

BP

- jakým máš desired sigmoid?
- jaký máš update rule?

First-order methods

- update rule Adabo

Second-order methods

- how does look discret step in quickprop?

PCA:

mám n dimenzí, chci pouze k

Hledám tedy $n-k$ nejmenších důležitých, neboť máme k největších důležitých dimenzí.

chci docílit nejmenší kvadratické odchylky $\xi_k^2 = \|x_k - y_k\|^2$, kde $y_k = \sum_{i=1}^p c_{ki} e_i$

↑
ortogonální vektory v X^p
tobto je definice toho zobrazení d.
másmo prázdně

Získám tak, že si vytvořím kovarianční matici V .

$$v_{ij} = v_{ji} = \frac{1}{K} \sum_{k=1}^K (x_{ki} - \mu_i) \cdot (x_{kj} - \mu_j), \quad \mu_i = \sum_{k=1}^K x_{ki} / K$$

Největší důležitá dimenze odpovídají největším vlastním číslům a jejich vektorům v kovarianční matici.

Perceptron:



$$\xi = \sum_i x_i w_i + \gamma \quad \swarrow \text{bias}$$

$$y = \sigma(x^T w) \rightarrow \text{extended vectors}$$

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad \text{— transfer function}$$

A, B jsou lin. sep., pokud existuje číselná rovina, nebo:

$$\exists w_1 - w_n, \gamma \quad \forall (x_1 - x_n) \in A \quad \sum w_i x_i \geq \gamma \quad \text{a}$$

$$\forall (y_1 - y_n) \in B \quad \sum w_i y_i < \gamma$$

algoritmus:

$w(0)$ — inicializace náhodně

while true:

$$y(t) = \text{sgn}(x^T w)$$

$$w(t+1) = w(t) + \alpha \cdot x(t) \cdot (\text{target} - y(t))$$

konvergence:

— pokud jsou množiny separabilní, pak dostaneme vždy dostatečně blízké řešení w^* .

uvádíme, že je něco špatně klasifikováno:

$$\min \{w^* \cdot \vec{p}_i; \vec{p}_i \in P\}$$

$$\cos \rho \frac{w^* \cdot w_{t+1}}{\|w_{t+1}\|} \rightarrow w^* \cdot w_{t+1} \geq w^* \cdot w_0 + (t+1)\delta$$

$$\|w_{t+1}\|^2 \leq \|w_0\|^2 + (t+1)$$

$$w_i \cdot p_i \leq 0 \text{ - protože misklas.}$$

$$\|w_{t+1}\|^2 \leq \|w_t\|^2 + 1$$

$$\cos \rho \geq \frac{w^* \cdot w_0 + (t+1)\delta}{\sqrt{\|w_0\|^2 + t+1}}$$

$$\cos \rho \leq 1, \delta > 0$$

pro každé w_0 a t , takže musí existovat maximum po konečné množině w_0 .

protože p_i je normal.

PCA:

destruktivní zmenení $X^n \rightarrow X^p$, kde $p < n$

hledání vhodné zmenení, kde minimalizuje čtvercovou chybu.

$$\epsilon_h^2 = \|X_h - y_h\|^2$$

ne hledat pomocí kovarianční matice a vlastních vektorů:

$$y_h = \sum_{i=1}^p c_{hi} \cdot e_i$$

normalizovaný vektor
z X^p

$$v_{ij} = v_j = \frac{1}{n} \sum_{k=1}^n (x_{ki} - \mu_i) \cdot (x_{kj} - \mu_j), \text{ kde } \mu_j = \frac{1}{n} \sum_{k=1}^n x_{kj}$$

$$X = \begin{pmatrix} \vdots \\ -x_{ij}- \\ \vdots \end{pmatrix}$$

$$\mu = \begin{pmatrix} -\mu_i- \end{pmatrix}$$

LVQ:

prototypování a přesouvání od nebo k sobě podle toho, jestli je shodná třída.

