

# Inlärningens geometri

## Populärföreläsning SF1611, Introduktionskurs i matematik.

### Timo Koski

TK

22.09.2014




En grundläggande form av inlärning är att inhämta kunskap ur valda exempel. Med ett exempel avses information om ett föremål och en klassificering av detsamma. Det kan handla om t.ex. handskrivna siffor. Förmågan att igenkänna handskrivna siffror är på något sätt inbyggd i den mänskliga hjärnan, förutsatt förtrogenhet med siffrorna. En dator behöver emellertid tydliga regler för hur den skall kunna utöva igenkänningens konst.

Detta föredrag presenterar en euklidisk geometrisk modell för inlärning. Denna matematiska modell utgör grunden för många av dagens bästa högteknologiska verktyg för igenkänning med datorns hjälp.


# (Bröst)cancer eller inte ? Vävnadsprov

TVÅ KLUMPAR AV CELLER (FNA)



<sup>1</sup>malignant= elakartad, benign= välartad

# Cancer eller inte ? Mätdata



$x_1$   
 $x_2$   
.  
.  
 $x_9$

(B)

$x_1$   
 $x_2$   
.  
.  
 $x_9$

(M)



KTH Matematik

Talen  $x_1, x_2, \dots, x_9$  i vektorn  $\mathbf{x}$  representerar var sitt numeriskt givna drag hos cellklumparna: t.e.x

1. Clump thickness
2. Uniformity of cell size
3. Uniformity of cell shape
4. Marginal Adhesion
5. Single epithelial cell size
6. Bare nuclei
7. Bland chromatin
8. Normal nucleoli
9. Mitoses

$$\mathbf{x} = (x_1, x_2, \dots, x_9)$$

Vi har ett stort antal mätvektorer  $\mathbf{x}$  av vävnadsprov, d.v.s. exempel, som av experter klassificerats som fall av elakartade eller välartade klumpar av celler.

- FRÅGA: Hur kan vi få en dator att utifrån dessa exempl  
lära sig att diagnosticera (rätt) dessa och nya fall av  
bröstcancer?



Frank Rosenblatt, amerikansk forskare 1928–1969, tog fram en allmän lösning (i själva verket en maskin) på problemet (ej inskränkt på automatisk diagnos av bröstcancer), och kallade sin *inlärningsmaskin* för **perceptron**.


- Rosenblatts lösning: Datorn skall tänka i en euklidisk geometri, eller precisare sagt, hitta ett *hyperplan* som skiljer vektorerna med elakartade fall från vektorerna med välartade fall. Det är givetvis inte alltid möjligt att göra så.



Ur Wikipedia:

*In a 1958 press conference organized by the US Navy, Rosenblatt made statements about the perceptron that caused a heated controversy; based on Rosenblatt's statements, The New York Times reported the perceptron to be "**the embryo of an electronic computer that [the Navy] expects will be able to walk, talk, see, write, reproduce itself and be conscious of its existence.**"*

Hannes Alfvén, 1908–1995, professor i bl.a. plasmafysik  
vid KTH, Nobelpristagare i fysik 1970



$R^n$ : reella vektorer med  $n$  (=dimension) komponenter.

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

$R^3$  svarar mot det tredimensionella rummet som vi upplever genom sinnena. Hyperplan är ett vanligt plan i  $R^3$ .

$R^2$  är det bekanta (cartesiska) talplanet. En rät linje är ett hyperplan i  $R^2$ .




KTH Matematik

# Geometri: $\mathbf{x} = (x_1, x_2)$ som vektor

Låt

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


beteckna ett talpar (en vektor) i  $R^2$ .



KTH Matematik


# Geometri: $\mathbf{u} = (u_1, u_2)$ och $t\mathbf{u}$

$t$  är ett reellt tal,  $t\mathbf{u} = t(u_1, u_2) = (tu_1, tu_2)$ .



# Geometri: Summan av $\mathbf{u}$ och $\mathbf{v}$

$$\mathbf{u} = (u_1, u_2), \mathbf{v} = (v_1, v_2), \mathbf{u} + \mathbf{v} = (u_1 + v_1, u_2 + v_2)$$



$$\mathbf{u} = (u_1, u_2), \mathbf{v} = (v_1, v_2) ,$$

$$\mathbf{u} - \mathbf{v} = \mathbf{u} + (-1)\mathbf{v} = (u_1 - v_1, u_2 - v_2)$$



KTH Matematik

En rät linje är

$$w_2x_2 + w_1x_1 + b = 0$$

ty vi har ( $w_2 \neq 0$ )

$$x_2 = -\frac{w_1}{w_2}x_1 - \frac{b}{w_2}$$

Vi sätter

$$f(\mathbf{x}) \stackrel{\text{def}}{=} w_2x_2 + w_1x_1 + b.$$

Då definierar även

$$f(\mathbf{x}) = 0$$

en rät linje.



