

N-HANNA

Neocortical Artificial Neural Network Architecture



Alejandro Barrera García-Orea

Madrid, 12 junio de 2007

- ✓ **Introducción**
- ✓ **Dinámica neuronal**
- ✓ **Implementación**
- ✓ **Resultados**
- ✓ **Conclusiones**



INTRODUCCIÓN

I. INTRODUCCIÓN (I)

- ✓ Problemas con los **IDS** actuales
- ✓ Dos enfoques a la detección
 - misuse detection*
 - anomaly detection*
- ✓ Problemas con las **redes neuronales**

I. INTRODUCCIÓN (II)

- ✓ Enfoque neuronal distinto
- ✓ Neocortex, minicolumnas y macrocolumnas



I. INTRODUCCIÓN (III)

✓ **Beneficios**

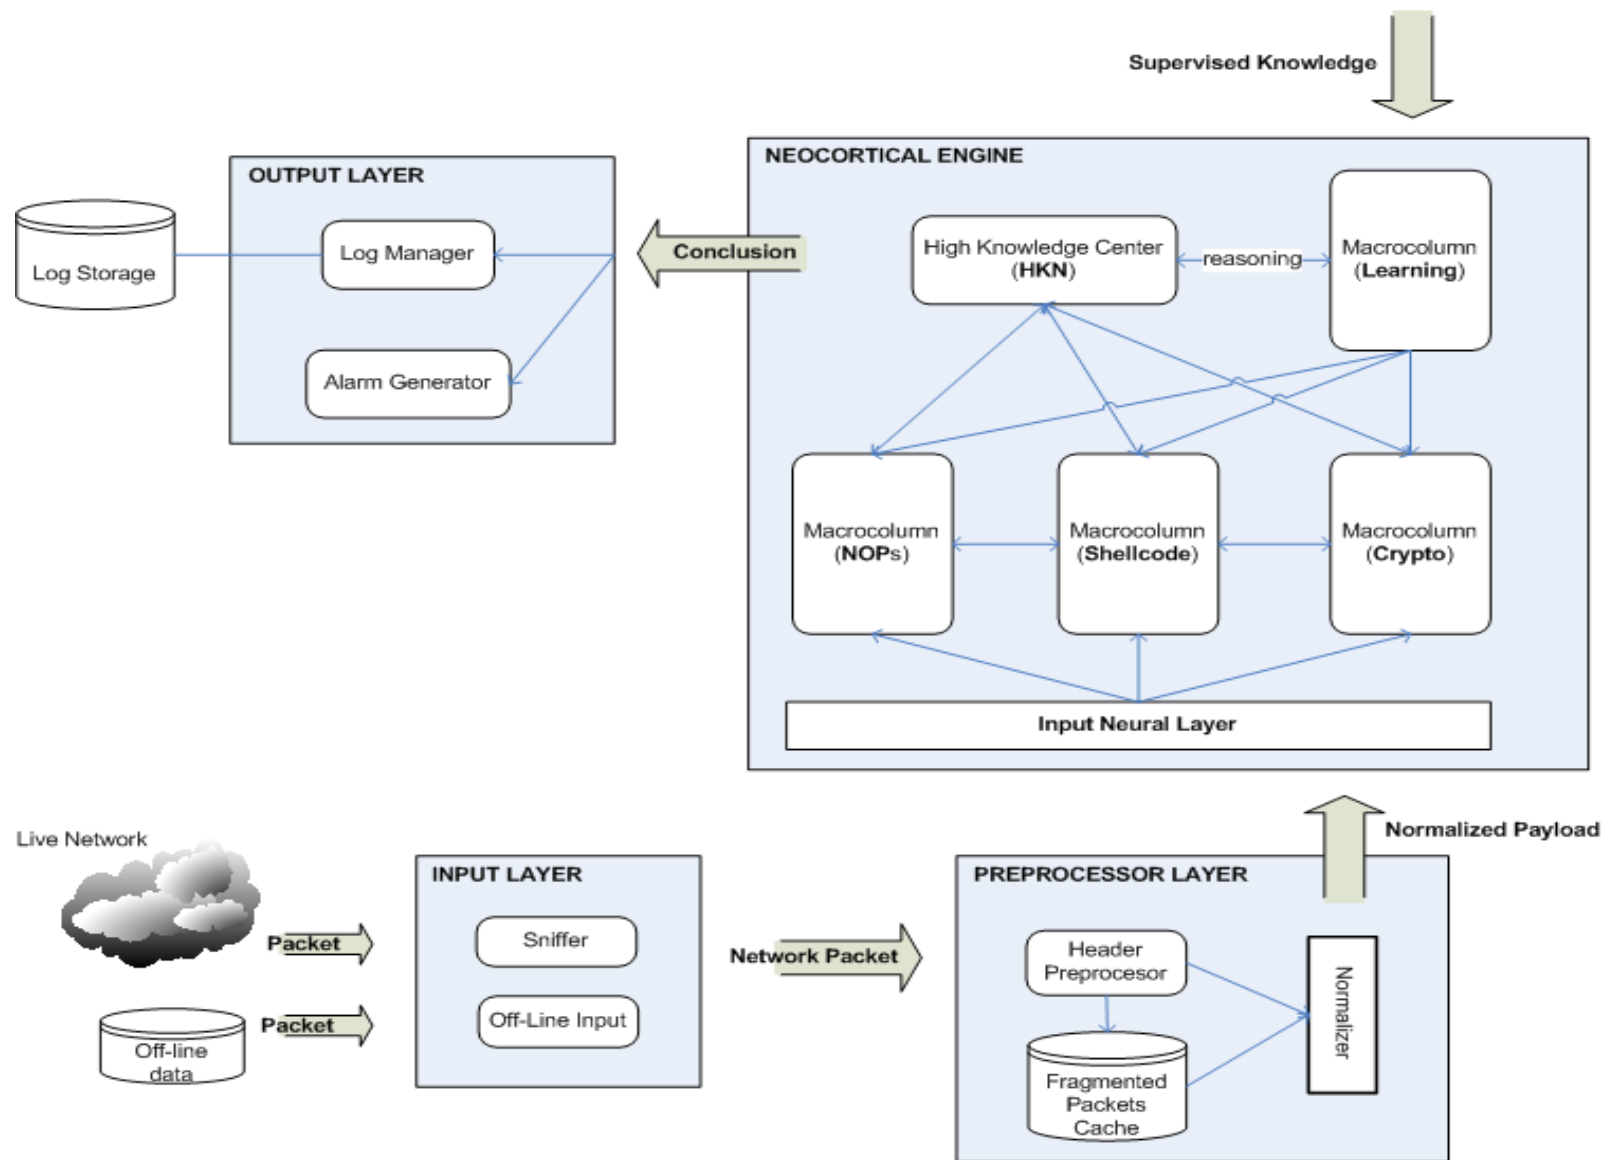
No supervisado

Rápida convergencia

Gran generalización

Jerárquico

I. INTRODUCCIÓN (IV)




DINÁMICA NEURONAL