$\forall x$:

$$q = \arg \min_p \sqrt{\sum_i (x_i - w_i(p))^2} \rightarrow \text{minimální vzdálenost od určitého vektoru}$$

$$C_{w_q} = C_{x_i}$$

$$w_q \leftarrow \mu(t) \cdot (x_i - w_q)$$

$$C_{w_q} \neq C_{x_i}:$$

$$w_q \leftarrow \mu(t) \cdot (x_i - w_q)$$

$\rightarrow$ nižší počet lib. dist. fei.

Perceptron

$$y = \text{sign}(x^T w) - \text{extended vector}$$

$$w(t+1) = w(t) + \alpha \cdot x \cdot (\text{target} - y) \quad \rightarrow \text{přiblížují / odcházejí se od druhé třídy}$$

$$\text{separabilita: } \exists w_1 - v_1, \gamma : \forall x_1 - x_n \quad \sum_i x_i \cdot w_i \geq \gamma \quad \wedge$$

$$\forall y_1 - y_n \quad \sum_i y_i \cdot w_i \leq -\gamma \quad \text{pak jsou lin. separabilní.}$$

$$\cos \varphi = \frac{w^* \cdot w_{t+1}}{\|w_{t+1}\|}$$

$$w^* \cdot w_{t+1} \geq w^* \cdot w_0 + (t+1)\gamma \quad \delta = \min_{p \in P} v_0 \cdot p$$

$$\|w_{t+1}\|^2 \leq \|w_0\|^2 + (t+1)$$

$$\cos \varphi \geq \frac{w^* \cdot w_0 + (t+1)\gamma}{\sqrt{\|w_0\|^2 + (t+1)}}$$

$\rightarrow \cos \varphi \leq 1$, takže musíme po hranici možná klesích nastat
in max, protože ten výraz výrazně roste s t.

LQR:

prototypy $\in$ prototypy, každý reprezentuje jeden cluster, třídu.

Zároveň s nárůstajícím přiručním vah. Pak postupně upravují podle vstupů.

Inferenci děláme tak, vzhledem k tomu, jaké prototypy je vstup nejblíže.

$$\forall x \in P:$$

$$q = \arg \min_i d(x, w_i)$$

$d(x, y)$ je vzdálenostní funkce, například tedy eukl.

$$d(x, y) = \sqrt{\sum_i (x_i - y_i)^2}$$

if $C_{x_i} = C_q$ (stejná třída) $\rightarrow$ přidáme třídě k bodu

$$\Delta w_q = +\mu \cdot (x_i - w_q)$$

if $C_{x_i} \neq C_q$ (jiná třída) $\rightarrow$ vzdálíme třídě od bodu

$$\Delta w_q = -\mu \cdot (x_i - w_q)$$

$$w_q(t+1) = w_q(t) + \Delta w_q$$

BP

transfer function: $f(x) = \sigma(x) = \frac{1}{1+e^{-x}}$... sigmoid

$$y_j = \sigma\left(\sum_i \bar{y}_i \cdot w_{ij} + \theta_j\right), \text{ kde } \bar{y}_i \text{ je upravený předchozí vstup (tedy to může být i výstup)}$$

chci minimalizovat chybu na výstupní vrstvě: $E = \frac{1}{2} \sum_p \sum_j (y_{pj} - d_{pj})^2$
 při tréninku musím chybu propagovat škrz celou síť na inputních všech vst.

$$w_{ij}(t+1) = w_{ij}(t) + \Delta E w_{ij}(t) \quad \text{aplikace chyb - rule}$$

$$\Delta E w_{ij} = - \frac{\partial E}{\partial w_{ij}} = - \frac{\partial}{\partial y_j} \cdot \frac{\partial y_j}{\partial \xi_j} \cdot \frac{\partial \xi_j}{\partial w_{ij}}$$

j 0
 w_{ij} ↑
 i 0

$$f'(x) = \lambda \cdot y_j \cdot (1 - y_j)$$

$w_{ij} \rightarrow$ váha mezi neuronem i a neuronem j

$$w_{ij}(t+1) = w_{ij}(t) + \alpha \cdot \delta_j y_i + \alpha_m (w_{ij}(t) - w_{ij}(t-1))$$

$$\delta_j \begin{cases} (d_j - y_j) \cdot \lambda \cdot y_j \cdot (1 - y_j) & \text{for output} \\ \left(\sum_k \delta_k \cdot w_{jk} \right) \cdot \lambda \cdot y_j \cdot (1 - y_j) & \text{for hidden layer} \end{cases}$$