KTH Matematik

$$\mathbf{w} = (w_1, w_2).$$

Dotprodukten är ett tal, som ges för ett par av vektorer enligt

$$\mathbf{w} \bullet \mathbf{x} \stackrel{\text{def}}{=} w_1 x_1 + w_2 x_2$$

Då kan man skriva

$$f(\mathbf{x}) = \mathbf{w} \bullet \mathbf{x} + b.$$

Vi har även (från definitionen)  $\mathbf{w} \bullet (\mathbf{x} + \mathbf{z}) = \mathbf{w} \bullet \mathbf{x} + \mathbf{w} \bullet \mathbf{z}$ .



KTH Matematik

# Geometri: normalvektor för en rät linje

Anta att den räta linjen i planet går genom  $\mathbf{z}$  och  $\mathbf{x}$ , d.v.s.

$$f(\mathbf{z}) = \mathbf{w} \bullet \mathbf{z} + b = 0, f(\mathbf{x}) = \mathbf{w} \bullet \mathbf{x} + b = 0.$$

Då fås


$$\mathbf{w} \bullet (\mathbf{x} - \mathbf{z}) = \underbrace{\mathbf{w} \bullet \mathbf{x}}_{=-b} - \underbrace{\mathbf{w} \bullet \mathbf{z}}_{=-b} = -b + b = 0.$$

P.g.a. att  $\mathbf{w} \bullet (\mathbf{x} - \mathbf{z}) = 0$  säger vi att  $\mathbf{w}$  är **normalvektorn** till linjen  $f(\mathbf{x}) = 0$  och ortogonal mot varje vektor som ligger i  $f(\mathbf{x}) = 0$ .




KTH Matematik

# Geometri: normalvektor




# Geometri: vektorerna i $f(\mathbf{x}) = 0$ .



KTH Matematik

Vi skall nu reda ut att

vi har en **positiv sida** och en **negativ sida** av linjen  $f(x) = 0$ :



KTH Matematik

för att

om

$$\text{sign}(x) \stackrel{\text{def}}{=} \begin{cases} +1 & 0 < x, \\ -1 & x < 0 \end{cases}$$

så har vi med

$$y = \text{sign}(f(\mathbf{x}))$$

en matematisk formel för att tillordna antingen  $-1$  eller  $+1$  som etikett till  $\mathbf{x}$ , beroende på om  $\mathbf{x}$  ligger på den negativa sidan eller positiva sidan av linjen  $f(\mathbf{x}) = 0$ , resp.. Rosenblatts perceptron förverkligar denna idé, liksom skall ses.

# Hjälpmittel: längden av en vektor, avståndet mellan vektorer

**Längden** av  $\mathbf{x}$  betecknas med  $\|\mathbf{x}\|$  och definieras som

$$\|\mathbf{x}\| \stackrel{\text{def}}{=} \sqrt{\mathbf{x} \bullet \mathbf{x}} = \sqrt{x_1^2 + x_2^2}$$

- En vektor  $\mathbf{x}$  med längd  $\|\mathbf{x}\| = 1$  kallas enhetsvektor.
- $\|\alpha\mathbf{x}\| = \sqrt{\alpha\mathbf{x} \bullet \alpha\mathbf{x}} = \sqrt{\alpha^2(x_1^2 + x_2^2)} = |\alpha|\|\mathbf{x}\|$ .
- $\|\mathbf{x} - \mathbf{z}\|$  är **avståndet** mellan  $\mathbf{x}$  och  $\mathbf{z}$ ,

$$\|\mathbf{x} - \mathbf{z}\| = \sqrt{(x_1 - z_1)^2 + (x_2 - z_2)^2}$$




KTH Matematik

# Ortogonal projektion

$$\mathbf{x} = \mathbf{x}_p + r_x \cdot \frac{\mathbf{w}}{\|\mathbf{w}\|},$$

där  $r_x$  är ett tal som vi kommer att bestämma och  $\frac{\mathbf{w}}{\|\mathbf{w}\|}$  är en enhetsvektor i  $\mathbf{w}$ :s riktning.  $\mathbf{x}_p$  är den vinkelräta (=ortogonala) projektionen av  $\mathbf{x}$  på  $f(\mathbf{x}) = 0$ .



