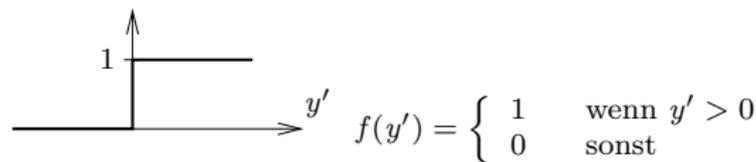
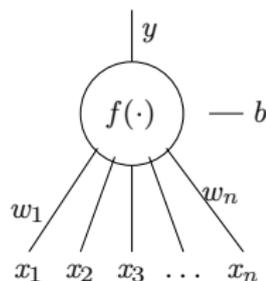


## Mustererkennung: Neuron

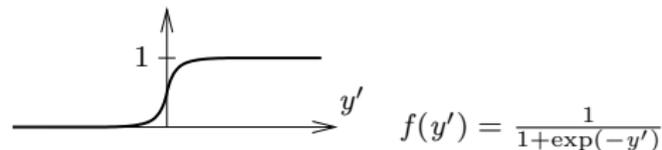
Input  $x \in \mathbb{R}^n$ , Gewichte  $w \in \mathbb{R}^n$ , Schwellwert  $b \in \mathbb{R}$ ,

Aktivierung  $y' = \sum_i w_i x_i = \langle w, x \rangle$ ,

Output  $y = f(y' - b) = f(\langle w, x \rangle - b)$

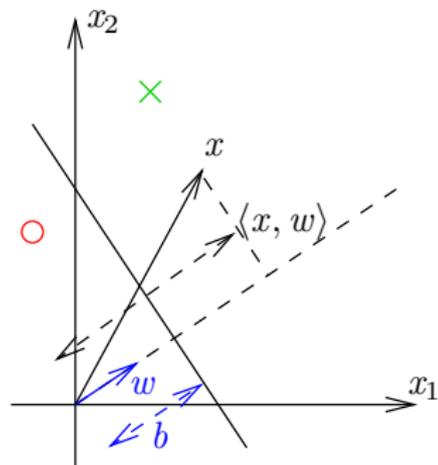


Step-Funktion



Sigmoid-Funktion (differenzierbar)

Kurz (Schwellwertneuron):  $\langle x, w \rangle \leq b$



$$\langle x, w \rangle = \|x\| \cdot \|w\| \cdot \cos \phi$$

Sei  $w$  normiert, d.h.  $\|w\| = 1$

$\Rightarrow \|x\| \cdot \cos \phi$  – Länge der Projektion von  $x$  auf  $w$

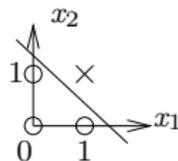
$\Rightarrow$  Trennebene  $\langle x, w \rangle = const$

Neuron realisiert einen *linearen Klassifikator*

Input:  $x = (x_1, x_2)$ ,  $x_i \in \{0, 1\}$ .

Gesucht ist das Neuron ( $w$  und  $b$ ), dass  $y = x_1 \& x_2$  realisiert.

$x_1$	$x_2$	$y$
0	0	0
0	1	0
1	0	0
1	1	1



$$w_1 = w_2 = 1, b = 1.5$$

ODER, Andere boolesche Funktionen, XOR geht nicht!!!

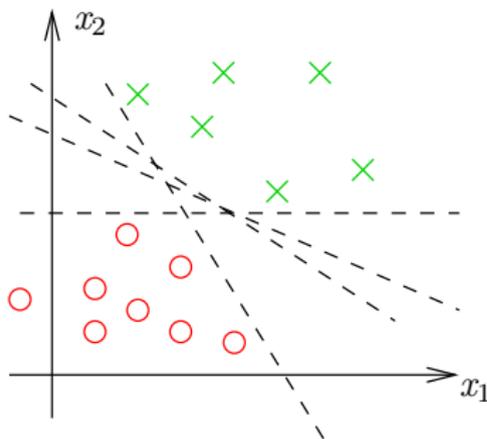
# Lernaufgabe

Gegeben: Lernstichprobe  $((x^1, y^1), (x^2, y^2), \dots, (x^L, y^L))$ ,  $x^l \in \mathbb{R}^n$ ,  $y^l \in \{0, 1\}$

Gesucht:  $w \in \mathbb{R}^n$ ,  $b \in \mathbb{R}$  so dass  $f(\langle x^l, w \rangle - b) = y^l$  für alle  $l = 1, \dots, L$

Für einen Schwellwertneuron – System linearer Ungleichungen:

$$\begin{cases} \langle x^l, w \rangle > b & \text{wenn } y^l = 1, \\ \langle x^l, w \rangle < b & \text{wenn } y^l = 0. \end{cases}$$



Es gibt (im Allgemeinen) mehrere Lösungen!!!