II. DINÁMICA NEURONAL (I)

- ✓ Basado en los trabajos de Jörg Lücke
- ✓ Múltiples minicolumnas

MINICOLUMNA 1




MINICOLUMNA 2



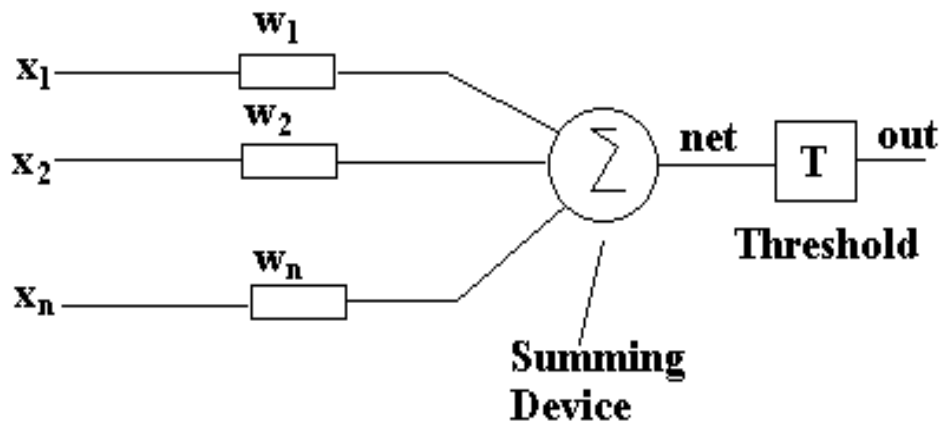
....

MINICOLUMNA N

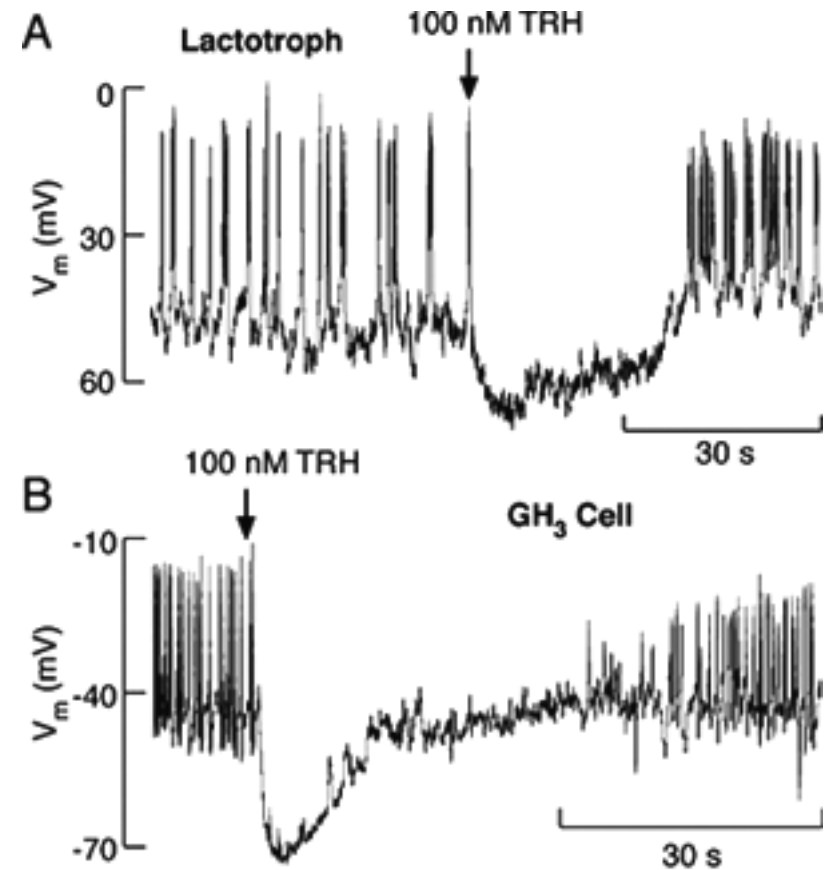


II. DINÁMICA NEURONAL (II)

✓ Dinámica de la neurona



✓ Estados de la neurona



Fuente: Biol. Res. [online]. 2006, vol.39, no.3

II. DINÁMICA NEURONAL (III)

✓ Dinámica de la neurona

Estado actual neurona j-ésima

Función umbral

Función de activación

$$n_i(t+1) = \mathcal{H}\left(\sum_{j=1}^m T_{ij}n_j(t) - \theta(t)\right) \cdot \underbrace{\mathcal{H}(1 - n_i(t))}_{\text{refractoriedad}}, \quad \mathcal{H}(x) = \begin{cases} 0 & \text{si } x \leq 0 \\ 1 & \text{si } x > 0 \end{cases} \quad (1)$$


