

INTELLIGENTNI SISTEMI

OSNOVNI KONCEPTI STROJNEGA UČENJA

Osnovni koncepti strojnega učenja

Prof. Jurij F. Tasič


Emil Plesnik

Uvod v strojno učenje: Teme

1. Polinomsko prilagajanje krivulj
2. Verjetnostna teorija več spremenljivk
3. Največja verjetnost
4. Bayesov pristop
5. Izbira modela
6. Prekletstvo dimenzionalnosti

Polinomsko prilagajanje krivulj

- Imamo realno vhodno spremenljivko x
- x uporabimo za predikcijo vrednosti ciljne spremenljivke t
- Sintetiziramo podatke s funkcijo $\sin(2\pi x)$
- Pri ciljnih vrednostih je prisoten naključni šum



Polinomsko prilagajanje krivulj


Zapišemo:

- N opazovanj x

$$x = (x_1, \dots, x_N)^T$$

$$t = (t_1, \dots, t_N)^T$$

- Cilj je izkoristiti učno množico za predikcijo vrednosti iz x
- Zahteven problem
- Teorija verjetnosti dovoljuje predikcijo



Sinteza podatkov:

$$N = 10$$

Enakomerna porazdeljenost na intervalu $[0,1]$

Ustvarjeno s funkcijo $\sin(2\pi x)$ z dodanim Gaussovimi šumom

Polinomsko prilagajanje krivulj

- Polinomska funkcija

$$y(x, \mathbf{w}) = w_0 + w_1x + w_2x^2 + \dots + w_Mx^M = \sum_{j=0}^M w_jx^j$$

- M je red polinoma
- Ali je večja vrednost M boljša?
- Koeficienti w_0, \dots, w_M sestavljajo vektor \mathbf{w}
- Nelinearna funkcija x , linearna funkcija koeficientov \mathbf{w}
- Klicani linearni modeli


Funkcija napake

Vsota kvadratov napak
med predikcijo $y(x_n, \mathbf{w})$ za
Vsako točko x_n in
ciljno vrednostjo t_n

$$E(\mathbf{w}) = \frac{1}{2} \sum_{n=1}^N \{y(x_n, \mathbf{w}) - t_n\}^2$$

- Rešitev je vrednost w , pri kateri je $E(w)$ najmanjša

Rdeča črta pomeni najboljšo polinomsko ujemanje



Minimizacija funkcije napake

Funkcija napake je kvadratična glede na koeficiente w

- Odvod po koeficientih pomeni

Linearno funkcijo glede na w

- Funkcija napake ima torej

Minimum w^*

- Rezultat je polinom $y(x, w^*)$

$$E(\mathbf{w}) = \frac{1}{2} \sum_{n=1}^N \{y(x_n, \mathbf{w}) - t_n\}^2$$

ker je $y(x, \mathbf{w}) = \sum_{j=0}^M w_j x^j$

$$\begin{aligned} \frac{\partial E(\mathbf{w})}{\partial w_i} &= \sum_{n=1}^N \{y(x_n, \mathbf{w}) - t_n\} x_n^i \\ &= \sum_{n=1}^N \left\{ \sum_{j=0}^M w_j x_n^j - t_n \right\} x_n^i \end{aligned}$$

postavimo izraz na nič



$$\sum_{n=1}^N \sum_{j=0}^M w_j x_n^{i+j} = \sum_{n=1}^N t_n x_n^i$$

Dobimo $M+1$ enačb, ki jih rešimo glede na w^*


Izbira stopnje M

Primerjava modelov ali izbira modelov


- Rdeče črte so najboljše prilagoditve za
 - $M = 0, 1, 3, 9$ in $N=10$



Slaba predstavitev $\sin(2\pi x)$



dobra predstavitev $(2\pi x)$



Najmanjši kvadrat je primer maksimalne verjetnosti

- Omejitev števila parametrov na velikost učne množice ni primerna
- Bolje je izbrati kompleksnost modela glede na kompleksnost problema
- Pristop najmanjših kvadratov je poseben primer maksimalne verjetnosti
 - Lastnost maksimalne verjetnosti je prevelika prilagoditev (Overfitting)
- Z Bayesovim pristopom se izognemo preveliki prilagoditvi
 - Število parametrov lahko močno preseže število podatkovnih točk
 - Efektivno število parametrov se avtomatsko prilagodi velikosti podatkovne množice