# „Vorbereitungen“

Vorbereitung 1:

$w$  und  $b$  zu einem Parametervektor  $\tilde{w}$ :

$$x = (x_1, x_2, \dots, x_n) \Rightarrow$$

$$\tilde{x} = (x_1, x_2, \dots, x_n, 1)$$

$$w = (w_1, w_2, \dots, w_n) \Rightarrow$$

$$\tilde{w} = (w_1, w_2, \dots, w_n, -b)$$

$\Downarrow$

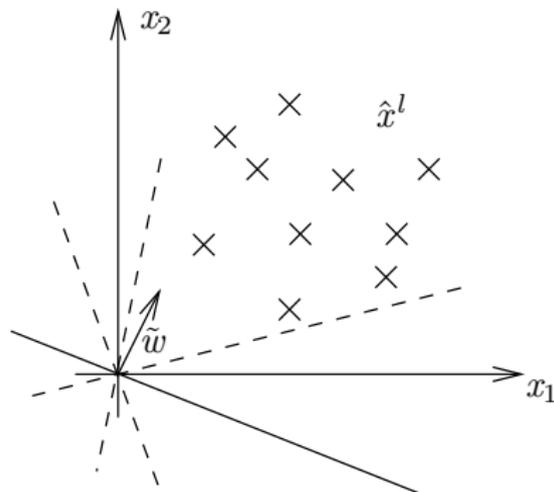
$$\langle x^l, w \rangle \geq b \Rightarrow \langle \tilde{x}^l, \tilde{w} \rangle \geq 0$$

Vorbereitung 2:

alles zum einheitlichen System:

$$\hat{x}^l = \tilde{x}^l \text{ für } l \text{ mit } y^l = 1$$

$$\hat{x}^l = -\tilde{x}^l \text{ für } l \text{ mit } y^l = 0$$



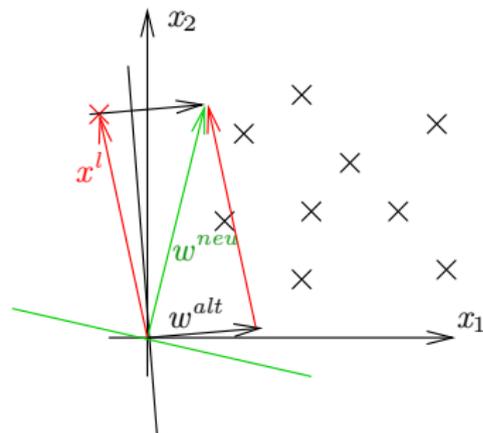
$$\begin{cases} \langle x^l, w \rangle > b & \text{wenn } y^l = 1 \\ \langle x^l, w \rangle < b & \text{wenn } y^l = 0 \end{cases} \Rightarrow \langle \hat{x}^l, \tilde{w} \rangle > 0 \quad \forall l$$

# Perzeptron Algorithmus

Algorithmus zur Lösung des Systems linearer Ungleichungen

$\langle x^l, w \rangle > 0$  für alle  $l = 1, \dots, L$ .

- 1) Suche eine noch nicht erfüllte Gleichung, d.h. ein  $l$  so dass  $\langle x^l, w \rangle \leq 0$  gilt;
- 2) Wenn nicht gefunden – Ende,  
sonst, aktualisiere  $w^{neu} = w^{alt} + x^l$ , gehe zu 1).



- Der Algorithmus terminiert, wenn eine Lösung existiert.  
Wenn keine Lösung existiert, hält er nie an.
- Die Lösung ist (bis auf eine Skalierung und unter Umständen)  
ein Punkt in der konvexen Hülle der Lernstichprobe

$$\begin{aligned}\|w^{(n+1)}\|^2 &= \|w^{(n)} + x^i\|^2 = \|w^{(n)}\|^2 + 2\langle w^{(n)}, x^i \rangle + \|x^i\|^2 \leq \|w^{(n)}\|^2 + D^2 \\ \Rightarrow \|w^{(n)}\| &\leq \sqrt{n}D \quad \text{weil } \langle w^{(n)}, x^i \rangle \leq 0 \quad (\text{nicht erfüllt})\end{aligned}$$

$$\begin{aligned}\frac{\langle w^{(n+1)}, w^* \rangle}{\|w^*\|} &= \frac{\langle w^{(n)}, w^* \rangle}{\|w^*\|} + \frac{\langle x^i, w^* \rangle}{\|w^*\|} \geq \frac{\langle w^{(n)}, w^* \rangle}{\|w^*\|} + \epsilon \\ \Rightarrow \frac{\langle w^{(n)}, w^* \rangle}{\|w^*\|} &\geq n\epsilon \quad \text{weil } \langle x^i, w^* \rangle > 0 \quad (\text{erfüllt})\end{aligned}$$

$$\begin{aligned}1 &\geq \frac{\langle w^{(n)}, w^* \rangle}{\|w^*\| \cdot \|w^{(n)}\|} \geq \sqrt{n} \frac{\epsilon}{D} \quad \text{wegen Cauchy-Schwarz Ungleichung} \\ \Rightarrow n &\leq \frac{D^2}{\epsilon^2}\end{aligned}$$

