(Y)} = \sum_i^v + \frac{1}{N} \sum_{\substack{\mu \neq v \\ p-1 \\ \text{termes}}} \sum_{\substack{j=1 \\ j \neq i \\ N-1 \\ \text{termes}}} \sum_i^{\mu} \sum_j^{\mu} \sum_j^v \pm 1$$

$$\begin{aligned} S_i &= \text{signo} (h_i^{(v)}) = \text{signo} \left(\sum_i^v + \frac{1}{N} \sum_{\mu \neq v} \sum_{j \neq i} \sum_i^{\mu} \sum_j^{\mu} \sum_j^v \right) \\ &= \text{signo} \left(\sum_i^v \left[1 + \frac{\sum_i^v}{N} \sum_{\mu \neq v} \sum_{j \neq i} \sum_i^{\mu} \sum_j^{\mu} \sum_j^v \right] \right) \\ &= \text{signo} \left(\sum_i^v (1 + C_i^v) \right) \end{aligned}$$

$$C_i^v = \frac{1}{N} \sum_{\mu \neq v} \sum_{j \neq i} \sum_i^{\mu} \sum_j^{\mu} \sum_j^v$$

la distrib. de prob. tende a una normal de medie 0 e

de varianze $\sigma = \frac{1}{N} \sqrt{(N-1)(P-1)}$

si $N \gg 1$ e $P \gg 1$


$$\sigma \approx \frac{1}{N} \sqrt{NP} = \sqrt{\frac{P}{N}}$$

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

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

Para que no desestabilice la neurona i

$$C_i^v < -1$$




Prob. = prob. de desestabilizacion

Queremos calcular la probabilidad de que una neurona se desestabilice

$$P_{\text{error}} = P(C_i^v < -1) = P(C_i^v > +1) \quad \text{for symmetric}$$

$$P_{\text{error}} = \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{x^2}{2\sigma^2}} dx$$

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



$$= 1 - \frac{1}{2} - \int_0^1 \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{x^2}{2\sigma^2}} dx$$

$$u^2 = \frac{x^2}{2\sigma^2} \quad du = \frac{dx}{\sqrt{2\sigma^2}}$$

$$P_{\text{error}} = \frac{1}{2} - \int_0^{\frac{1}{\sqrt{2\sigma^2}}} e^{-u^2} \frac{du}{\sqrt{\pi}}$$

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

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

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

Dado un error fijo, o una tolerancia
Perror puede indagarse cual debería
ser el nivel máximo de $\frac{P}{N}$.

Si fijo N, estoy indagando Pmax

Perror	Pmax
0.001	$0.105 * N$
0.01	$0.185 * N$
0.05	$0.37 * N$
0.1	$0.61 * N$

Una forma más rigurosa es preguntarse
por la estabilidad de los N

$$\text{Pido } (1 - \text{Perror})^N > 0.99$$

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


$$\text{Si } P_{\text{error}} \ll 1$$

$$(1 - P_{\text{error}})^N \approx 1 - N P_{\text{error}}$$

hacer la cuenta





$$P_{\text{max}} = \frac{N}{2 \ln N}$$



Otra cuenta posible es pedir que los ϕ sean estables

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



```

for t:=1 to tmax
  for i:=1 to N
    h:=0
    for j:=1 to N
      h:=h+W[i,j]*S[j]
    end
    if h > 0 then
      S[i]:=+1
    else
      S[i]:=-1
    end
  end
end

```

puedo chequear si llego a punto (j)

end

$$m^k = \frac{1}{N} \sum_{i=1}^N \sum_{t=1}^k S_i(t)$$

$$-1 \leq m^k \leq 1$$

$$d^k = \frac{1}{4N} \sum (S_i^k - S_i(t=\infty))^2$$

$$= \frac{1}{2} \sum_i (\xi_i^2 - 2 \xi_i^{\mu} S(t=0) + S(t=0)^2)$$

$$= \frac{1}{2} \sum_i (1 - \xi_i^{\mu} S(t=\infty))$$

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