Ureditev metode najmanjših kvadratov

- uporaba kompleksnih modelov z omejenimi velikostmi podatkovnih množic
- dodajanje omejitve v funkcijo napake, ki preprečuje koeficientom doseganje velikih vrednosti
 - λ določa relativno pomembnost ureditvenega izraza za funkcijo napake
 - Možna je natančna minimizacija v zaprti obliki
 - Poznano kot skrčitev v statistiki

Osnove adaptivnih sistemov



- Linearno adaptivno sito ali nerekurzivno adaptivno sito je eden osnovnih elementov v adaptivnem procesiranju diskretnih signalov.
- Predpostavimo torej diskreten vhodni signal, ki ima več komponent. Tak vhodni signal lahko zapišemo v obliki vektorja \mathbf{X} . Poleg tega predpostavimo tudi vektor uteži \mathbf{W} , s katerim dejansko vplivamo na komponente vhodnega signala,

Enovhodni primer:

$$X_k = [x_k, x_{k-1} \dots x_{k-L}]^T \quad (2.1)$$

Večvhodni primer:

$$X_k = [x_{0k}, x_{1k} \dots x_{Lk}]^T \quad (2.2)$$



Osnove adaptivnih sistemov

Vektor uteži lahko podobno kot vhodna vektorja zapišemo z izrazom

$$W_k = [w_{0k}, w_{1k}, \dots, w_{Lk}]^T$$

Odnos med vhomom in izhodom lahko torej zapišemo za oba primera izrazimo z

Enovhodni primer:

$$y_k = \sum_{l=1}^L W_{lk} \cdot x_{k-1}$$

Večvhodni primer:

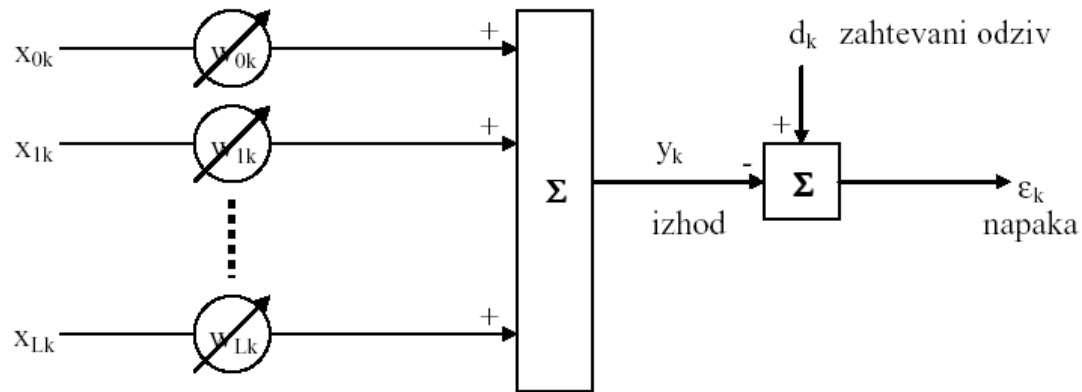
$$y_k = \sum_{l=1}^L W_{lk} \cdot x_{lk}$$

Za oba primera pa lahko odnos med vhomom in izhodom zapišemo tudi z izrazom v vektorski obliki, ki je enaka za oba primera:

$$y_k = X_k^T W_k = W_k^T X_k$$

Večvhodno adaptivno linearno sito

Zapišimo z izrazom napako, ki jo dobimo s principielnim vezjem:



$$\varepsilon_k = d_k - y_k = d_k - X_k^T W = d_k - W^T X_k$$

$$\varepsilon_k^2 = d_k^2 + W^T X_k X_k^T W - 2d_k X_k^T W$$


$$R = E[X_k X_k^T] = E \begin{bmatrix} X_{0k}^2 & X_{0k}X_{1k} & X_{0k}X_{2k} \cdots & X_{0k}X_{Lk} \\ X_{1k}X_{0k} & X_{1k}^2 & X_{1k}X_{2k} \cdots & X_{1k}X_{Lk} \\ \vdots & \vdots & \vdots & \vdots \\ X_{Lk}X_{0k} & X_{Lk}X_{1k} & X_{Lk}X_{2k} & X_{Lk}^2 \end{bmatrix}$$

$$P = E[d_k X_k] = [d_k x_{0k}, d_k x_{1k} \dots d_k x_{Lk}]^T$$

KVADRATIČNA NAPAKA

Srednjo kvadratično napako izrazimo kot

$$MSE = \xi = E[\varepsilon^2] = E[d_k^2] + \mathbf{W}^T \mathbf{R} \mathbf{W} - 2\mathbf{P}^T \mathbf{W}$$



X, Y, Z

Površina paraboloida kvadrata napake

UVOD V OPTIMIZACIJSKE METODE

- terminologija in predpostavke
- metoda manjšanja gradienta
- metoda največje strmine gradienta
- Newton-ova metoda
- samousklajene funkcije
- implementacija

Optimizacija je matematična disciplina, ki se ukvarja z iskanjem minimumov in maksimumov funkcij glede na dane omejitve.