Wenn eine Lösung  $w^*$  existiert,  
konvergiert der Algorithmus nach höchstens  $D^2/\epsilon^2$  Schritten.

$$D = \max_l \|x^l\|, \quad \epsilon = \min_l \langle x^l, w^* \rangle / \|w^*\| - \text{der Margin.}$$

Entscheidungsregel für eine reelwertige Größe  $x \in \mathbb{R}$  sei ein Polynom  $k$ -tes Grades, d.h.

$$a_n x^n + a_{n-1} x^{n-1} + \dots + a_1 x + a_0 = \sum_i a_i x^i \geq 0$$

Man lerne die unbekanntenen Koeffizienten  $a_i$  des Polynoms anhand einer klassifizierten Lernstichprobe  $((x^l, y^l) \dots)$ ,  $x^l \in \mathbb{R}$ ,  $y^l \in \{0, 1\}$ .

Man überführe die Aufgabe in eine Perzeptron-Aufgabe.

Obwohl die Entscheidungsregel bezüglich  $x$  nicht mehr linear ist, ist sie immer noch linear bezüglich der Parameter  $a_i$

$\Rightarrow$  System linearer Ungleichungen

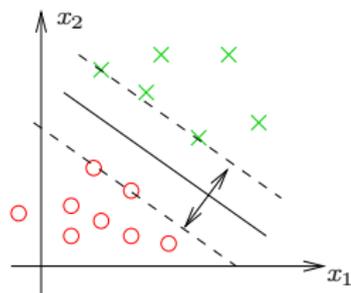
$$w = (a_n, a_{n-1}, \dots, a_1, a_0)$$

$$\tilde{x} = (x^n, x^{n-1}, \dots, x, 1) \text{ – und das für jedes } l \text{ (ein } n+1\text{-dimensionaler Vektor)}$$

$$\sum_i a_i x^i = \langle \tilde{x}, w \rangle \quad \Rightarrow \text{ Perzeptron Aufgabe.}$$

---

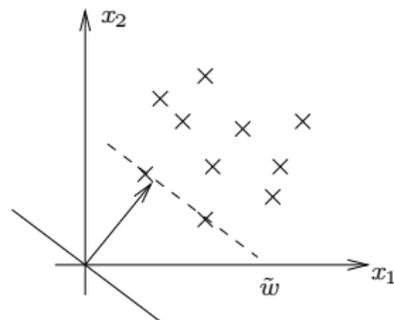
Allgemein: durch eine geeignete Transformation des Raums lassen sich viele nicht-lineare Entscheidungsregel mit dem Perzeptron Algorithmus lernen.



Es existieren mehrere Lösungen



Man suche nach einem  
„Streifen“ maximaler Breite,  
der die Lernstichprobe separiert.  
(Max-margin, large-margin training)

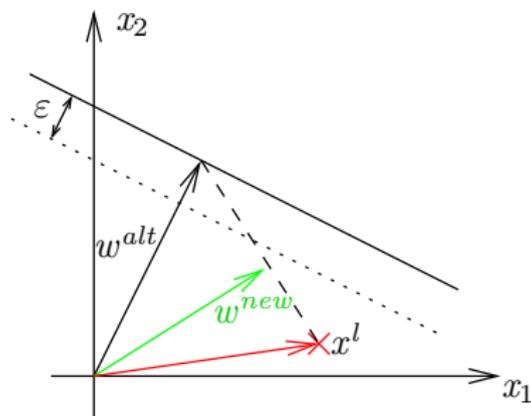


Nach „Vorbereitung 1“ und  
„Vorbereitung 2“:

$$\min_l \frac{\langle x^l, w \rangle}{\|w\|} \rightarrow \max_w$$

Vergleiche mit Perceptron

$$\min_l \frac{\langle x^l, w \rangle}{\|w\|} > 0$$



$\epsilon$ -genauer Algorithmus:

- 1 Suche ein  $x^l$  so dass  $\frac{\langle x^l, w \rangle}{\|w\|} < \|w\| - \epsilon$  gilt;
- 2 Wenn nicht gefunden – Ende.
- 3 Suche  $\gamma^* = \arg \min_{\gamma} \|w^{alt} + \gamma(x^l - w^{alt})\|^2$ ,  
aktualisiere  $w^{neu} = w^{alt} + \gamma(x^l - w^{alt})$ ,  
gehe zu 1.

Terminiert nach einer endlichen Anzahl der Schritte bei  $\epsilon > 0$   
(Beweis ähnlich dem Perzeptron Algorithmus)

Terminiert nicht unbedingt bei  $\epsilon = 0$ .