



# **REDES NEURONALES CON PESOS FUNCIONALES GENERADOS MEDIANTE PUERTA (GG-FWNN)**

Aníbal R. Figueiras-Vidal  
G2PI-DTSC-UCIIIM


---



## ÍNDICE

1. DECISIÓN MÁQUINA
2. CONJUNTOS
3. COMITÉS
4. MEZCLAS DE EXPERTOS
5. GG-FWNN
6. MEJORAS Y EXTENSIONES
7. UNA NOTA SOBRE FUSIÓN H-M

# 1. DECISION MÁQUINA



Máquina: información

$$\begin{cases} \mathbf{x}^{(k)}, t^{(k)} \\ \mathbf{x}^{(k)}, (t^{(k)}) \end{cases}$$

(supervisión)  
(semisupervisión)

Propósitos: explicativo (Occam)

predictivo (“No free lunch”)



## 2. CONJUNTOS

(Occam vs. Epicuro)

Ventajas:

- potencia expresiva a menor coste de diseño
- eventualmente, mejor interpretabilidad

Familias:

- comités : aprendices y fusión separados
- cooperativos : aprendices y fusión simultáneos
  - “boosting” (y NCL)
  - MoE



### 3. COMITÉS

Aprendices: “diversidad”  arquitectura  
 aprendizaje: datos  
variables  
inicialización  
algoritmo  
...  
(extremo: expertos regionales) (también diseños cooperativos)

Fusión: fija (promedio) / entrenable (comb. lineal)  
global (anteriores) / local (mayoría; puerta)

...

Ejs. importantes:  “bagging” (aprendices con “bootstrap”)  
 (“wagging”, etc.)  
 RF (variables y datos)  
(se basan en aprendices inestables)

(RF: pierden inteligibilidad; paralelas a Inteligencia Colectiva...  
¡mal pensada!) (fusión puerta)



---

## 4. MEZCLAS DE EXPERTOS (1)

### A. Regresión

Se supone

$$p(s | \mathbf{x}) = \sum_m g_m(\mathbf{x}) G\left(s | \mathbf{w}_{me}^T \mathbf{x}_e, v_m\right)$$


$$\Rightarrow E\{s | \mathbf{x}\} = \sum_m g_m(\mathbf{x}) \mathbf{w}_{me}^T \mathbf{x}_e$$

Si  $\{g_m(\mathbf{x})\}$  sencillas, entrenamiento ML directo / EM

(subir capacidad expresiva: jerárquicos)

## 4. MEZCLAS DE EXPERTOS (2)

### Arquitectura





---

## 4. MEZCLAS DE EXPERTOS (3)

### A. Entrenamiento directo

$$\text{Con } g_m(\mathbf{x}) = \frac{\exp(\mathbf{w}_{gme}^T \mathbf{x}_e)}{\sum_{m'} \exp(\mathbf{w}_{gm'e}^T \mathbf{x}_e)} = \frac{\exp[y_{gm}(\mathbf{x})]}{\sum_{m'}}$$

$$L(\{\mathbf{w}_{me}\}, \{\mathbf{w}_{gme}\}) = \ln \sum_{m'} g_{m'} \frac{1}{\sqrt{v_{m'}}} \exp \left[ -\frac{1}{2} \frac{(s - o_{m'})^2}{v_{m'}} \right] + \text{cte}$$

$$\frac{\partial L}{\partial o_m} = \frac{g_m \frac{1}{\sqrt{v_m}} \exp \left[ -\frac{1}{2} \frac{(s - o_m)^2}{v_m} \right]}{\sum_{m'} v_m} \frac{s - o_m}{v_m} = h_m(\mathbf{x}) \frac{s - o_m}{v_m}$$

(  $h_m$  : “pertenencia” a  $m$  )



## 4. MEZCLAS DE EXPERTOS (4)

$$\frac{\partial L}{\partial \mathbf{w}_{me}} = \frac{\partial L}{\partial o_m} \frac{\partial o_m}{\partial \mathbf{w}_{me}} = -h_m \frac{s - o_m}{v_m} \mathbf{x}_e, \quad y \text{ LMS}$$