# Avstånd med tecken

$\mathbf{x} = \mathbf{x}_p + r_x \cdot \frac{\mathbf{w}}{\|\mathbf{w}\|}$ . Vi beräknar det kvadrerade avståndet

$$\begin{aligned}\|\mathbf{x} - \mathbf{x}_p\|^2 &= \left\| r_x \cdot \frac{\mathbf{w}}{\|\mathbf{w}\|} \right\|^2 = \left( \frac{r_x}{\|\mathbf{w}\|} w_1 \right)^2 + \left( \frac{r_x}{\|\mathbf{w}\|} w_2 \right)^2 \\ &= \frac{r_x^2}{\|\mathbf{w}\|^2} (w_1^2 + w_2^2)\end{aligned}$$

vilket är liktydigt med att

$$\|\mathbf{x} - \mathbf{x}_p\|^2 = \frac{r_x^2}{\|\mathbf{w}\|^2} \|\mathbf{w}\|^2 = r_x^2$$

d.v.s.

$$\|\mathbf{x} - \mathbf{x}_p\| = |r_x|$$

Således är  $r_x$  **avståndet med tecken**  $\pm$  från  $\mathbf{x}$  till linjen  $f(\mathbf{x}) = 0$ .



# Avstånd med tecken

Ytterligare, med

$$\begin{aligned}f(\mathbf{x}) &= \mathbf{w} \bullet \mathbf{x} + b = \\&= \mathbf{w} \bullet \left( \mathbf{x}_p + r_x \cdot \frac{\mathbf{w}}{\|\mathbf{w}\|} \right) + b = \mathbf{w} \bullet \mathbf{x}_p + \mathbf{w} \bullet \left( \frac{r_x}{\|\mathbf{w}\|} \cdot \mathbf{w} \right) + b \\&= \underbrace{\mathbf{w} \bullet \mathbf{x}_p + b}_{=f(\mathbf{x}_p)} + \mathbf{w} \bullet \left( \frac{r_x}{\|\mathbf{w}\|} \cdot \mathbf{w} \right) \\&= \underbrace{f(\mathbf{x}_p)}_{=0} + \mathbf{w} \bullet \left( \frac{r_x}{\|\mathbf{w}\|} \cdot \mathbf{w} \right)\end{aligned}$$

$$\begin{aligned}&= \mathbf{w} \bullet \left( \frac{r_x}{\|\mathbf{w}\|} \cdot \mathbf{w} \right) \\&= \frac{r_x}{\|\mathbf{w}\|} \cdot \underbrace{\mathbf{w} \bullet \mathbf{w}}_{=\|\mathbf{w}\|^2} = r_x \|\mathbf{w}\|.\end{aligned}$$

Med andra ord

$$f(\mathbf{x}) = r_x \|\mathbf{w}\|$$

d.v.s.

$$r_x = \frac{f(\mathbf{x})}{\|\mathbf{w}\|}$$

Därtill, om  $\mathbf{0} = (0, 0)$ ,  $f(\mathbf{0}) = \mathbf{w} \bullet \mathbf{0} + b = 0 + b = b$ , d.v.s.,

$$r_0 = \frac{f(\mathbf{0})}{\|\mathbf{w}\|} = \frac{b}{\|\mathbf{w}\|}$$

är avståndet med tecken från planets origo till linjen  $f(\mathbf{x}) = 0$ .



KTH Matematik

$$f(\mathbf{x}) = r_x \|\mathbf{w}\|$$

D.v.s  $f(\mathbf{x}) > 0$  om  $r_x > 0$  (den positiva sidan av  $f(\mathbf{x}) = 0$ ) och  
 $f(\mathbf{x}) < 0$  om  $r_x < 0$  (den negativa sidan av  $f(\mathbf{x}) = 0$ ).



$$r_x = \frac{f(\mathbf{x})}{\|\mathbf{w}\|}$$

m.a.o.

$$f(\mathbf{x}) = r_x \|\mathbf{w}\|$$



$$r_0 = \frac{f(\mathbf{0})}{\|\mathbf{w}\|} = \frac{b}{\|\mathbf{w}\|}$$

# Parallellförflyttning av ett hyperplan


$r_0$  är avståndet med tecken från origo till linjen, och

$$r_0 = \frac{b}{\|\mathbf{w}\|}$$

Vi ser således att när  $b$  varieras (med fixt  $\mathbf{w}$ ), så kommer hyperplanet att förflyttas parallellt. Om  $b > 0$ , då ligger  $\mathbf{0}$  i positiva sidan, och om  $b < 0$ , så ligger  $\mathbf{0}$  i den negativa sidan.