! 0

for output: $-\frac{\partial E}{\partial w_{ij}} = - \frac{\partial E}{\partial y_j} \cdot \frac{\partial y_j}{\partial \xi_j} \cdot \frac{\partial \xi_j}{\partial w_{ij}} = \boxed{\quad} \cdot \frac{\partial}{\partial w_{ij}} \cdot \sum_k w_{kj} \cdot y_k = \boxed{\quad} \cdot y_i$

$$= - \frac{\partial E}{\partial y_j} \cdot f'(\xi_j) \cdot y_i = -(y_j - d_j) \cdot f'(\xi_j) \cdot y_i$$

for hidden: $-\frac{\partial E}{\partial w_{ij}} = - \left(\sum_k \frac{\partial E}{\partial \xi_k} \cdot \frac{\partial \xi_k}{\partial y_j} \right) \cdot \frac{\partial y_j}{\partial \xi_j} \cdot \frac{\partial \xi_j}{\partial w_{ij}} = \boxed{\quad} \cdot y_i =$

$$\boxed{\quad} \cdot \boxed{f'(\xi_j) \cdot y_i} = - \left(\sum_k \frac{\partial E}{\partial \xi_k} \cdot \frac{\partial}{\partial y_j} \cdot \sum_k w_{kj} \cdot y_k \right) \cdot \boxed{\quad} = - \left(\sum_k \delta_k \cdot w_{jk} \right) \cdot f'(\xi_j) \cdot y_i$$

First-order methods

- chceme zrychlit trénink $\rightarrow$ ten. dělat takové úpravy, abych se rychleji dostal k optimu.

Momentum:

tuhle je ten moment

$$w_{ij}(t+1) = w_{ij}(t) + \alpha \Delta E(t) + \underbrace{\alpha_m (w_{ij}(t) + w_{ij}(t-1))}$$

držím si nějakou historii předchozích směrů úprav, abych byl konzistentní?

Musím důvěřovat, abych minimálně změnil...

AdaGrad


při každém update si aktualizuju

$$A_i(t+1) = A_i(t) + \left(\frac{\partial E}{\partial w_i} \right)^2$$

pak

$$w_i(t+1) = w_i(t) - \frac{\alpha}{\sqrt{A_i}} \cdot \frac{\partial E}{\partial w_i}$$

tady si agreguju změny pod daným parametrem $\rightarrow$ je to tak, velmi důvěřovat, abych minimálně změnil, zároveň to je změna dlouho udržet



Second-order algs

- principem je, že pomocí informace, zdali jsem se zlepšil/zhoršil, chci říct

sklon té objective function $\rightarrow$ abych vybral ten směr, který mi nejméně

trajektorii $\rightarrow$ tu mi ideálně dostane nejrychleji k cíli.

$$E(w+h) = E(w) + \nabla E(w)^T h + \frac{1}{2} h^T \nabla^2 E(w) h$$

$$\nabla E = \begin{pmatrix} \frac{\partial E}{\partial w_1} \\ \vdots \\ \frac{\partial E}{\partial w_n} \end{pmatrix} \quad \nabla^2 E = \begin{pmatrix} \frac{\partial^2 E}{\partial w_1 \partial w_1} & \dots & \frac{\partial^2 E}{\partial w_1 \partial w_n} \\ \vdots & \ddots & \vdots \\ \frac{\partial^2 E}{\partial w_n \partial w_1} & \dots & \frac{\partial^2 E}{\partial w_n \partial w_n} \end{pmatrix}$$

$$\nabla E(w+h) \text{ w.r.t. } h = \nabla E(w) + h^T \nabla^2 E(w) \quad \rightarrow \text{mi hledáme, kde je } 0$$

$$h = -(\nabla^2 E(w))^{-1} \nabla E(w) \quad \rightarrow \text{jenže je problém, že je nemusím najít inverzi tak rychle}$$