---

$$L = \ln \sum_{m'} (\exp y_{gm'}) \frac{1}{\sqrt{v_{m'}}} \exp \left[ -\frac{1}{2} \frac{(s - o_{m'})^2}{v_{m'}} \right] - \ln \sum_{m'} \exp(y_{gm'})$$

$$\frac{\partial L}{\partial y_{gm}} = \frac{\exp(y_{gm}) \frac{1}{\sqrt{v_m}} \exp \left[ -\frac{1}{2} \frac{(s - o_m)^2}{v_m} \right]}{\sum_{m'} \exp(y_{gm'})} - \frac{\exp(y_{gm})}{\sum_{m'} \exp(y_{gm'})} = h_m - g_m$$

$$\frac{\partial L}{\partial \mathbf{w}_{gme}} = \frac{\partial L}{\partial y_{gm}} \frac{\partial y_{gm}}{\partial \mathbf{w}_{gme}} = (h_m - g_m) \mathbf{x}_e, \quad y \text{ LMS}$$



---

## 4. MEZCLAS DE EXPERTOS (5)

En cuanto a  $v_m$ ,

$$\frac{\partial L}{\partial v_m} = \frac{g_m \left\{ -\frac{1}{2} v_m^{-3/2} \exp \left[ -\frac{1}{2} \frac{(s - o_m)^2}{v_m} \right] + \frac{1}{\sqrt{v_m}} \exp \left[ -\frac{1}{2} \frac{(s - o_m)^2}{v_m} \right] \frac{1}{2} \frac{(s - o_m)^2}{v_m^2} \right\}}{\sum_{m'} h_m \frac{1}{2 v_m^{3/2}} \left[ \frac{(s - o_m)^2}{v_m} - 1 \right]} , \text{ y LMS}$$

o actualización directa

---

También se puede utilizar EM.

Se generaliza fácilmente para jerárquicos.



---

## 4. MEZCLAS DE EXPERTOS (6)

### B. Entrenamiento EM

#### B.1. Versión general

Se introducen los indicadores  $\{z_m(x)\}$  y la ddp completa

$$p(s, z|x) = \prod_m [g_m(x)p_m(s|x)]^{z_m(x)}$$

La log L es

$$L(w_{\text{tot}}, z|x_e) = \sum_m z_m(x) [\ln g_m(x) + \ln p_m(s|x)]$$

muestralmente

$$L_K(w_{\text{tot}}, \{z^{(n)}\}) = \sum_n \sum_m z_m^{(n)} (\ln g_m^{(n)} + \ln p_m^{(n)})$$



## 4. MEZCLAS DE EXPERTOS (7)

\* Paso E:

$$Q(\mathbf{w}_{\text{tot}}, \mathbf{w}_{\text{tot}}[r]) = E_z \left\{ L_K \left( \mathbf{w}_{\text{tot}}, \{\mathbf{z}^{(n)}\} \mid \mathbf{w}_{\text{tot}}[r] \right) \right\} = \\ = \sum_n \sum_m E \left\{ z_m^{(n)} \mid s^{(n)}, \mathbf{x}^{(n)}, \mathbf{w}_{\text{tot}}[r] \right\} (\ln g_m^{(n)} + \ln p_m^{(n)})$$

y como

$$E \left\{ \cdot \right\} = \Pr \left\{ z_m^{(n)} = 1 \mid s^{(n)}, \mathbf{x}^{(n)}, \mathbf{w}_{\text{tot}}[r] \right\} = \frac{p(z_m^{(n)} = 1, s^{(n)} \mid \mathbf{x}^{(n)}, \mathbf{w}_{\text{tot}}[r])}{p(s^{(n)} \mid \mathbf{x}^{(n)}, \mathbf{w}_{\text{tot}}[r])} = \\ = \frac{p(s^{(n)} \mid z_m^{(n)} = 1, \mathbf{x}^{(n)}, \mathbf{w}_{\text{tot}}[r]) \Pr(z_m^{(n)} = 1 \mid \mathbf{x}^{(n)}, \mathbf{w}_{\text{tot}}[r])}{p(s^{(n)} \mid \mathbf{x}^{(n)}, \mathbf{w}_{\text{tot}}[r])} = \\ = \frac{p_m(s^{(n)} \mid \mathbf{x}^{(n)}, \mathbf{w}_{\text{tot}}[r]) g_m^{(n)}}{\sum_{m'} p_{m'}(s^{(n)} \mid \mathbf{x}^{(n)}, \mathbf{w}_{\text{tot}}[r]) g_{m'}^{(n)}} = h_m^{(n)}(\mathbf{w}_{\text{tot}}[r])$$