SESTAVNI DELI

- Kriterijska funkcija
- Spremenljivke
- Omejitve

Cilj je poiskati takšne vrednosti spremenljivk, ki minimizirajo ali maksimizirajo kriterijsko funkcijo, upoštevajoč omejitve.

Odločanje

Primeri:

- Odločanje, katere sestavine in v kakšnih količinah dodati, da bo dobljena zmes ustrezala specifikacijam sestave
- Dodeliti razpoložljiva sredstva med različne prejemnike/agencije
- Odločanje, katero pot ubrati do neke nove lokacije

- Odločanje vedno zajema odločitev med različnimi razpoložljivimi možnostmi.

Optimizacijski modeli

- En sam x Večobjektni modeli
- Statični x Dinamični modeli
- Deterministični x Stohastični modeli

Neomejena minimizacija

- terminologija in predpostavke
- metoda manjšanja gradienta
- metoda največje strmine gradienta
- Newton-ova metoda
- implementacija

Recimo, da imamo stroškovno funkcijo (**objective function**)

$$f(\mathbf{x}) : \mathbb{R}^N \longrightarrow \mathbb{R}$$

Cilj je poiskati vrednosti parametrov (**odločitvenih spremenljivk**) \mathbf{x} , ki minimizirajo to funkcijo

$$\mathbf{x}^* = \arg \min_{\mathbf{x}} f(\mathbf{x})$$

Upoštevamo sledeče **omejitve**:


enakost: $c_i(\mathbf{x}) = 0$

neenakost: $c_j(\mathbf{x}) \geq 0$

Če iščemo minimum funkcije $f(\mathbf{x})$ (**profitna funkcija**), je to ekvivalentno iskanju minimuma funkcije $-f(\mathbf{x})$


Practical Optimization

Philip E. Gill, Walter Murray, and Margaret H. Wright,
Academic Press,
1981



Practical Optimization: Algorithms and Engineering Applications

Andreas Antoniou and Wu-Sheng Lu
2007



Numerical Recipes in C (or C++) : The Art of Scientific Computing

William H. Press, Brian P. Flannery, Saul A. Teukolsky,
William T. Vetterling

Good chapter on optimization

Available on line at

(1992 ed.)

www.nrbook.com/a/bookcpdf.php

(2007 ed.) www.nrbook.com





NEOS Guide

www-fp.mcs.anl.gov/OTC/Guide/

This powerpoint presentation

www.utia.cas.cz






Od začetne točke je odvisno, katerega od minimumov bomo našli

Takšen potek je pogost v realnih funkcijah

Predpostavimo, da je začetna točka v bližini globalnega minimuma




Kako določiti minimum?

- Več metod (Dichotomous, Fibonacci, Golden-Section)
- Metode aproksimacije
 1. Polinomska interpolacija
 2. Newton-ova metoda
- Kombinacija obojih (Davies, Swann, in Campey algoritmi)

Oglej si oklepaje in pomen

Kaj pomeni postaviti meji, med katerima je minimum?



Običajno obstaja več lokalnih minimumov x_{left} and x_{right}

Postaviti obe meji pomeni:

Postavitev začetne točke $x_{initial}$, ter korak - *increment*


Ocenimo $f(x_{initial}), f(x_{initial}+increment)$

Zmanjšuj po korakih, dokler funkcija ne naraste,

Napravi korak v obratni smeri z zmanjšanim korakom,
dokler funkcija spet ne naraste,