Newton method

$$w(t+1) = w(t) - (\nabla^2 E(w))^{-1} \cdot \nabla E(w)$$

Pseudo-newton's method

— umäjjene pance puvky um d'ingamle, estaten' per ∇ .

$$w(t+1) = w(t) - \frac{\nabla E(w)}{\frac{\partial^2 E(w)}{\partial w^2}}$$

Quickprop:

$$w(t+1) = w(t) + \Delta w(t)$$

$$\Delta w(t) = - \frac{\nabla E(w)^{(t)}}{\frac{\nabla E(w)^{(t)} - \nabla E(w)^{(t-1)}}{\Delta w(t-1)}}$$

BP

$$E = \frac{1}{2} \sum_i \sum_j (d_{ij} - y_{ij})^2 \quad f(x) = \sigma(x) = \frac{1}{1+e^{-x}} \quad f'(x) = \lambda y_j \cdot (1-y_j)$$

$$w_{ij}(t+1) = w_{ij}(t) + \Delta_e w_{ij}(t)$$



$$\nabla w_{ij}(t) = - \frac{\partial E}{\partial w_{ij}} = \overset{\text{chain-rule}}{\frac{\partial E}{\partial y_j} \cdot \frac{\partial y_j}{\partial \xi_j} \cdot \frac{\partial \xi_j}{\partial w_{ij}}}$$

$$w_{ij}(t+1) = w_{ij}(t) + \alpha \delta_j y_i$$

$$\delta_j \begin{cases} (d_j - y_j) \cdot \lambda y_j \cdot (1-y_j) \text{ for output} \\ \left(\sum_k \delta_k w_{jk} \right) \cdot \lambda y_j \cdot (1-y_j) \text{ for hidden} \end{cases}$$

First-order-methods to speedup training

Momentum



$$\dots + \alpha_m (w(t) - w(t-1))$$

Ada Grads

$$A_i(t+1) = A_i(t) + \left(\frac{\partial E}{\partial w_i} \right)^2$$

a potom

$$w_i(t+1) = w_i(t) - \frac{\alpha}{\sqrt{A_i}} \cdot \frac{\partial E}{\partial w_i}$$

Second-order-derivatives

$$E(w+h) \approx E(w) + \nabla E(w)^T h + \frac{1}{2} h^T \nabla^2 E(w) \cdot h$$

$$\nabla E(w+h) = \nabla E(w) + h^T \nabla^2 E(w)$$

→ nastavení rovnice

$$h = - \left(\nabla^2 E(w) \right)^{-1} \cdot \nabla E(w)$$

Newton's method:

$$w(t+1) = w(t) + \Delta w(t)$$

problém je, že nemáme vždy mjet inverzi

Pseudo newton method:

$$\frac{\partial^2 E}{\partial w_i^2}$$


$$w_i(t+1) = w_i(t) - \frac{\frac{\partial E}{\partial w_i}}{\frac{\partial^2 E}{\partial w_i^2}}$$

quickerly má "small steps", což jsou diskrétní

aproximace

$$= \frac{\nabla_i E^{(t)}}{\frac{\nabla_i E^{(t)} - \nabla_i E^{(t-1)}}{\Delta w_i(t-1)}}$$

Real value approx:




$$\varphi_N(x) = \min \{ f(x') : x \in [x_i, x_{i+1}] \text{ for } x_i \leq x \leq x_{i+1} \}$$

$$E = \int_0^1 |f(x) - \tilde{f}(x)| dx < \varepsilon$$

$$\forall \varepsilon \exists n_0 : N \geq n_0 : \int_0^1 f(x) dx - \int_0^1 \varphi_N(x) dx < \varepsilon$$

$$\varepsilon = \int_0^1 f(x) dx - \int_0^1 \varphi_N(x) dx$$

pak mám vždy dvojici neuronů, kterým je aktivní, pokud $\underbrace{(x_i)}_{\text{neuron 1}} \leq x < \underbrace{(x_{i+1})}_{\text{neuron 2}}$



Asociativní paměť

$$c = x \cdot W \quad \text{bez zpětné vazby}$$

recurrent:

$$\text{hledám takový bod, aby } \xi = \xi \cdot W \quad \rightarrow \text{ten, že to je vlastní vektor vlastního čísla 1.}$$