resulta

$$Q(\mathbf{w}_{\text{tot}}, \mathbf{w}_{\text{tot}}[r]) = \sum_n \sum_m h_m^{(n)}(\mathbf{w}_{\text{tot}}[r]) (\ln g_m^{(n)} + \ln p_m^{(n)})$$



## 4. MEZCLAS DE EXPERTOS (8)

\* Paso M

$$\begin{aligned}\mathbf{w}_{\text{tot}}[r+1] &= \arg \max_{\mathbf{w}_{\text{tot}}} Q(\mathbf{w}_{\text{tot}}, \mathbf{w}_{\text{tot}}[r]) = \\ &= \arg \max_{\mathbf{w}_{\text{tot}}} \sum_n \sum_m h_m^{(n)}[r] (\ln g_m^n + \ln p_m^{(n)})\end{aligned}$$

separable en dos grupos:

$$\{\mathbf{w}_{\text{gme}}[r+1]\} = \arg \max_{\mathbf{w}_{\text{gme}}} \sum_n \sum_m h_m^{(n)}[r] (\mathbf{w}_{\text{me}}[r], \mathbf{w}_{\text{gme}}[r]) \ln g_m^{(n)}(\{\mathbf{w}_{\text{gme}}\}), \quad 1 \leq m \leq M$$

y las ecuaciones desacopladas:

$$\{\mathbf{w}_{\text{me}}[r+1]\} = \arg \max_{\mathbf{w}_{\text{me}}} \sum_n h_m^{(n)}(\mathbf{w}_{\text{me}}[r], \mathbf{w}_{\text{gme}}[r]) \ln p_m(s^{(n)} | x^{(n)}, \mathbf{w}_{\text{me}}), \quad 1 \leq m \leq M$$

sobre lo que hay que aplicar búsqueda (gradiente estocástico: GME)



## 4. MEZCLAS DE EXPERTOS (9)

### B.2. Caso gaussiano

Si  $\{p_m\}$  son gaussianas

$$\frac{\partial \ln \exp \left[ - (s - \mathbf{w}_{me}^T \mathbf{x}_e)^2 / 2v_m \right]}{\partial \mathbf{w}_{me}} = - \frac{s - \mathbf{w}_{me}^T \mathbf{x}_e}{v_m} \mathbf{x}_e$$

y para las ecuaciones del segundo grupo se tiene

$$\sum_n h_m^{(n)} [r] (s^n - \mathbf{w}_{me}^T \mathbf{x}_e^{(n)}) \mathbf{x}_e^{(n)} = \mathbf{0} , \quad 1 \leq m \leq M$$

sistema de  $D+1$  ecs. con  $D+1$  incógnitas.

$\{v_m\}$  se pueden ajustar según lo ya visto.

Para las ecuaciones del primer grupo, como

$$\frac{\partial \ln g_{m'}}{\partial \mathbf{w}_{gme}} = \frac{\partial \left( \ln \exp o_{gm'} - \ln \sum_{m''} \exp (o_{gm''}) \right)}{\partial \mathbf{w}_{gme}} = \left( \delta_{mm'} - \frac{\exp o_m}{\sum_{m''} \exp o_{m''}} \right) \mathbf{x}_e = (\delta_{mm'} - g_m) \mathbf{x}_e$$



---

## 4. MEZCLAS DE EXPERTOS (10)

se tiene

$$\sum_n \sum_m h_{m'}^{(n)}[r] \left( \delta_{mm'} - g_m^{(n)} \right) \mathbf{x}_e^{(n)} = \mathbf{0} , \quad 1 \leq m \leq M$$

$$\sum_n \left( h_m^{(n)}[r] - g_m^{(n)} \sum_{m'} h_{m'}^{(n)}[r] \right) \mathbf{x}_e^{(n)} = \mathbf{0} , \quad 1 \leq m \leq M$$

$$\sum_n \left( h_m^{(n)}[r] - g_m^{(n)} \right) \mathbf{x}_e^{(n)} = \mathbf{0} , \quad 1 \leq m \leq M$$

siendo  $g_m^{(n)} = g_m^{(n)} \left( \{\mathbf{w}_{gme}\} \right);$

se trata de un sistema de  $M$  ecuaciones no lineales acopladas en  $\{\mathbf{w}_{gme}\}$