# Inlärningens geometri



# Exempel: En mängd av exempel i $R^2$

## Mätdata & etiketterna

$x_1$	$x_2$	y
1	-0.5	+1
1	1	+1
-2	1	+1
-1	-1.5	-1
2	-2	-1
-2	-1	-1




KTH Matematik


# Exempel i $R^2$ : $+1 \mapsto +$ , $-1 \mapsto o$

Nummer  $l$       Mätdata  $\mathbf{x}(l) = (x_1(l), x_2(l))$       etiketterna  $y$

$l$	$x_1(l)$	$x_2(l)$	$y(l)$
1	1.5	-0.5	+1
2	1	1	+1
3	-2	1	+1
4	-1	-1.5	-1
5	2	-2	-1
6	-2	-1	-1



# Da Capo



Vi vill nu hitta  $w_1$ ,  $w_2$  och  $b$  så att

$$f(\mathbf{x}(l)) = w_2 x_2(l) + w_1 x_1(l) + b$$

har rätt förtecken (och därmed rätt etikett) för varje  $\mathbf{x}(l)$ , d.v.s.

$$\text{sign}(f(\mathbf{x}(l))) = y(l)$$


bör gälla för varje datapunkt i de exempel vi har.

Detta kallas *övervakad inlärning*.



KTH Matematik

# En korkad frågeställning?




# En korkad frågeställning?

Jodå (kanske), men vi vill hitta en **algoritm** för placering av linjalen !


Algoritm: varje räkneförfarande efter ett givet schema kallas algoritm



$\textcircled{1} \mapsto -1$  och  $\textcircled{+} \mapsto +1$




# Linjen ändrar riktning



KTH Matematik

# Parallel förflyttning av linjen



# En algoritm som gör dessa steg

- Välj startvärdena  $w_1$ ,  $w_2$  och  $b$  på måfå.
- För varje  $l$ : om  $f(\mathbf{x}(l))$  har rätt förtecken med dessa vikter och bias, gör ingenting.
- Om  $\text{sign}(f(\mathbf{x}(l))) \neq y(l)$ , uppdatera bias och vikterna enligt följande (vi tar  $\eta = 0.2$ ):

$$\begin{aligned} b &\leftarrow b + \eta y(l) \\ w_1 &\leftarrow w_1 + \eta y(l)x_1(l) \\ w_2 &\leftarrow w_2 + \eta y(l)x_2(l) \end{aligned}$$

- Fortsätt att gå genom  $\mathbf{x}(l)$  tills alla har fått korrekt etikett.



KTH Matematik

# En allmän princip om uppdatering (numerisk metodik, statistik, signalbehandling m.m.)


nya värdet  $\leftarrow$  nuvarande värdet + korrektionen

Korrektionen beror på data.



KTH Matematik

Vi väljer (på måfå)  $b = 0$ ,  $w_1 = 1$ ,  $w_2 = 0.5$ , d.v.s.,




$$f(\mathbf{x}) = 0.5x_2 + x_1$$



# Exempel i $R^2$

Vi plottar datapunkterna samt den räta linjen  $0.5x_2 + x_1 = 0$  d.v.s.  
 $x_2 = -2x_1$



# Exempel i $R^2$ : uppdatering

Vi har fel i  $l = 5$  med  $\mathbf{x}(5) = (2, -2)$ ,  $y(5) = -1$  Regeln

$$\begin{aligned} b &\leftarrow b + \eta y(5) \\ w_1 &\leftarrow w_1 + \eta y(5)x_1(5) \\ w_2 &\leftarrow w_2 + \eta y(5)x_2(5) \end{aligned}$$

ger med  $b = 0$ ,  $w_1 = 1$ ,  $w_2 = 0.5$ ,  $\eta = 0.2$

$$\begin{aligned} -0.2 &= 0 + 0.2 \cdot (-1) \\ 0.6 &= 1 + 0.2 \cdot (-1) \cdot 2 \\ 0.9 &= 0.5 + 0.2 \cdot (-1) \cdot (-2) \end{aligned}$$


d.v.s. vi har en ny bias och de nya vikterna

$$f(\mathbf{x}) = 0.9x_2 + 0.6x_1 - 0.2$$

$$\text{d.v.s. } x_2 = -\frac{0.6}{0.9}x_1 + \frac{0.2}{0.9}.$$

# Exempel i $R^2$ : efter en första uppdatering

Datapunkterna och  $x_2 = -\frac{0.6}{0.9}x_1 + \frac{0.2}{0.9}$



# Exempel i $R^2$ : uppdatering

Vi har fel i  $l = 3$  med  $\mathbf{x}(3) = (-2, 1)$ ,  $y(3) = 1$  och med  
 $b = -0.2$ ,  $w_1 = 0.6$ ,  $w_2 = 0.9$ ,  $\eta = 0.2$

$$\begin{aligned}0 &= 0.2 + (-0.2) \cdot 1 \\0.2 &= 0.6 + 0.2 \cdot 1 \cdot (-2) \\1.1 &= 0.9 + 0.2 \cdot 1 \cdot 1\end{aligned}$$

d.v.s. vi har en ny bias och de nya vikterna


$$f(\mathbf{x}) = 1.1x_2 + 0.2x_1$$

d.v.s.  $x_2 = -\frac{0.2}{1.1}x_1$ .