Eigenvalue autointer:

$$x^i \cdot W = \lambda_i \cdot x^i \quad \rightarrow \text{pro vlastní vektory a jejich vlastní čísla}$$

$$a_i = \alpha_1 \cdot \lambda_1^i \cdot x_1 + \alpha_2 \cdot \lambda_2^i \cdot x_2 + \dots$$

tak po dostatečně mnoha iteracích bude převládnout jedno $\alpha_i \cdot x_i$
tudíž x_i budeme označovat jako atraktor

Hebbian Learning

$$W = \sum_i^m W^i \quad W^i = n \times l \text{ correlation matrix}$$

$$W^L = [x_i^L y_j^L]_{n \times l}$$

$$x^P \cdot W = x^P \cdot (W^1 + W^2 + \dots + W^m)$$

$$= x^P W^P + \sum_{i \neq P} x^P W^i$$

$$= y^P x^P x^P + \sum_{i \neq P} y^i x^i x^P \quad \text{cross talk}$$

$$x^P x^P \geq 0 \Rightarrow \text{sgn}(x \cdot W) = \text{sgn}\left(y^P + \sum_{i \neq P} \frac{x^i x^P}{x^P x^P}\right) \stackrel{\text{dom}}{=} y^P$$

to je pravice v prispodu,
že je cross talk < 1

$$a_1 = \alpha_1 \lambda_1^+ x_1 + \dots$$

$$x^i W = \lambda_i \cdot x^i$$

$$W = W^1 + W^2 + \dots + W^n$$

$$W^L = [x_i^L y_j^L]_{n \times l} \rightarrow \text{dominant matrix}$$

$$x^P \cdot W = x^P W^P + \sum_{i \neq P} x^P W^i$$

$$= y^P x^P x^P + \sum_{i \neq P} y^i x^i x^P \quad \text{cross talk}$$

$$\text{sgn}(x^P W) = \text{sgn}\left(y^P + \sum_{i \neq P} y^i \frac{x^i x^P}{x^P x^P}\right) = \text{polind dom} = y^P \text{ tak cross talk} < 1$$

m2 0,184

BAM

$$y_0 = \text{sgn}(x_0 W)$$

$$x_1 = \text{sgn}(W y_0^T)$$

$$y_1 = \text{sgn}(x_1 W)$$

$$x_2 = \text{sgn}(W y_1^T)$$

Hebbian learning: $W = x^T y$

$$y = \text{sgn}(x W) = \text{sgn}(x x^T y) = \text{sgn}(\|x\|^2 y) = y$$

$$x^T = \text{sgn}(W y^T) = \text{sgn}(x^T y y^T) = \text{sgn}(x^T \|y\|^2) = x^T$$

energy function: $E(x_i, y_i) = -\frac{1}{2} x_i W y_i^T$

generalized en. func.

$$E(x_i, y_i) = -\frac{1}{2} x_i W y_i^T + \frac{1}{2} \theta_c y_i^T + \frac{1}{c} x_i \theta_r^T$$

$\hookrightarrow$ extended BAM $W' = \begin{pmatrix} -\theta_c \\ W \\ \theta_r \end{pmatrix}$

convergence:

$$E(x, y) - E(x', y') = -\frac{1}{2} g_i (x_i - x'_i) \quad \rightarrow \text{argue update, because tidy by the error}$$

$$E(x, y) - E(x', y') > 0, \text{ pokiať } \text{sgn}(y_i) \neq \text{sgn}(x_i - x')$$

tak nový stav (x', y') má nižšiu energiu. Dvaďak ľuď teda redukujú energiu.

$\hookrightarrow$ možno použiť hranicový princíp konvergencie.