---

## 4. MEZCLAS DE EXPERTOS (11)

### C. Caso de clasificación

#### C.1. Método de Newton

Si  $F$  es cuadrática

$$F(\mathbf{w}) = F(\mathbf{w}_0) + \frac{\partial F}{\partial \mathbf{w}} \Big|_0 (\mathbf{w} - \mathbf{w}_0) + \frac{1}{2} (\mathbf{w} - \mathbf{w}_0)^T \frac{\partial^2 F}{\partial \mathbf{w} \partial \mathbf{w}^T} \Big|_0 (\mathbf{w} - \mathbf{w}_0)$$
$$\left( \frac{\partial F}{\partial \mathbf{w}} \Big|_0 = \text{grad } F \Big|_0 ; \frac{\partial^2 F}{\partial \mathbf{w} \partial \mathbf{w}^T} \Big|_0 = H_F \Big|_0 \right)$$



---

## 4. MEZCLAS DE EXPERTOS (12)

y si  $\mathbf{w}^*$  es el max/min

$$\left. \frac{\partial F}{\partial \mathbf{w}} \right|_* = \mathbf{0} = \left. \frac{\partial F}{\partial \mathbf{w}} \right|_0 + \left. \frac{\partial^2 F}{\partial \mathbf{w} \partial \mathbf{w}^T} \right|_0 (\mathbf{w}^* - \mathbf{w}_0)$$

de donde

$$\mathbf{w}^* = \mathbf{w}_0 - \left[ \left. \frac{\partial^2 F}{\partial \mathbf{w} \partial \mathbf{w}^T} \right|_0 \right]^{-1} \left. \frac{\partial F}{\partial \mathbf{w}} \right|_0$$

y se llega al max/min en un paso.

Si no es cuadrático pero es suave, y  $\mathbf{w}_0$  es cercano a  $\mathbf{w}^*$ , la igualdad es aproximada y basta con iterar.



---

## 4. MEZCLAS DE EXPERTOS (13)

### C.2. Algoritmo IRLS (“Iterative Reweighted Least Squares”)

Si se trata de un objetivo muestral con la forma

$$F = \sum_n F\left(\mathbf{w}_e^T \mathbf{x}_e^{(n)}\right) :$$

$$\frac{\partial F}{\partial \mathbf{w}_e} = \sum_n F'\left(\mathbf{w}_e^T \mathbf{x}_e^{(n)}\right) \mathbf{x}_e^{(n)} = \mathbf{X}_e^T \boldsymbol{\Omega} \mathbf{e} \quad ((D+1) \times 1)$$

$$\frac{\partial^2 F}{\partial \mathbf{w}_e \partial \mathbf{w}_e^T} = \sum_n F''\left(\mathbf{w}_e^T \mathbf{x}_e^{(n)}\right) \mathbf{x}_e^{(n)} \mathbf{x}_e^{(n)T} = -\mathbf{X}_e^T \boldsymbol{\Omega} \mathbf{X}_e \quad ((D+1) \times (D+1))$$



## 4. MEZCLAS DE EXPERTOS (14)

con

$$\mathbf{X}_e = \begin{bmatrix} 1 & x_1^{(1)} & \cdots & x_D^{(1)} \\ 1 & x_1^{(2)} & \cdots & x_D^{(2)} \\ \vdots & \vdots & & \vdots \\ 1 & x_1^{(N)} & \cdots & x_D^{(N)} \end{bmatrix}$$

$(N \times (D+1))$

$$\Omega = - \begin{bmatrix} F''(\mathbf{w}_e^T \mathbf{x}_e^{(1)}) & & 0 \\ & \ddots & \\ 0 & & F''(\mathbf{w}_e^T \mathbf{x}_e^{(N)}) \end{bmatrix}$$