Nuevo estado neurona i-ésima

Peso sináptico

Estado actual neurona i-ésima

II. DINÁMICA NEURONAL (IV)

✓ Inhibición lateral



II. DINÁMICA NEURONAL (V)

✓ Función umbral

Factor proporcionalidad inhibitoria

$$\theta(t) = v \frac{1}{m} \sum_{i=1}^m n_i(t) + \theta_0 + \theta_{\text{ruido}} = vp(t) + \theta_0 + \theta_{\text{ruido}}$$

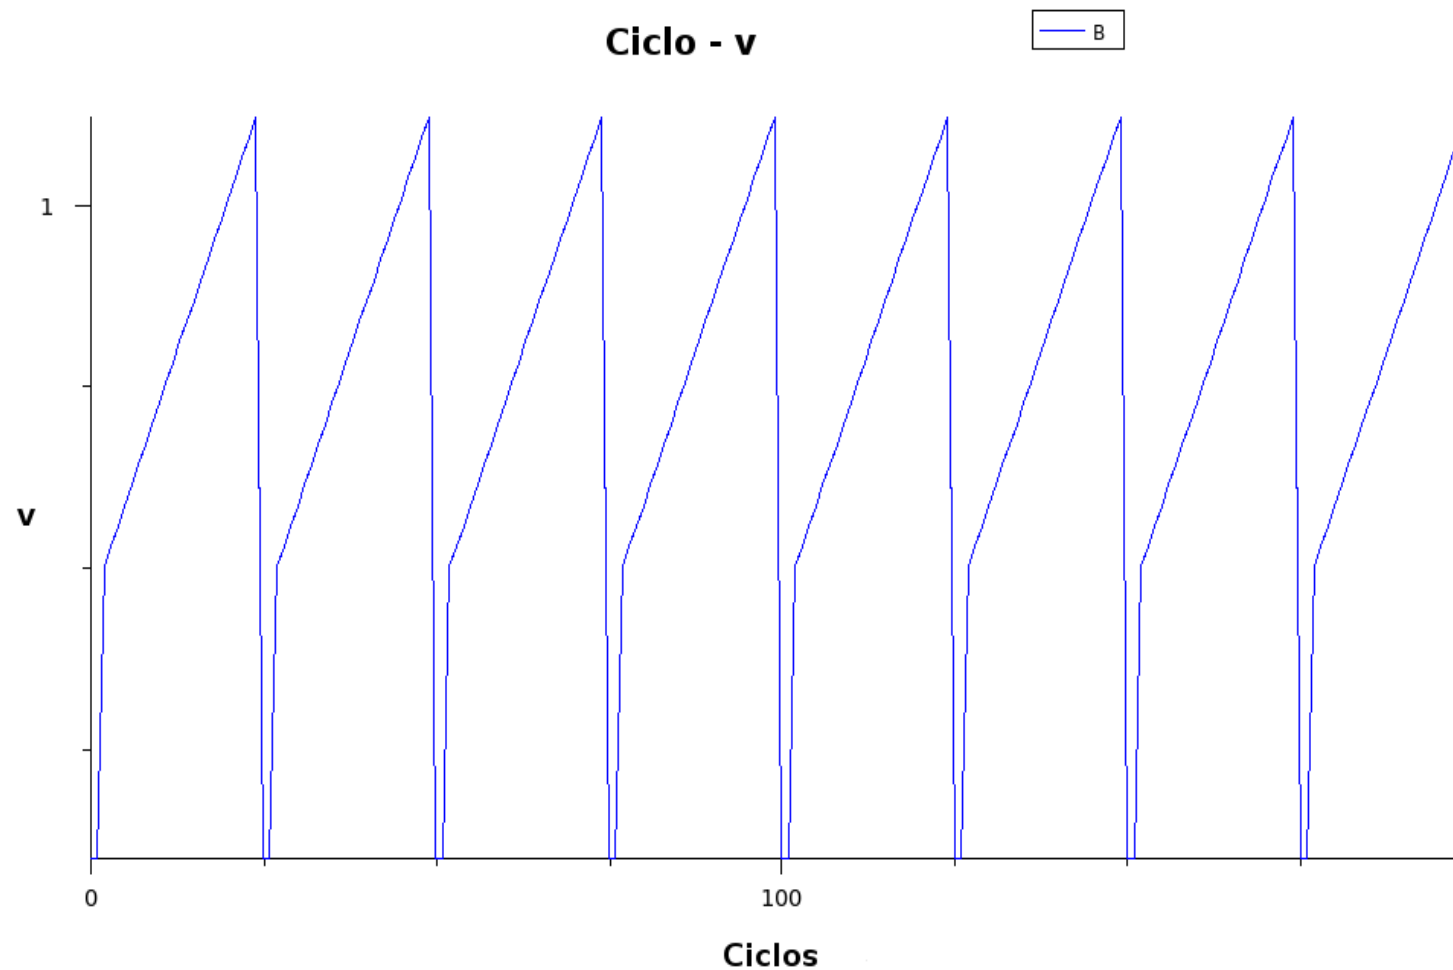
Umbral constante Ruido del umbral

neuronas por minicolumna Estado actual neurona i-ésima

(2)

