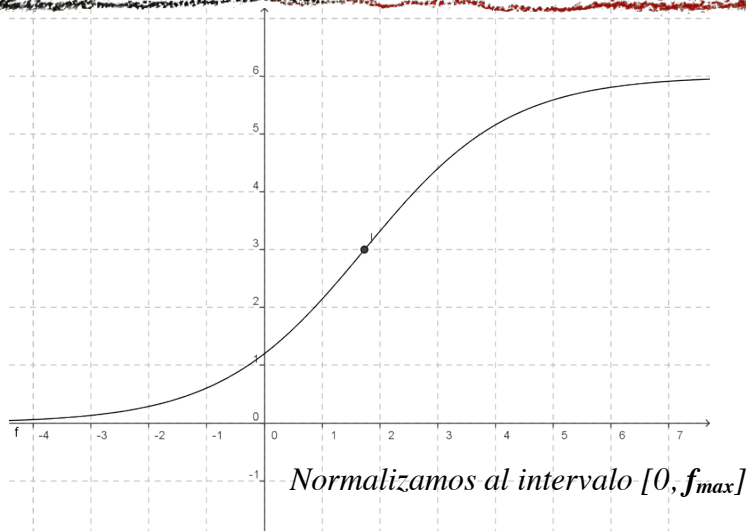


## En matemáticas

$$y = \begin{cases} 1, & \text{si } a \geq \theta, \\ 0, & \text{si } a < \theta. \end{cases} \quad \text{donde } a = \sum_{i=1}^n w_i x_i.$$

*Probar: tolerancia a errores/ruido en las entradas*

## Función sigmoideal



## Secuencias de picos


- *Frecuencia de generación de picos  $f$*
- *Varía entre cero y un máximo (fisiológico)  $f_{max}$*
- *Graduación continua del señal no es posible si usamos simplemente la codificación binaria*

## Formula

$$y = \sigma(a) \equiv \frac{1}{1 + e^{-(a-\theta)/\rho}}$$

Parámetro que determina la forma de la curva  
(menor valor, mayor pendiente)

## Linearización por partes




## Efecto de “memoria”

- *Ahora cuando se apaga la entrada, la salida sigue por un tiempo antes de tocar cero*
- *De la misma forma, al prender la entrada, la salida tarda en llegar a su nivel máximo*

## Aspecto temporal

$$\frac{da}{dt} = -\alpha a + \beta s, \text{ donde ahora } s = \sum_{i=1}^n w_i x_i$$




*Tasa de cambio instantáneo*

*Integrador con fuga*

## Equilibrio

$$a_{\text{eqm}} = \left( \frac{\beta}{\alpha} \right) s$$

## Respuesta a dos impulsos



## Espacio de patrones de entrada

- $n$  entradas,  $n$  dimensiones
- representamos las entradas como componentes de un vector

$$\mathbf{x} = (x_1, x_2, \dots, x_n)$$

## Separabilidad lineal

- En dos dimensiones, tenemos una línea  
 $w_1 x_1 + w_2 x_2 = \theta$ 
  - Esta separa las activadas de las ignoradas
  - La distancia entre un punto y la línea se mide por  $\Delta x_i$
- En  $n$  dimensiones, será un hiperplano
  - ... que hará exactamente lo mismo
  - Se llama **plano de decisión**

## Aritmética vectorial

- Sumar, restar y multiplicar por componentes

- Largo/norma:  $\|\mathbf{x}\| = \sqrt{\sum_{i=1}^n x_i^2}$

- Producto interno (escalar):

$$\mathbf{v} \cdot \mathbf{w} = \|\mathbf{v}\| \|\mathbf{w}\| \cos \phi$$

## Proyección vectorial

- *Cuánto de un vector  $\mathbf{v}$  corresponde a la dirección de otro vector  $\mathbf{w}$*

$$v_w = \frac{\mathbf{v} \cdot \mathbf{w}}{\|\mathbf{w}\|}$$

## Activación de un TLU: hiperplano

$$\begin{aligned} a &= \mathbf{w} \cdot \mathbf{x} \\ \theta &= \mathbf{w} \cdot \mathbf{x} \\ x_w &= \frac{\theta}{\|\mathbf{w}\|} \end{aligned}$$

*Ahora válido tal cual en  $n$  dimensiones.*

## Clasificación con el superficie de decisión

$$y = \begin{cases} 1, & \text{si } x_w \geq \frac{\theta}{\|\mathbf{w}\|}, \\ 0, & \text{si } x_w < \frac{\theta}{\|\mathbf{w}\|}. \end{cases}$$

## Entrenamiento supervisado

- *Propósito: determinar el superficie de decisión adecuado.*
- *Típicamente un proceso iterativo:*
  - *Se presentan ejemplos preclasificados  $\{\mathbf{x}_i\}$ .*
  - *Se realizan ajustes pequeños para acercar las respuestas a las deseadas  $\{\mathbf{t}_i\}$ .*

## Cambio notacional

- Observamos que  $w \cdot x - \theta = 0$ .
- Reescribimos  $w$  con  $n+1$  elementos, agregando  $\theta$  al final.
- Al final de  $x$  agregamos un  $-1$  constante.
- Ahora con estas modificaciones tenemos  $w \cdot x \geq 0 \Rightarrow y = 1$ , y en otro caso  $y = 0$ .

## Teorema de convergencia de perceptrón

*Si dos clases de vectores son linealmente separables, la aplicación iterativa de la regla de entrenamiento de perceptrón a estas clases eventualmente producirá un vector de ponderación  $w$  cuyo hiperplano de decisión separa las clases.*

Rosenblatt, 1962.

## Regla de entrenamiento de perceptrón

- Supongamos que hemos presentado una muestra  $v$  al TLU y nos ha producido  $y = 0$  aunque debería haber dado  $y = 1 = t$ .
- Habrá que rotar  $w$  para acercar el TLU a la clasificación deseada:
  - $w' = w + \alpha v$ ;
  - $\alpha \in (0, 1)$  es una constante que se llama la tasa de aprendizaje.
- Si ocurre lo contrario (el TLU produce  $y = 1$  aunque se esperaba que dara  $y = 0 = t$ ), rotamos en la dirección contraria:
  - $w' = w - \alpha v$ .
- Combinando esto en términos de  $t$ , obtenemos una sola regla:
  - $w' = w + \alpha(t - y)v$ .