$(N \times N)$

$$\mathbf{e} = - \begin{bmatrix} \frac{F'(\mathbf{w}_e^T \mathbf{x}_e^{(1)})}{F''(\mathbf{w}_e^T \mathbf{x}_e^{(1)})} \\ \frac{F'(\mathbf{w}_e^T \mathbf{x}_e^{(2)})}{F''(\mathbf{w}_e^T \mathbf{x}_e^{(2)})} \\ \vdots \\ \frac{F'(\mathbf{w}_e^T \mathbf{x}_e^{(N)})}{F''(\mathbf{w}_e^T \mathbf{x}_e^{(N)})} \end{bmatrix}$$

$(N \times 1)$



## 4. MEZCLAS DE EXPERTOS (15)

y las iteraciones resultan

$$\begin{aligned}\mathbf{w}_e[r+1] &= \mathbf{w}_e[r] + (\mathbf{X}_e^T \Omega[r] \mathbf{X}_e)^{-1} \mathbf{X}_e^T \Omega[r] \mathbf{e}[r] = \\ &= (\mathbf{X}_e^T \Omega[r] \mathbf{X}_e)^{-1} \mathbf{X}_e^T \Omega[r] \mathbf{X}_e \mathbf{w}_e[r] + (\mathbf{X}_e^T \Omega[r] \mathbf{X}_e)^{-1} \mathbf{X}_e^T \Omega[r] \mathbf{e}[r] = \\ &= (\mathbf{X}_e^T \Omega[r] \mathbf{X}_e)^{-1} \mathbf{X}_e^T \Omega[r] \{\mathbf{X}_e \mathbf{w}_e[r] + \mathbf{e}[r]\} = \\ &= (\mathbf{X}_e^T \Omega[r] \mathbf{X}_e)^{-1} \mathbf{X}_e^T \Omega[r] \mathbf{v}[r]\end{aligned}$$

que es el algoritmo IRLS.



---

## 4. MEZCLAS DE EXPERTOS (16)

### C.3. Forma exponencial del modelo de Bernoulli

Para una s binaria, el modelo mezcla de Bernoulli es

$$p(s|\mathbf{x}) = \sum_m g_m(\mathbf{x}) o_m^s(\mathbf{x}) [1 - o_m(\mathbf{x})]^{1-s}, 0 \leq o_m(\mathbf{x}) \leq 1 \quad (\text{prob. de 1})$$

escribiendo

$$\begin{aligned} o_m^s(1 - o_m)^{1-s} &= \exp \left\{ \ln \left[ o_m^s(1 - o_m)^{1-s} \right] \right\} = \\ &= \exp \left[ s \ln \frac{o_m}{1 - o_m} + \ln(1 - o_m) \right] = \exp[s \eta_m - \ln(1 + \exp \eta_m)] \end{aligned}$$

$$\text{con } \eta_m = \ln \frac{o_m}{1 - o_m} \Rightarrow o_m = \frac{\exp \eta_m}{1 + \exp \eta_m}$$



---

## 4. MEZCLAS DE EXPERTOS (17)

Empleando como aprendices decisores softmax lineales

$$o_m = \text{sgm}(\mathbf{w}_{me}^T \mathbf{x}_e) = \frac{\exp(\mathbf{w}_{me}^T \mathbf{x}_e)}{1 + \exp(\mathbf{w}_{me}^T \mathbf{x}_e)}$$

resulta

$$\eta_m = \ln \frac{\exp(\mathbf{w}_{me}^T \mathbf{x}_e) / [1 + \exp(\mathbf{w}_{me}^T \mathbf{x}_e)]}{1 - \exp(\mathbf{w}_{me}^T \mathbf{x}_e) / [1 + \exp(\mathbf{w}_{me}^T \mathbf{x}_e)]} = \ln [\exp(\mathbf{w}_{me}^T \mathbf{x}_e)] = \mathbf{w}_{me}^T \mathbf{x}_e$$

y:

$$p(s|\mathbf{x}) = \sum_m g_m(\mathbf{x}) \exp \left\{ s \mathbf{w}_{me}^T \mathbf{x}_e - \ln [1 + \exp(\mathbf{w}_{me}^T \mathbf{x}_e)] \right\}$$