# Exempel i $R^2$ : andra uppdateringen

Datapunkterna och  $x_2 = -\frac{0.2}{1.1}x_1$ .



# Exempel i $R^2$ : uppdatering

Nu blev det fel i  $\ell = 1$  med  $\mathbf{x}(1) = (1.5, -0.5)$ ,  $y(1) = 1$ . Med  $b = 0$ ,  $w_1 = 0.2$ ,  $w_2 = 1.1$ ,  $\eta = 0.2$

$$0.2 = 0 + 0.2 \cdot 1$$

$$0.5 = 0.2 + 0.2 \cdot 1 \cdot 1.5$$

$$1.0 = 1.1 + 0.2 \cdot 1 \cdot (-0.5)$$

d.v.s. vi har en ny bias och de nya vikterna


$$f(\mathbf{x}) = 1.0x_2 + 0.5x_1 + 0.2$$

d.v.s.  $x_2 = -0.5x_1 - 0.2$ .





# Exempel i $R^2$ :tredje uppdateringen

Datpunkterna och  $x_2 = -0.5x_1 - 0.2$ .



# Exempel i $R^2$ : felfritt ! Algoritmen stannar !

Datpunkterna och  $x_2 = -0.5x_1 - 0.2$ .




- Hur är det ? Kommer den ovan applicerade algoritmen alltid att stanna eller var detta en tillfällighet ?
- Innan algoritmen stannat, kan vi uppskatta hur länge vi måste hålla på tills den stannar?


SVAREN ges i slutet av föredraget.



# Systemdiagram



# INLÄRNING



## Exemplen


Nummer  $I$       Mätdata  $\mathbf{x}(I) = (x_1(I), x_2(I))$       etiketterna  $y$

$I$	$x_1(I)$	$x_2(I)$	$y(I)$
1	1.5	-0.5	+1
2	1	1	+1
3	-2	1	+1
4	-1	-1.5	-1
5	2	-2	-1
6	-2	-1	-1

har ovan **lagrats** med 'trial and error' i  
 $b = 0.2, w_1 = 0.5, w_2 = 1.0.$



# I DRIFT EFTER INLÄRNING



Vi matar in en **ny** vektor  $x$  av mätdata, ut kommer en diagnos:  
t.ex., elakartad, säg  $+1$ , eller välartad,  $-1$



KTH Matematik


# LINEAR LEARNING MACHINE a.k.a. PERCEPTRON (ur Wikipedia)

Frank Rosenblatt developed in 1957 the perceptron, i.e.,

$$y = \text{sign}(f(\mathbf{x})), \quad y \in \{+1, -1\}$$

as a model & learning algorithm to understand human memory, learning, and cognition. The perceptron was based on biological ideas about networks of neurons in the brain.





In 1960 Rosenblatt demonstrated at Cornell University a piece of electromechanical hardware, named **Mark I Perceptron**, the first machine that could learn to recognize and identify optical patterns. This was the first computer that could learn new skills by trial and error, using a type of neural network that simulates human thought processes.

Hannes Alfvén *Sagan om den stora datamaskinen. En vision.* (1966). Pilgrim press Stockholm, 1987. En författarröst från en avlägsen framtid berättar om superdatorernas utveckling:


Men allteftersom neurofysiologien har lärt oss uppbyggnaden och funktionen av (neuronerna) har kretsar av liknande typ införts i (super)datorerna. sid. 127

... människornas nervsystem och hjärna ... dess mest förnämliga egenskaper (inspirerar) till förbättring av (super)datorernas struktur. sid. 132




# The Mark 1 Perceptron

This machine was designed for image recognition: it had an array of 400 photocells, randomly connected to the "neurons". Weights were encoded in potentiometers, and weight updates during learning were performed by electric motors.




# Dr. Perceptron




Dr. Perceptron is a doctor of Freudian Circuit Analysis, and works at the HAL Institute For Criminally Insane Robots.