II. DINÁMICA NEURONAL (VI)

✓ *v-cycles* (ciclos-v)



II. DINÁMICA NEURONAL (VII)

✓ Dinámica de la macro columna

Estado actual neurona j -ésima de la **minicolumna alfa**

$$n_i(t+1)^\alpha = \mathcal{H}\left(\sum_{j=1}^m T_{ij}^\alpha n_j^\alpha(t) - \theta(t)\right) \cdot \underbrace{\mathcal{H}(1 - n_i^\alpha(t))}_{\text{refractoriedad}},$$

Nuevo estado neurona i -ésima de la **minicolumna alfa**

Función umbral

Función de activación

$$\mathcal{H}(x) = \begin{cases} 0 & \text{si } x \leq 0 \\ 1 & \text{si } x > 0 \end{cases} \quad (4)$$

Peso sináptico de la sinapsis de la **minicolumna alfa**

Estado actual neurona i -ésima de la **minicolumna alfa**

II. DINÁMICA NEURONAL (VIII)

✓ Dinámica de la macrocolumna

Factor proporcionalidad inhibitoria

Función umbral

Ruido del umbral

$$\theta(t) = \mathcal{I}(t) + \theta_0 + \theta_{ruido} = v \max_{\beta=1, \dots, k} \{p_{\beta}(t)\} + \theta_0 + \theta_{ruido} \quad (5)$$

k minicolumnas por macrocolumna

Máxima actividad de la macrocolumna

Umbral constante

II. DINÁMICA NEURONAL (IX)

✓ Entradas del sistema

Capa de neuronas de entrada (Receptive Field)

j ● ● ● ● ● ● ● ● N neuronas


R_{ij}

$r = 3$

i


Minicolumna

m neuronas



II. DINÁMICA NEURONAL (X)

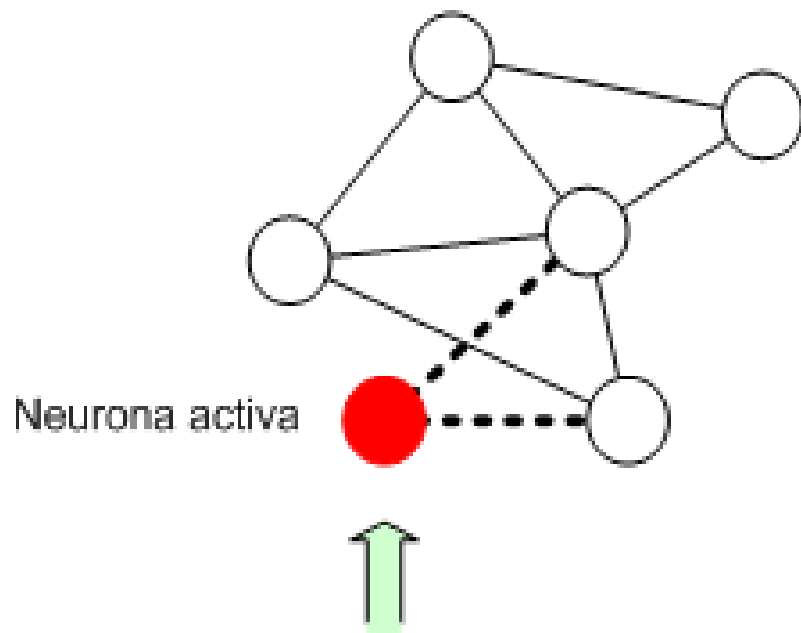
✓ Entradas del sistema



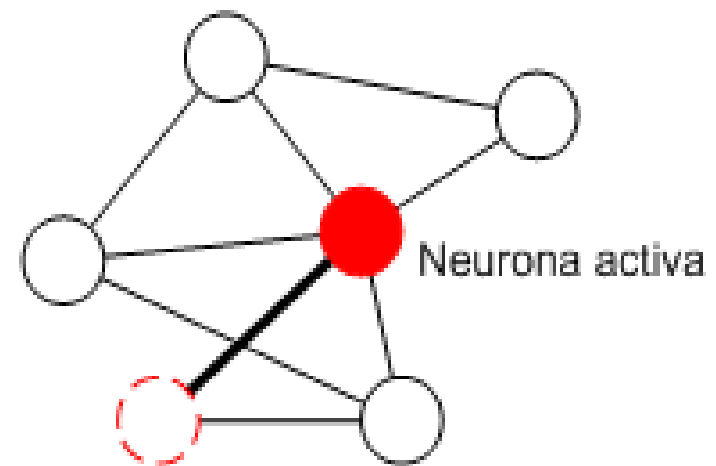
II. DINÁMICA NEURONAL (XI)