---

## 4. MEZCLAS DE EXPERTOS (18)

### C.4. Aplicación

Yendo a las ecuaciones desacopladas para las  $\{\mathbf{w}_{me}\}$  en el EM

$$\{\mathbf{w}_{me}[r+1]\} = \arg \max_{\mathbf{w}_{me}} \sum_n h_m^{(n)}[r] \ln p_m(s^{(n)} | \mathbf{x}^{(n)}, \mathbf{w}_{me})$$

basta introducir en el IRLS para cada m la ponderación  $h_m^{(n)}[r]$  :

$$F = h_m[r] \left\{ s \mathbf{w}_{me}^T \mathbf{x}_e - \ln [1 + \exp(\mathbf{w}_{me}^T \mathbf{x}_e)] \right\}$$

$$F' = h_m[r] \left[ s - \frac{\exp(\mathbf{w}_{me}^T \mathbf{x}_e)}{1 + \exp(\mathbf{w}_{me}^T \mathbf{x}_e)} \right] = h_m[r] [s - \text{sgm}(\mathbf{w}_{me}^T \mathbf{x}_e)]$$

$$F'' = -h_m \text{sgm}(\mathbf{w}_{me}^T \mathbf{x}_e) [1 - \text{sgm}(\mathbf{w}_{me}^T \mathbf{x}_e)]$$



## 4. MEZCLAS DE EXPERTOS (19)

con lo que se tiene:

$$e_{nm} = \frac{s^{(n)} - \text{sgm}(\mathbf{w}_{me}^T \mathbf{x}_e^{(n)})}{\text{sgm}(\mathbf{w}_{me}^T \mathbf{x}_e^{(n)}) [1 - \text{sgm}(\mathbf{w}_{me}^T \mathbf{x}_e)]}$$

$$\Omega_{nm} = h_m^{(n)} [r] \text{sgm}(\mathbf{w}_{me}^T \mathbf{x}_e^{(n)}) [1 - \text{sgm}(\mathbf{w}_{me}^T \mathbf{x}_e)]$$

y se puede aplicar cómodamente el IRLS.



---


## 5. GG-FWNN (1)

Ecuaciones MoE (regresión)

$$\begin{aligned} o_T(\mathbf{x}) &= \sum_m g_m(\mathbf{x}) o_m(\mathbf{x}) = \\ &= \sum_m g_m(\mathbf{x}) \sum_d w_{dm} x_d = \\ &= \sum_d \left( \sum_m w_{dm} g_m(\mathbf{x}) \right) x_d = \\ &= \sum_d w_d(\mathbf{x}) x_d \end{aligned}$$

## 5. GG-FWNN (2)

### Arquitectura





---

## 5. GG-FWNN (3)

Reformulación:

$$\begin{aligned} o_T(\mathbf{x}) &= \sum_{d=0}^D w_d(\mathbf{x})x_d = \\ &= \sum_{d=0}^D \sum_{r=0}^R w_{dr} o_{gr}(\mathbf{x})x_d = \\ &= w_{00} + \sum_{r=m}^R w_{0r} o_{gr}(\mathbf{x}) + \sum_{d=m}^D \sum_{r=0}^R w_{dr} o_{gr}(\mathbf{x})x_d = \\ &= \sum_{s=0}^S a_s z_s(\mathbf{x}) \end{aligned}$$

$$z_s(\mathbf{x}) = o_{gr}(\mathbf{x})x_d$$

permite MM con  $\{z_s(\mathbf{x})\}$



---

## 5. GG-FWNN(4)

### Selección de centroides

#### A. Preselección (Método de Shin-Choi)

Se aplica un k-NN, con  $k$  el primer valor que exceda  $2N\hat{P}_e$ , siendo  $\hat{P}_e$  la tasa de error con un 1-NN, y se estima la probabilidad de que  $\mathbf{x}^{(n)}$  pertenezca a la clase:

$$P_j(\mathbf{x}^{(n)}) = \frac{k_j^{(n)}}{k}$$

y, a partir de ese valor, se definen

- la proximidad a la frontera

$$pf(\mathbf{x}^{(n)}) = - \sum_{j=-1,1} P_j(\mathbf{x}^{(n)}) \log_2 [P_j(\mathbf{x}^{(n)})]$$