Freudian Circuit Analysis = freudiansk kretsanalys ↔ psykoanalys

# Dr. Perceptron: det allmänna fallet



# Dr. Perceptron: det allmänna fallet



1. Clump thickness
2. Uniformity of cell size
3. Uniformity of cell shape
4. Marginal Adhesion
5. Single epithelial cell size
6. Bare nuclei
7. Bland chromatin
8. Normal nucleoli
9. Mitoses

0.2000	0.2000	0.5000	0.5000	0.5000	0.2000	0.3000	1.0000	1.0000
0.4000	0.1000	0.1000	0.1000	0.4000	0.3000	0.3000	0.5000	0.5000
0.9000	0.1000	0.1000	0.1000	0.1000	0.6000	0.3000	0.1000	0.7000
0.6000	0.8000	0.1000	0.1000	0.1000	0.1000	0.8000	0.1000	0.1000
0.8000	1.0000	0.7000	0.1000	0.2000	0.2000	0.2000	0.4000	0.2000
0.3000	0.8000	0.6000	0.6000	0.2000	0.1000	0.1000	0.1000	0.1000
0.1000	0.1000	0.9000	1.0000	0.4000	0.1000	0.2000	0.3000	0.2000
0.8000	0.2000	0.1000	0.7000	0.7000	0.7000	0.3000	0.1000	0.1000
0.1000	1.0000	0.1000	0.1000	1.0000	0.7000	1.0000	0.1000	0.1000
0.1000	0.1000	0.1000	0.1000	0.1000	0.7000	1.0000	0.3000	0.1000



$$\mathbf{w} = (w_1, w_2, \dots, w_n), \mathbf{x} = (x_1, x_2, \dots, x_n)$$

$$\mathbf{w} \bullet \mathbf{x} \stackrel{\text{def}}{=} w_1x_1 + w_2x_2 + \dots + w_nx_n$$

$$f(\mathbf{x}) = \mathbf{w} \bullet \mathbf{x} + b$$

$$\mathbf{x} \bullet \mathbf{y} = x_1y_1 + \dots + x_ny_n = \sum_{i=1}^n x_iy_i$$

**Matchning** av två vektorer.

# Euklidiska rum

$R^n$  med dotprodukt kan åskådliggöras med bekanta geometriska ideer, som linje, punkt, plan, vinkel och kallas därför ett euklidiskt



Euklides av Alexandria  
f. ung. 325 f.Kr.  
d. ung. 265 f.Kr.

rum.



KTH Matematik

- längden av  $\mathbf{x}$  är

$$\|\mathbf{x}\| = \sqrt{\mathbf{x} \bullet \mathbf{x}} = \sqrt{x_1^2 + \dots + x_n^2}$$

Ett *hyperplan* är ett affint<sup>2</sup> underrum av dimension  $n - 1$ , som delar upp  $R^n$  i två halvrum. Vi betraktar följande *hyperplan*  $D \subset R^n$ :

$$D = \{\mathbf{x} \in R^n \mid f(\mathbf{x}) = 0\}$$

$\mathbf{w}$  är igen ortogonal mot varje vektor in  $D$ .



$$f(\mathbf{x}) = \mathbf{w} \bullet \mathbf{x} + b$$

$$D = \{\mathbf{x} \in R^n \mid f(\mathbf{x}) = 0\}$$

Hyperplanet  $D$  delar upp  $R^n$  i två halvrum  $\mathcal{R}_1$  och  $\mathcal{R}_2$ :


$$\mathcal{R}_1 = \{\mathbf{x} \in R^n \mid f(\mathbf{x}) > 0\}$$

$$\mathcal{R}_2 = \{\mathbf{x} \in R^n \mid f(\mathbf{x}) < 0\}$$

Som ovan är  $\mathbf{w}$  ortogonal mot varje vektor i  $D$  och pekar ut mot  $\mathcal{R}_1$ .



# Inlärningens geometri är densamma !



# PERCEPTRON

$$f(\mathbf{x}) = \mathbf{w} \cdot \mathbf{x} + b$$

där  $\mathbf{w}$  kallas igen en *viktvektor*, och  $b$  är ett reellt tal som igen kallas *bias* (eller tröskel).

# TRÄNING AV EN PERCEPTRON

- Låt  $\mathbf{x}_i \in R^n$ ,  $y_i \in Y = \{+1, -1\}$ ,  $i = 1, \dots, m$  vara  $m$  par av exempl. Vi kallar

$$\mathcal{S} = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_m, y_m)\}$$

en *träningsmängd*.

- Nu gäller det uppenbarligen att bestämma vikterna  $\mathbf{w}$  och bias  $b$  utifrån exemplen i träningsmängden.
- 'självprogrammerande dator' ? Datorn lär sig regelbundenheterna i träningsmängden och lagrar dessa i  $\mathbf{w}$  och  $b$ .