- ✓ **Algoritmo de aprendizaje**
Regla de aprendizaje de *Hebb*

Iteración t

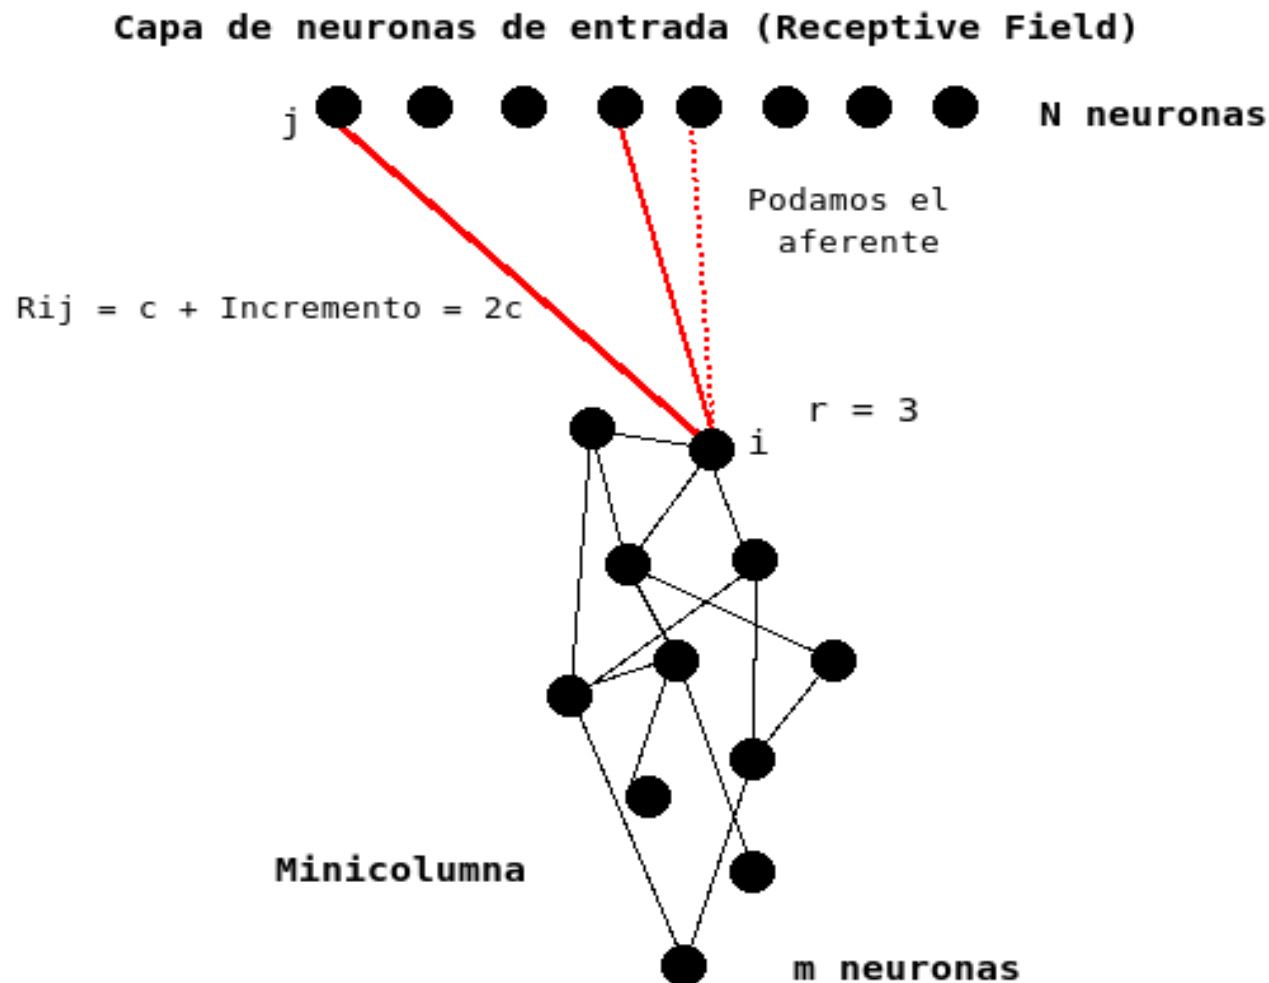