- la corrección

$$c(\mathbf{x}^{(n)}) = P_{d^{(n)}}(\mathbf{x}^{(n)})$$

y se preseleccionan las muestras con  $pf > 0$  y  $c > 1/2$



## 5. GG-FWNN(5)

### B. Selección (Método APC-III de Hwang-Bang)

- se selecciona la muestra de mayor  $p_f$ ,
- se excluyen las muestras en una hiperesfera de radio  $h$ ,
- si quedan muestras, se itera  
( $h$  es un parámetro de diseño).



## 6. GG-FWNN(6)

Prestaciones (10x10-fold) :

	SVM	RAB	GG-FWNN 1	GG-FWNN 2	GG-FWNN 3	
aba	19.8	19.4±0.02	19.8±0.2	19.6	<b>18.9</b>	
bre	3.2	2.6±0.5	2.9±0	<b>2.1</b>	3.2	
con	29.3±1.4	29.0±0.2	<b>28.6±1.1</b>	29.7±0.8	28.8±1.2	
cra	3.8	2.5±0	3.7±0	1.2	<b>0</b>	-----
hep	14.5	8.6±1.6	13.8±2.3	<b>6.4</b>	14.5	←
ima	3.2	<b>2.5±0.04</b>	3.8±0.4	5.0	2.6	←
ion	<b>2.0</b>	4.9±0.9	3.6±0.8	5.3	5.3	←
kwo	12.1	<b>11.7±0.01</b>	11.8±0.06	12.4	12.1	
pho	<b>11.1±0.4</b>	14.0±0.07	11.9±0.4	14.7±0.4	11.8±0.5	
rip	9.6	9.7±0.01	9.6±0	9.6	<b>9.1</b>	
spa	6.3±0.7	<b>5.9±0.09</b>	6.3±0.6	6.3±0.6	6.2±0.7	
tic	1.6±0.5	<b>0.8±0.19</b>	<b>0.8±06</b>	26±0.8	22.9±4.3	←



## 5. GG - FWNN (7)

Prestaciones (25x10-fold)

	SVM	RAB	GG-FWNN 1	GG-FWNN 2	GG-FWNN 3
hep	14.5	8.6±1.6	8.2±1.0	<b>6.4</b>	12.9
ion	<b>2.0</b>	4.9±0.9	5.1±0.9	<b>2.0</b>	6.7
tic	1.7±0.3	0.8±0.19	<b>0.4±0.5</b>	1.7±0.3	1.7±0.3



---

## 6. MEJORAS Y EXTENSIONES

- \* Mejoras mediante técnicas complementarias
  - otras selecciones de centroides
  - ponderación de muestras
  - reducción / construcción de variables
- \* Mejoras mediante modificaciones
  - selección de  $\{z_s\}$
  - versiones adaptativas “on line”
  - otras técnicas constructivas
- \* Extensiones
  - regresión
  - FWNN directas




## 7. UNA NOTA SOBRE INTEGRACIÓN H-M (1)

- \* Es obvio que conviene reducir la reluctancia de los expertos
  - socialmente
  - sicológicamente: observar como un niño  
evaluar como un sabio  
actuar como un artista
- \* También es evidente que hay que mejorar la interpretabilidad de las máquinas
- \* Pero el Gran Desafío es la integración ~~versus~~ coevolución
  - (requiere: sicólogos, sociólogos, matemáticos, ingenieros... en equipo; también mucho trabajo teórico y experimental).

## 7. UNA NOTA SOBRE INTEGRACIÓN H-M (2)


- \* Primeros intentos de integración:
  - Reglas / Sistemas Expertos: dificultad de elicitación
  - Grafos para redes Bayesianas: análogo riesgo
- \* Son “aprendices diversos” => fusión



## 7. UNA NOTA SOBRE INTEGRACIÓN H-M (3)

Requisitos { personalización  
 coevolución { M adaptativa  
 M interpretable

Fusión con GG-FWNN:



## 16. UNA NOTA SOBRE INTEGRACIÓN H-M (4)

También Inteligencia Colectiva

