


REDES NEURONALES RECURRENTE

Toda red que permite que la información viaje en dos sentidos, es una red recurrente. Esto puede lograrse con

loops:



retornos:




autointeracciones:



Ya hemos visto la red Hopfield (1982) que digamos, permite almacenar información holísticamente en la red, y la recupera por asociación. Hay cientos de modificaciones sobre el modelo de Hopfield.

Seguiremos ahora con las llamadas Máquinas de Boltzmann, que son redes neuronales probabilísticas.

MAQUINA DE BOLTZMANN (Hinton 1983)



- neuronas visibles
- neuronas invisibles

Los acoplamientos entre las neuronas, cuando existen, son bidireccionales y simétricos:

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

NEURONAS ESTOCASTICAS

$S_i = +1$ la neurona dispara

$S_i = -1$ la neurona está en reposo

la dinámica es similar a la de Hopfield

$$\text{Prob}(S_i(t+\Delta t)=+1) = g(h_i) = g\left(\sum_j w_{ij} S_j(t)\right)$$

$$\text{Prob}(S_i(t+\Delta t)=-1) = 1 - g(h_i)$$

$$h_i(t) = \sum_j w_{ij} S_j(t)$$

$$\beta \equiv \frac{1}{T}$$

$$g(h) = \frac{1}{1 + e^{-2\beta h}}$$

T: medida del ruido

Por ser los acoplamientos simétricos, el sistema tiene una función de Lyapunov que cumple que, si $T=0$, esta función solo decrece o se mantiene en el tiempo a medida que avanza el tiempo.

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

El sistema, a un dado valor de T , recorre las 2^N posibles configuraciones con probabilidad

$$P\{s_i(t)\} = \frac{e^{-\beta H(\{s_i\})}}{Z}$$

$$Z = \sum_{\{s_i\}}^{2^N} e^{-\beta H(\{s_i\})}$$

Con esta probabilidad podemos calcular promedios de cualquier cantidad que depende de $\{s_i\}$

$$\langle X \rangle = \sum_{\{s_i\}}^{2^N} P(\{s_i\}) X(\{s_i\})$$

¿Qué hace esta red? Nos concentramos en las neuronas visibles solamente, a las que denominamos s_i^α . A las ocultas las llamamos s_j^β .

La red tiene que recorrer las posibles configuraciones de forma tal que las neuronas visibles recorran sus subestados con cierta probabilidad.

Si tenemos 2 neuronas visibles tenemos 4 estados

	S_1^α	S_2^α	Prob
$\alpha=1$	+1	+1	$0.6 = R_1$
$\alpha=2$	+1	-1	$0.1 = R_2$
$\alpha=3$	-1	+1	$0.1 = R_3$
$\alpha=4$	-1	-1	$0.2 = R_4$

$2^2 = 4$

$$P_\alpha = \sum_{\beta} P_{\alpha\beta} = \sum_{\beta} \frac{e^{-\beta H_{\alpha\beta}}}{Z}$$

$$Z = \sum_{\alpha\beta} e^{-\beta H_{\alpha\beta}}$$

$$H_{\alpha\beta} = -\frac{1}{2} \sum_i \sum_j w_{ij} S_i^{\alpha\beta} S_j^{\alpha\beta}$$

$$E = \sum_{\alpha} R_{\alpha} \ln\left(\frac{R_{\alpha}}{R_{\beta}}\right)$$

R_{α} : probabilidad de $\{S_{\alpha}\}$ deseada

$$W_{ij}^{\text{nuevo}} = W_{ij}^{\text{anterior}} + \Delta W_{ij}$$

$$= W_{ij}^{\text{anterior}} - \eta \frac{\partial E}{\partial W_{ij}}$$

$$= W_{ij}^{\text{anterior}} + \eta \sum_{\alpha} \left(\frac{R_{\alpha}}{P_{\alpha}}\right) \left(\frac{\partial P_{\alpha}}{\partial W_{ij}}\right)$$

$$\frac{\partial P_{\alpha}}{\partial W_{ij}} = \frac{\beta \sum_{\beta} e^{-\beta H_{\alpha\beta}} S_i^{\alpha\beta} S_j^{\alpha\beta}}{Z} - \frac{\left(\sum_{\beta} e^{-\beta H_{\alpha\beta}}\right) \beta \sum_{\lambda\mu} e^{-\beta H_{\lambda\mu}} S_i^{\lambda\mu} S_j^{\lambda\mu}}{Z}$$

$$= \beta \left(\sum_{\beta} S_i^{\alpha\beta} S_j^{\alpha\beta} P_{\alpha\beta} - P_{\alpha} \langle S_i S_j \rangle \right)$$

$$\Delta W_{ij} = \eta \beta \left[\sum_{\alpha} \frac{R_{\alpha}}{P_{\alpha}} \sum_{\beta} S_i^{\alpha\beta} S_j^{\alpha\beta} P_{\alpha\beta} - \sum_{\alpha} R_{\alpha} \langle S_i S_j \rangle \right]$$

$$= \eta \beta \left[\sum_{\alpha \beta} R_{\alpha} P_{\beta | \alpha} S_i^{\alpha \beta} S_j^{\alpha \beta} - \sum_{\alpha} R_{\alpha} \langle S_i S_j \rangle \right]$$

$$= \eta \beta \left[\langle S_i S_j \rangle_{\text{clamped}} - \langle S_i S_j \rangle_{\text{libres}} \right]$$

$$\Delta w_{ij} = \eta \beta \left[\overline{\langle S_i S_j \rangle}_{\text{sujetados}} - \langle S_i S_j \rangle_{\text{libres}} \right]$$

$$\overline{\langle S_i S_j \rangle}_{\text{sujetados}} = \sum_{\alpha \beta} R_{\alpha} P_{\beta | \alpha} S_i^{\alpha \beta} S_j^{\alpha \beta}$$

he red ajusta todos los complementos de la red, que sigue la distribución de Maxwell-Boltzmann, de forma tal que las neuronas visibles recorren sus estados α con probabilidad R_{α} .

Esto es una red generativa, pues genera configuraciones con probabilidades dadas.

Para deep learning se usan redes de Boltzmann restringidas (RBM).

Note: esto no es más que una dinámica Monte Carlo

$$\text{Prop}(S_i \rightarrow -S_i) = \frac{1}{1 + e^{\beta \Delta H_i}}$$

ΔH_i : cambio en H al invertir S_i

Es lento pero poderoso. Se usa simulated annealing (templado simulado) o simulated annealing optimizado (móquina de Cauchy).


o En el nivel más alto, debemos actualizar cada peso muchas veces para que converja, calculando en una simulación Monte Carlo $\langle S_i S_j \rangle_{\text{sujetos}}$ y $\langle S_i S_j \rangle_{\text{libres}}$.

o luego variamos T , descendiendo lentamente

o congelamos las sinapsis.

MÁQUINA DE BOLTZMANN RESTRINGIDA

$$E(v, h) = - \sum a_i(v_i) - \sum b_\mu(h_\mu) - \sum_{i\mu} W_{i\mu} v_i h_\mu$$



Capa
Bernoulli

$$a_i(v_i) = \begin{cases} a_i v_i & \text{si } v_i \in \{0, 1\} \text{ binario} \\ \frac{v_i^2}{2\sigma_i^2} & \text{si } v_i \in \mathbb{R} \end{cases}$$

Capa
gaussiana

$$b_\mu(h_\mu) = \begin{cases} b_\mu h_\mu & h_\mu \in \{0, 1\} \\ \frac{h_\mu^2}{2\sigma_\mu^2} & h_\mu \in \mathbb{R} \end{cases}$$