Iteración $t + 1$



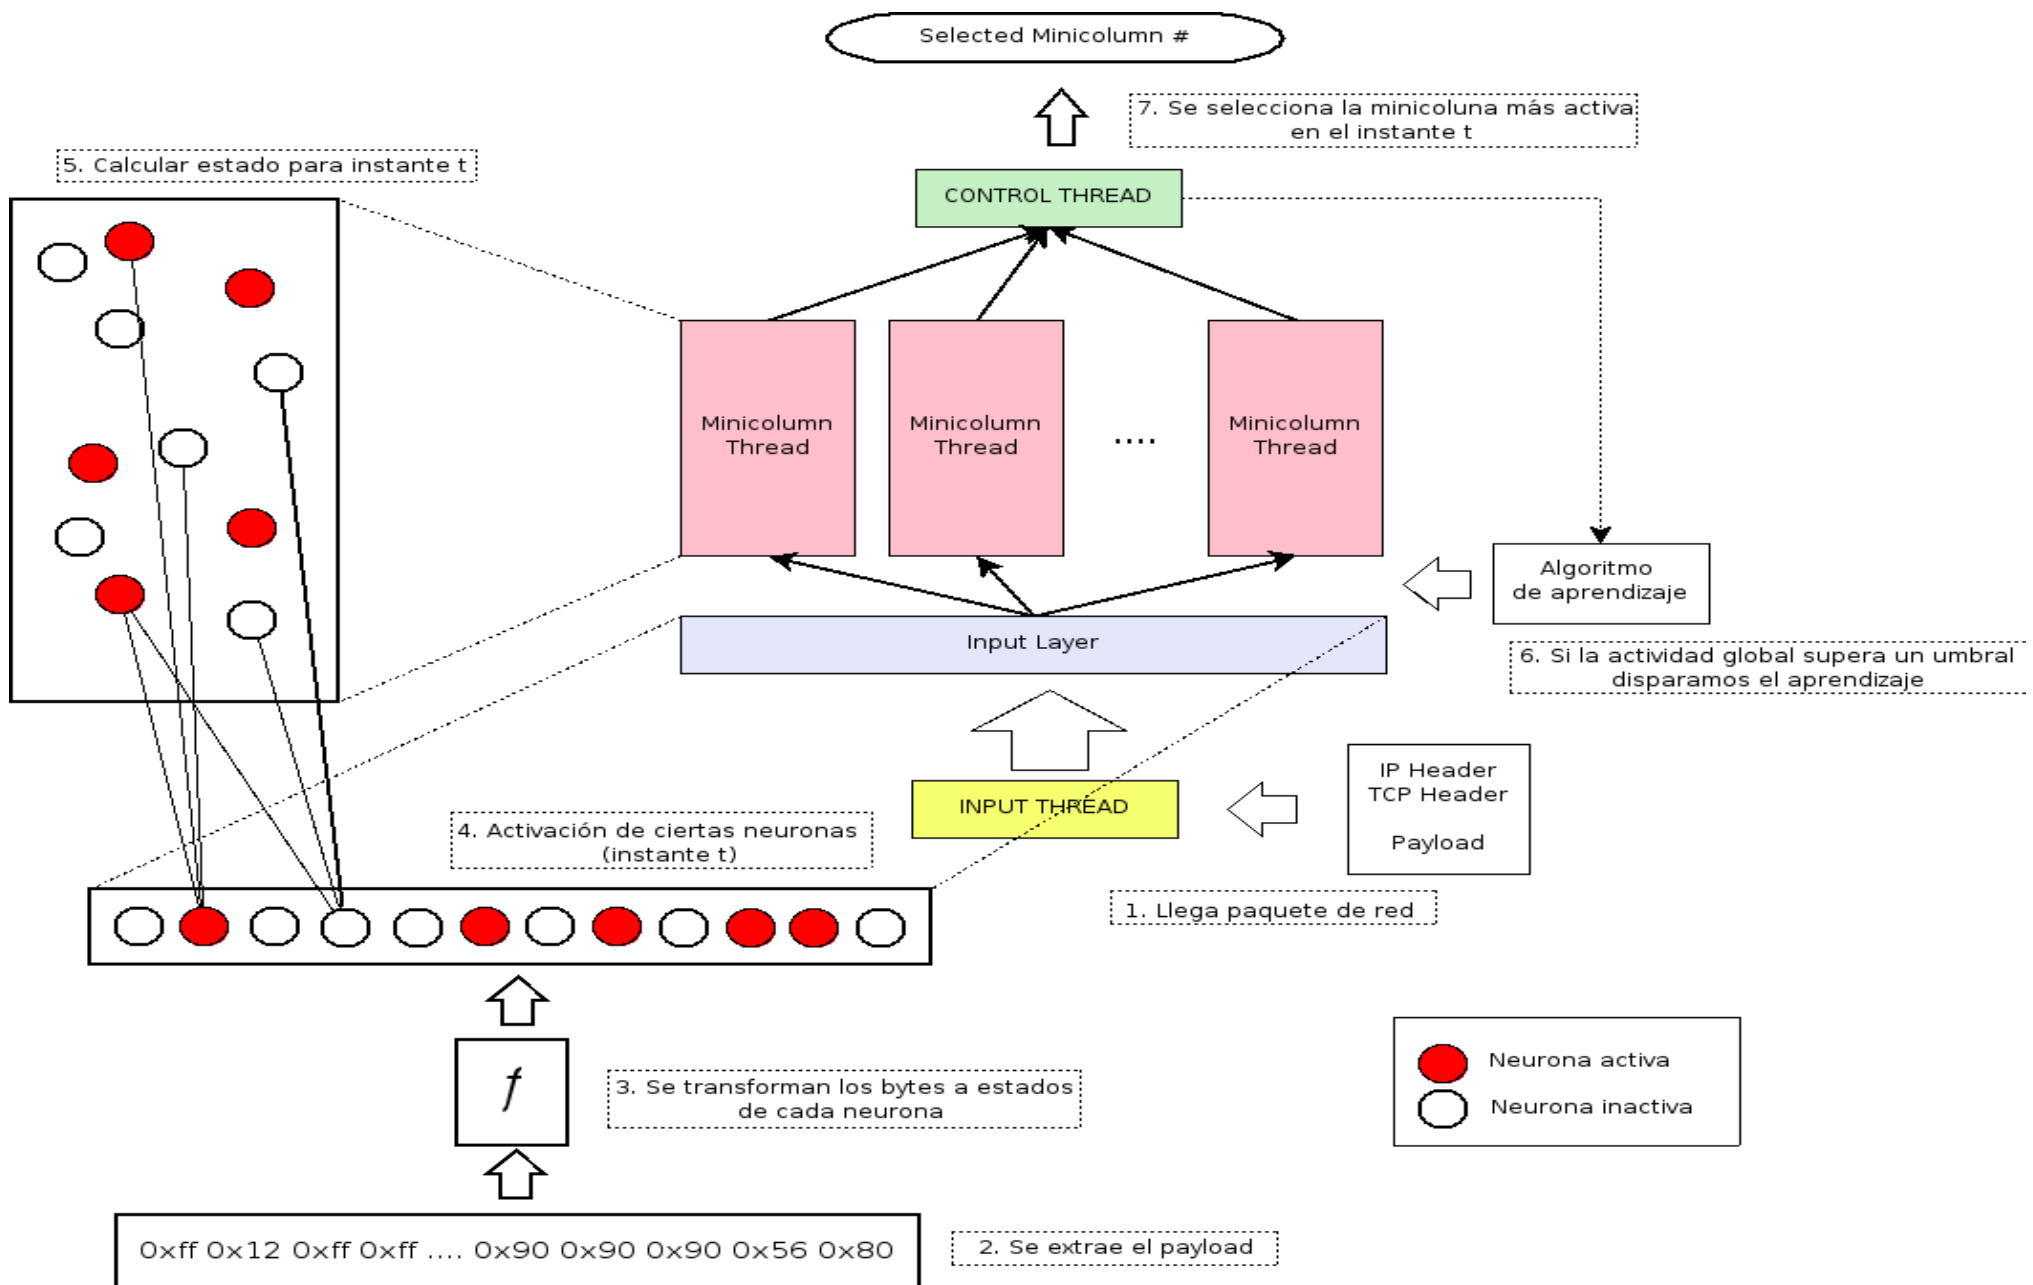
II. DINÁMICA NEURONAL (XII)