Hopfield network:

$$v_{ij} = \begin{cases} \sum_{s=1}^m \sum_{t=1}^n x_i^s x_j^t & i \neq j \\ 0 & i = j \end{cases}$$

$$y_i(0) = x_i$$

$$y_j(t+1) = \text{sgn} \left(\sum_{i=1}^n w_{ij} y_i(t) \right)$$

fully connected network again

state is stable:

$$E = x_1 \cdot W = x_1 \cdot (x_1^T x_1 + \dots + x_m^T x_m - mI)$$

$$= \underbrace{x_1 x_1^T}_{n} x_1 + \underbrace{x_1 x_2^T}_{\alpha_{12}} x_2 + \dots + \underbrace{x_1 x_m^T}_{\alpha_{1m}} x_m - m x_1^T x_1$$

$$= (n-m) \cdot x_1 + \underbrace{\sum_{j=2}^m \alpha_{1j} x_j}_{\text{perturbation}}$$

x_1 je stabilizovaný, pretože $\sum_{j=2}^m \alpha_{1j} x_j$ je malý

$$\text{sgn}(E) = \text{sgn}(x_1)$$

energy function: $-\frac{1}{2} x W x^T + \theta x^T$

(convergence)

$$E = -\frac{1}{2} \sum_{j=1}^n \sum_{i=1}^m w_{ij} x_i x_j$$

necht^{ku} se h-tý neuron změní!

$$x' = (x_1 \dots x'_k \dots x_n)$$

$$E(x') = -\frac{1}{2} \sum_{j \neq k} \sum_{i \neq k} w_{ij} x_i x_j - \sum_i w_{ik} x_i x'_k$$


$$\begin{aligned} E(x) - E(x') &= -\sum_i w_{ik} x_i x_k - \left(-\sum_i w_{ik} x_i x'_k \right) \\ &= -(x_k - x'_k) \cdot \sum_i w_{ik} x_i > 0 \end{aligned}$$

takže zase každým k-tým jsem snížil tu energy function

BAM

$$y = xW$$

$$x = Wy^T$$



fully connected

$$y_0 = \text{sgn}(x_0 w)$$

$$x_1 = \text{sgn}(wy_1^T)$$

$$y_1 = \text{sgn}(x_1 w)$$

opět nastavením $W = x^T y$

$$y = \text{sgn}(xW) = \text{sgn}(xx^T y) = \text{sgn}(\|x\|^2 y) = y$$

$$x^T = \text{sgn}(Wy^T) = \text{sgn}(x^T y y^T) = \text{sgn}(x^T \|y\|^2) = x^T$$

$$E = -\frac{1}{2} xWy^T + \theta_1 y^T + \theta_2 x$$

$$W' = \begin{pmatrix} -\theta_2 & 1 \\ W & \theta_1 \end{pmatrix}$$

Konverguje to?

asynchr. update, takže se mi změní jen jeden stav

$$E = -\frac{1}{2} (x_1 \dots x_n) \cdot \begin{pmatrix} g_1 \\ 1 \\ g_n \end{pmatrix}$$

mohl se mi změnit jen jeden x_i

$$E(x) - E(x') = -\frac{1}{2} g_i \cdot (x_i - x'_i)$$

$\text{sgn}(g_i) \neq \text{sgn}(x_i - x'_i)$, takže

$E(x) - E(x') > 0$, takže jsem snížil energy function.

Mám jen konečně mnoho stavů,
každým k-tým se zlepšuji.

Hopfield network:

$$w_{ij} = \begin{cases} \sum_{s=1}^n x_i^s x_j^s & i \neq j \\ 0 & i = j \end{cases} \rightarrow \text{toto je } \text{training}$$

$$y_i(0) = x_i$$

$$y_i(t+1) = f \left(\sum_{j=1}^n w_{ij} y_j(t) \right) \rightarrow \text{toto je } \text{inference}$$

kdý je stav stabilní?

$$E = X_1 \cdot W = X_1 \cdot (X_1^T + X_2^T + \dots + X_n^T - mI)$$

$$= \underbrace{X_1 X_1^T}_{\alpha_{11}} + \underbrace{X_1 X_2^T}_{\alpha_{12}} + \dots + \underbrace{X_1 X_n^T}_{\alpha_{1n}} - m X_1 I$$

$$= (n-m) X_1 + \sum_{j=2}^n \alpha_{1j} X_j$$

perturbation

je stabilní, pokud perturbation je malá, $n > m$

$$\text{sgn}(E) = \text{sgn}(X_1)$$

energy function:

$$E = -\frac{1}{2} X W X^T + \theta X^T$$

converguje to? asyn. dynamics

$$E = -\frac{1}{2} \sum_{j=1}^n \sum_{i=1}^n w_{ij} x_i x_j \quad X' = (x_1 - x_n' - x_n)$$

$$E(x') = -\frac{1}{2} \sum_{j \neq n} \sum_{i \neq n} w_{ij} x_i x_j - \sum_i w_{in} x_i x_n'$$

$$E(x) - E(x') = - \sum_i w_{in} x_i x_n - \left(- \sum_i w_{in} x_i x_n' \right)$$

$$= - (x_n - x_n') \cdot \underbrace{\sum_i w_{in} x_i}_{\text{potenciál}}$$

> 0 tak to energy function má
klas v každém úseku,
takže se blíží výsledku.

Multiflop: using hpf field

$$E(x_1, \dots, x_n) = \left(\sum_{i=1}^n x_i - 1 \right)^2 = \sum_{i=1}^n x_i^2 + \sum_{i \neq j} x_i x_j - 2 \cdot \sum_{i=1}^n x_i + 1$$

$$x_i^2 = x_i \text{ pro } x_i \in \{0, 1\}$$

$$E = \sum_{i=1}^n x_i + \sum_{i \neq j} x_i x_j - 2 \sum_{i=1}^n x_i + 1 = \sum_{i \neq j} x_i x_j - \sum_{i=1}^n x_i + 1$$

$$= -\frac{1}{2} \sum_{i \neq j} (-2) \cdot x_i x_j + \sum_{i=1}^n (-1) \cdot x_i + 1$$

tabele jsou moje vsázky
zakroutíš dle mne true
vynásíš jeden nastavení mne true

simulated annealing:

$$P_{\Delta E} = \frac{1}{1 + e^{\Delta E/T}} \rightarrow x + \Delta x \text{ bude updatováno s tímto pravděpodobností}$$

Multiflop: Can be solved with hpf field network:

$$E = \left(\sum_{i=1}^n x_i - 1 \right)^2 = \sum_{i=1}^n x_i^2 + \sum_{i \neq j} x_i x_j - 2 \cdot \sum_{i=1}^n x_i + 1$$

$$= \sum_{i \neq j} x_i x_j - \sum_{i=1}^n x_i + 1$$

$$= -\frac{1}{2} \sum_{i \neq j} (-2) \cdot (x_i x_j) + \sum_{i=1}^n (-1) \cdot x_i + 1$$

Simulated annealing

$$P_{\Delta E} = \frac{1}{1 + e^{\Delta E/T}}$$

Self-organisation

we want to cluster data without supervision

problem is how to choose cluster prototype and how many we should have of these.

Competitive learning: winner takes it all, inhibition of neighbours, network plasticity

k-means

— grouping do k clusters

— na začátku každý cluster obsahuje pouze jeden vektor

— jakmile přidám prvek do clusteru, upravím jeho centroid

$$C_i(\text{new}) = C_i(\text{old}) + \frac{1}{n_i} (x_i - C_i(\text{old}))$$

Ojař alg.

— pro výpočet první komponenty PCA

u nás na začátku máme zvolen w

pak iterativně upyadají:


$$w = w + \gamma \phi \cdot (x - \phi w)$$

Pohyb existuje unikátní řešení, Oja ho najde:

$x - \phi w$ je ortogonální k w

jeden iterační attracts w to vectors from X

pohyb $\|w\| = 1$, bude dlehn do středu clusteru.

Nyní je potřeba učit, že se vektoru samy normalizují a by bylo splněno tot 

pohyb $\|w\| > 1$

$(x - \phi w)$ je negativní projekce do w .

$$(x - (xw)w)w = x \cdot w - \|w\|^2 x \cdot w < 0$$

pohyb $\|w\| < 1$


přesně splněno

— > tedy pohyb to stlačuje hodnoty k 1 a dlehn do prostředku clusteru.