KTH Matematik


Bestäm  $(\mathbf{w}, b)$  m.h.a.  $\mathcal{S}$  så att  $f(\mathbf{x}_i) = y_i$  för all  $i$ , d.v.s., varje vektor i träningsmängden är rätt klassificerad.

- ① Finns det en lösning till denna uppgift ?
- ② Om en lösning existerar, finns det en algoritm som hittar lösningen i ett ändligt antal steg ?

# EN PERCEPTRON

En perceptron är därmed en enhet som tar en vektor  $\mathbf{x}$  och beräknar  $y \in \{+1, -1\}$  enligt regeln  $y = \text{sign}(f(\mathbf{x}))$ , d.v.s.

- Om  $\mathbf{x} \in \mathcal{R}_1$  så är  $y = +1$
- Om  $\mathbf{x} \in \mathcal{R}_2$  så är  $y = -1$



# Existens av lösning: Linjär separabilitet

Vi antar att det finns (ett för oss tillsvidare okänt) hyperplan sådant att det finns  $(\mathbf{w}_*, b_*)$  sådana att om

$$f_* (\mathbf{x}) = \mathbf{w}_* \bullet \mathbf{x} + b_*$$

så gäller det för alla  $(\mathbf{x}_i, y_i) \in \mathcal{S}$  att  $f_* (\mathbf{x}) > 0$  om och endast om  $y_i = +1$ .


När detta antagande är sant, kallas  $\mathcal{S}$  linjärt separabel.



KTH Matematik


# Linjär separabilitet

Exemplen representeras av punkter med två etiketter  $\circ$  och  $+$ . Alla  $+$  ligger i  $\mathcal{R}_1$  och alla  $\circ$  ligger i  $\mathcal{R}_2$  med avseende på hyperplanet  $f_*(\mathbf{x}) = 0$ .




KTH Matematik

# Konvexitet



KONVEX



ICKE-KONVEX

# Konvext hölje

Vi erhåller ett konvext område (=konvext hölje för ett ändligt antal punkter) genom att spänna ett gummiband runt punktmängden.




# Linjär separabilitet: konvext hölje

Vi erhåller två konvexa områden genom att spänna två gummiband i blått runt två punktmängder. De **konvexa höljena** är i bilden disjunkta. Vi har följande matematiska sats:


Två disjunkta konvexa mängder är linjärt separabla.

Alltså råder linjär separabilitet för de konvessa höljena i bilden, och därför finns ett hyperplan som separerar punktmängderna i bilden.



# ETT ICKE-SEPARABELT FALL

Det konvexa höljet av punkterna med etiketterna  $x$  innehåller det konvexa höljet av punkterna med etiketterna  $\circ$ . Denna träningsmängd kan inte separeras av ett hyperplan utan att ett antal fel uppstår.



- Vi tar på måfå en viktvektor  $\mathbf{w}$  och en bias  $b$ .
- Sedan sveper vi genom exemplen i träningsmängden med den motsvarande perceptronen.
- För varje felaktigt klassificerat exempel ändras hyperplanets riktning och/eller hyperplanet förflyttas parallellt.



# Rosenblatts perceptron algoritm

Varje gång något exempel felklassificeras under ett svep, uppdateras viktvektorn genom att addera en term som är proportionell mot felsignalen (med tecken).

- Om  $\mathbf{w}_k$  och  $b_k$  är sådana att

$$y_i (\mathbf{w}_k \bullet \mathbf{x}_i + b_k) = y_i f(\mathbf{x}_i) > 0$$

så är  $\mathbf{x}_i$  rätt klassifierad.

Således ändras hyperplanets riktning genom att addera till viktvektorn en vektor som är proportionell mot  $y_i f(\mathbf{x}_i)$ , så snart som  $y_i f(\mathbf{x}_i)$  är negativt.





KTH Matematik

Algoritmen körs (svepet upprepas) tills inga exempl i träningsmängden är felklassificerade.

**Perceptronkonvergens** Det kan bevisas att algoritmen alltid kommer att stanna efter ett ändligt antal steg, förutsatt att vi har en linjärt separabel träningsmängd.