✓ Algoritmo de aprendizaje




IMPLEMENTACIÓN

III. IMPLEMENTACIÓN (I)




RESU LTAD OS

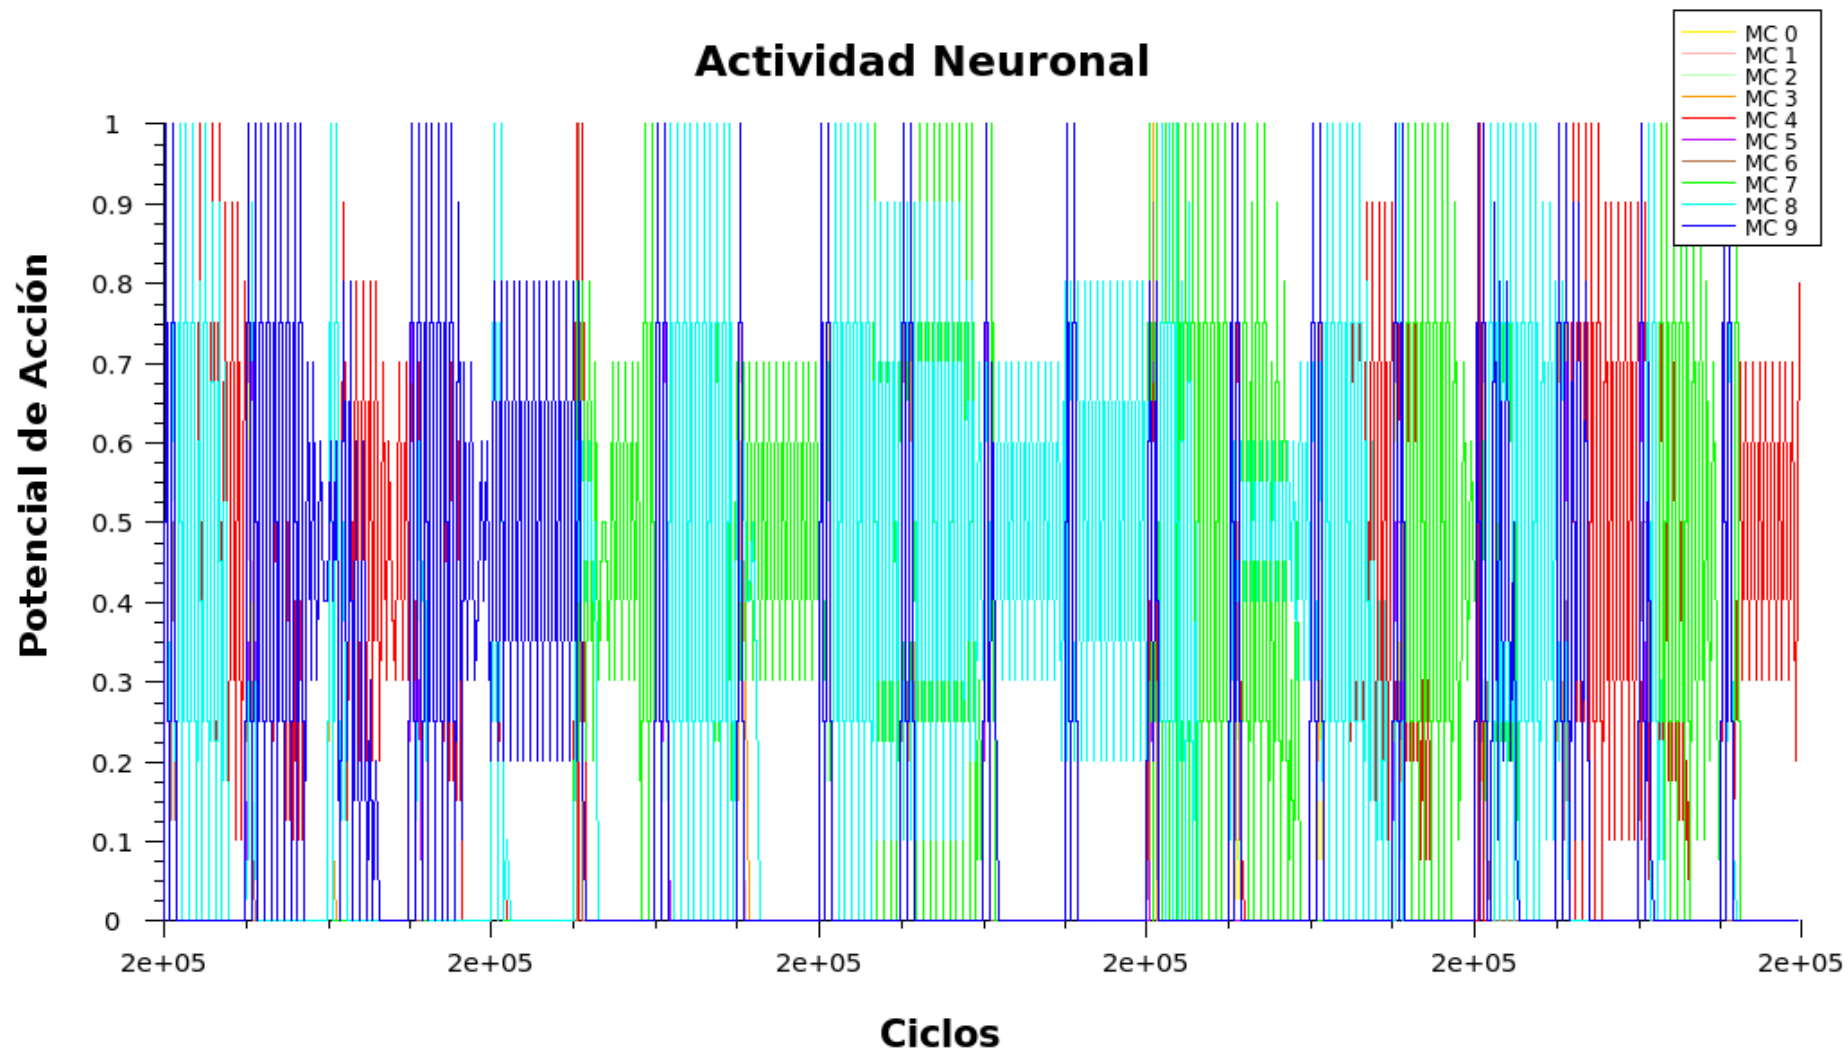
IV. RESULTADOS (I)