$$C(\text{new}) = C(\text{old}) + \frac{1}{n_i} (x_i - C(\text{old}))$$

→ čím větší je odskok, tím více
mám nový prvek ovlivňovat centrálu

Kohonen mapy:



každý neuron dostane celý vstup

$$w(t+1) = w(t) + \alpha(t) \cdot \phi(c_{ij}) \cdot (x_i - w(t))$$

0 1 0 0 1 0

0 1 * * * 0

0(s) — počet fixů

$\delta(s)$ — velikost mezi prvním a posledním fixem

$$p_i = \frac{f_i}{\sum_j f_j}$$

m — očekávaný počet jedinců schematu H

$$m = m(H, t)$$

selection

$$m(H, t+1) = m(H, t) \cdot N \cdot \frac{f(H)}{\sum_j f_j}$$

→ prost, že schema vyhovuje

crossover

$$p_s = 1 - \frac{\delta(H)}{l-1}$$

→ prost, že ind. přežije crossover

$$p_s = 1 - p_c \cdot \frac{\delta(H)}{l-1}$$

$$m(H, t+1) \geq m(H, t) \cdot N \cdot \frac{f(H)}{\sum_j f_j} \cdot \left(1 - p_c \cdot \frac{\delta(H)}{l-1}\right)$$

mutation

$$p[\text{přizije}] = (1 - p_m)^{o(H)} \sim (1 - p_m) \cdot o(H)$$

$p_m \ll 1$

$$m(H, t+1) = m(H, t) \cdot N \cdot \frac{f(H)}{\sum_j f_j} \cdot \left(1 - p_c \cdot \frac{\delta(H)}{l-1} - o(H) \cdot p_m\right)$$

Ojiv alg.

- pro hledání hlavní komponenty

nastavím w vhodně

iterativně provádím pohyb z X dokud mám čas

$$w = w + \gamma \cdot \phi \cdot (x - \phi w) \quad , \quad \phi = x \cdot w$$

- jakmile skončím, tak w určuje směr hlavní komponenty z X .

Pokud existuje více Ojivů, tak je.

$x - \phi w$ je ortogonální k w

Ojiv u každé iteraci posouvám w k průměru z X .

Pokud $\|w\| = 1$, tak w je pouze posunutým dopředu klustrem.

Co kdyby, pokud to tak není?

$\|w\| > 1$, pak $(x - \phi w)w$ je negativní posun ke w .


$xw - \|w\|^2 xw < 0$, takže to w bude zhracovat

$\|w\| < 1$, tak platí obecná analýza.

Proto Ojiv se bude automaticky normalizovat.




Dokování naps

$h_{ij}(t) \rightarrow$ neighbour function



BMV $\rightarrow$ best matching unit

$$w_i(t+1) = w_i(t) + \alpha(t) \cdot h_{ij}(t) \cdot (x - w_i) \quad \text{--- BMV is } j$$



$$m = m(H, t)$$

$$m(H, t+1) = m(H, t) \cdot N \cdot \frac{f(H)}{\sum_j f_j} \quad \rightarrow \text{selection}$$

$$m(H, t+1) \geq m(H, t) \cdot N \cdot \frac{f(H)}{\sum_j f_j} \cdot \left[1 - p_c \frac{\delta(H)}{L-1} \right] \quad \rightarrow \text{crossover}$$

$$m(H, t+1) \geq m(H, t) \cdot N \cdot \frac{f(H)}{\sum_j f_j} \cdot \left[1 - p_c \frac{\delta(H)}{L-1} - p_m \cdot O(H) \right] \quad (1 - p_m) \cdot O(H)$$

Second-order-taylor

$$E(w+h) \approx E(w) + \nabla E(w)^T h + \frac{1}{2} h^T \nabla^2 E(w) h$$

w.r.t. h

$$\nabla E(w+h) = \nabla E(w) + h^T \nabla^2 E(w)$$

Newton method

$$h = - \underbrace{(\nabla^2 E(w))^{-1}}_{\uparrow} \cdot \nabla E(w)$$

$$w(t+1) = w(t) - \hat{0}$$

to be as close as possible to zero

using matrix $\frac{\partial^2 E}{\partial w_i^2}$ diagonal matrix

$$\frac{\nabla E(k) - \nabla E(k-1)}{\Delta w^{(k-1)}} \quad - \text{several steps}$$