# Rosenblatts perceptron algoritm

```
1:  $\mathbf{w}_0 \leftarrow \mathbf{0}$ ,  $b_0 \leftarrow 0$ ,  $k \leftarrow 0$   $\mathcal{R} \leftarrow \max_{1 \leq i \leq I} \|\mathbf{x}_i\|$ 
2: repeat
3:   for  $i = 1$  to  $I$  do
4:     if  $y_i (\mathbf{w}_k \bullet \mathbf{x}_i + b_k) \leq 0$  then
5:        $\mathbf{w}_{k+1} \leftarrow \mathbf{w}_k + y_i \mathbf{x}_i$ ,
          $b_{k+1} \leftarrow b_k + y_i \mathcal{R}^2$ ,
          $k \leftarrow k + 1$ 
6:     end if
7:   end for
8: until no mistakes made in the loop
9: return  $\mathbf{w}_k, b_k$ , where  $k$  is the number of mistakes.
```



KTH Matematik

# Geometrisk marginal



# Konvergensteoremet för perceptroner

Låt  $\mathcal{S}$  vara en icke-trivial linjärt separabel träningsmängd och låt för alla  $i$


$$\gamma_i = y_i \mathbf{w}^* \bullet \mathbf{x}_i + b^* \geq \gamma$$

där  $\|\mathbf{w}^*\| = 1$ .

Då är antalet 'repeats' i Rosenblatts perceptron algoritm högst

$$\left( \frac{\mathcal{R}^2}{\gamma} \right)$$

# Ett enkelt fall där en perceptron inte kan fungera



KTH Matematik

# Vikterna efter träningen

Algoritmen arbetade genom att addera till en tidigare viktvektor en felklassificerad träningsvektor  $\mathbf{x}_i$  multiplicerad med motsvarande  $y_i$ . Efter att algoritmen har stannat har vi således

$$\mathbf{w}^* = \sum_{i=1}^m a_i y_i \mathbf{x}_i$$

där  $a_i$  är antalet gånger felklassificering av  $x_i$  har föranlett en ändring av  $\mathbf{w}$  under inlärningen. Vi kan skriva

$$\mathbf{w}^* = \sum_{i=1|y_i=+1}^m a_i \mathbf{x}_i - \sum_{i=1|y_i=-1}^m a_i \mathbf{x}_i$$



# Vikterna efter träningen

Med

$$\mathbf{w}^* = \sum_{i=1|y_i=+1}^m a_i \mathbf{x}_i - \sum_{i=1|y_i=-1}^m a_i \mathbf{x}_i$$

fås

$$f^*(\mathbf{x}) = \mathbf{w}^* \bullet \mathbf{x} + b^*$$

$$= \sum_{i=1|y_i=+1}^m a_i (\mathbf{x}_i \bullet \mathbf{x}) - \sum_{i=1|y_i=-1}^m a_i (\mathbf{x}_i \bullet \mathbf{x}) + b^*$$

Med andra ord, träningsmängden har lagrats i vikterna, enligt

$$f^*(\mathbf{x}) = \sum_{i=1|y_i=+1}^l a_i (\mathbf{x}_i \bullet \mathbf{x}) - \sum_{i=1|y_i=-1}^l a_i (\mathbf{x}_i \bullet \mathbf{x}) + b^*$$

Varje ny mätvektor  $\mathbf{x}$  **matchas** med  $\mathbf{x}_i$  i varje exempel, och matchningarna viktas och summeras över alla exempl. Jämförelsen av skillnaden mellan de positiva och negativa exemplen med bias  $b^*$  (tröskel) avgör resultatet.

# Associativt minne ?

Matchning mot de lagrade vektorerna gör att vi vill tala om ett  
*associativt minne*

$$f^*(\mathbf{x}) = \sum_{i=1|y_i=+1}^I a_i (\mathbf{x}_i \bullet \mathbf{x}) - \sum_{i=1|y_i=-1}^I a_i (\mathbf{x}_i \bullet \mathbf{x}) + b^*$$



KTH Matematik


Det finns nyare, kraftfullare utvecklingar och utvidgningar av perceptronen, som klarar av icke-separabla problem. En av dessa, som kallas på engelska *support vector machines*, tar avstamp i en viss mening på formeln

$$f^*(\mathbf{x}) = \sum_{i=1|y_i=+1}^l a_i (\mathbf{x}_i \bullet \mathbf{x}) - \sum_{i=1|y_i=-1}^l a_i (\mathbf{x}_i \bullet \mathbf{x}) + b^*$$

De nya inlärningsmaskiner som förbättrar perceptronernas egenskaper kallas neurala nätverk,



# Megatron (senare Galvatron)



**"the embryo of an electronic computer that will be able to walk, talk, see, write, reproduce itself and be conscious of its existence."**

**Hannes Alfvén:** " (Mänskans) verkliga storhet ligger i att hon är den levande varelse som var intelligent nog för att inse att (evolutionens) mål är datorn. " sid. 17 i a.a.

Slut på föreläsningen - tack !