IV. RESULTADOS (II)



IV. RESULTADOS (III)



IV. RESULTADOS (IV)

- ✓ 20000 ciclos
- ✓ LRate = 0.002
- ✓ 10 minicolumnas
- ✓ 10 neuronas / minico l.
- ✓ 256 neuronas entrada
- ✓ 5 patrones aleatorios

patrón	iteración				
\$\$\$	199500	0	mc	4	2.100000
+++	199525	0	mc	9	2.300000
\$\$\$	199550	0	mc	4	2.400000
+++	199575	0	mc	9	2.300000
+++	199600	0	mc	9	2.200000
###	199625	0	mc	7	2.700000
***	199650	0	mc	8	3.600000
###	199675	0	mc	7	2.700000
---	199700	0	mc	8	3.900000
---	199725	0	mc	8	5.000000
***	199750	0	mc	8	2.200000
***	199775	0	mc	8	2.800000
###	199800	0	mc	7	3.000000
---	199825	0	mc	8	3.100000
\$\$\$	199850	0	mc	4	2.900000
###	199875	0	mc	7	1.900000
---	199900	0	mc	8	2.000000
\$\$\$	199925	0	mc	4	2.100000
###	199950	0	mc	7	2.100000
\$\$\$	199975	0	mc	4	2.300000

minicolumna ganadora

actividad neuronal

IV. RESULTADOS (V)

- ✓ 20000 ciclos
- ✓ LRate = 0.0048
- ✓ 10 minicolumnas
- ✓ 10 neuronas / minico l.
- ✓ 300 neuronas entrada
- ✓ 5 shells reales

Vector	Ensayo 1: Minicols	Ensayo 2: Minicols	Ensayo 3: Minicols
vector 1	0, 1, 4	1, 4	1, 3
vector 2	4	0, 3	0, 2, 4
vector 3	0, 2, 4	4	0
vector 4	0, 2, 3	0, 1	3, 1, 0
vector 5	3	0, 4	2, 3

Cuadro 15: Clasificación de los patrones de entrenamiento en minicolumnas, $LRate = 0,0048$.

Vector	Ensayo 1: Minicolumnas
vector 1	1, 2
vector 2	1, 4
vector 3	0, 1
vector 4	0
vector 5	0, 4

Idem. LRate = 0.005

IV. RESULTADOS (VI)

Vector	Entrenamiento
vector 1	0, 4
vector 2	0, 3
vector 3	2
vector 4	0, 3
vector 5	0

Cuadro 17: Clasificación de los patrones de entrenamiento

Vector	Prueba
vector 1	1, 2
vector 2	1
vector 3	1
vector 4	1, 4
vector 5	1
vector 6	1
vector 7	0, 1, 4
vector 8	4

Cuadro 18: Clasificación de los patrones de prueba

CONCLUSIONS

V. CONCLUSIONES

- ✓ Novedoso, plausible y **rápido**
- ✓ Estados binarios insuficientes
- ✓ **Escalable**
- ✓ Necesaria una **jerarquía**
- ✓ Aprendizaje no supervisado
- ✓ **Generalización robusta**

¡MUCHAS GRACIAS!

Dudas y preguntas

Alejandro Barre ra García -Orea
abarrera@neurosecurity.com
Madrid, 12 de junio de 2007