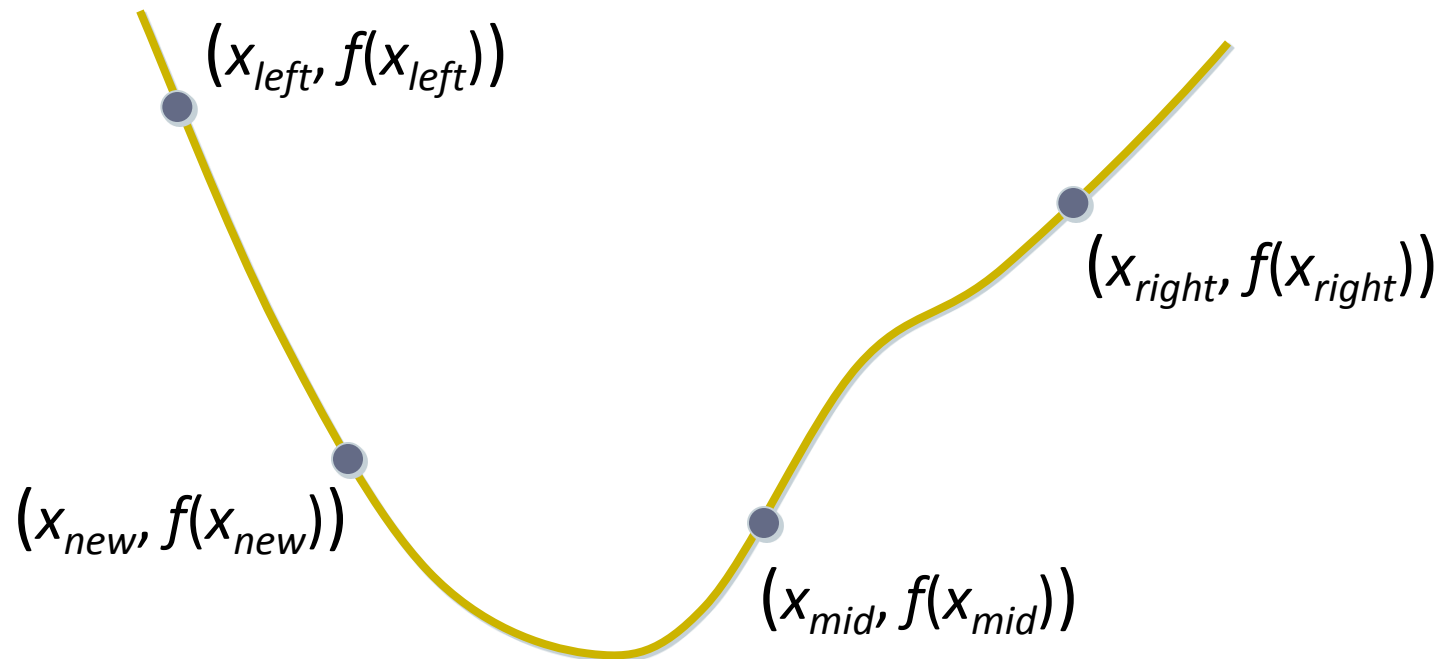
Spremeni korak po vsaki taki iteracijski zanki.

Strategija: oceni funkcijo v novem x_{new}




Strategija: oceni funkcijo v novem x_{new}

Postavi nove meje "bracket" točke so x_{new} , x_{mid} , x_{right}




Strategija: oceni funkcijo v novem x_{new}

Novo točko omejitve so x_{left} , x_{new} , x_{mid}



Poiščimo optimalno točko x_{mid} , glede na levo in desno, tako da zagotavlja enako stopnjo redukcije.



if $f(x_{new}) < f(x_{mid})$
 novi interval = α

else
 novi interval = $1 - \alpha^2$

Da zagotovimo enak interval, želimo $\alpha = 1 - \alpha^2$

Velja,

$$\alpha = \frac{\sqrt{5} - 1}{2} = \bar{\varphi}$$

To je faktor “zlatega reza” = 0.618...

Interval se tako zmanjša za 30% na iteracijo

Linearna konvergenca

V bližini minimuma je odvod = 0, zato velja

$$f(x + \Delta x) = f(x) + \frac{1}{2} f''(x) \Delta x^2 + \dots$$

$$f(x + \Delta x) - f(x) = \frac{1}{2} f''(x) \Delta x^2 = \text{machine } \varepsilon$$

$$\Rightarrow \Delta x \sim \sqrt{\varepsilon}$$

Pravilo palca: nesmiselno je iskati večjo natančnost, kot $\text{sqrt}(\varepsilon)$

Uporaba double precision, če želimo single-precision rezultat (in/ali imamo single-precision podatke)

Kompromis med super in linearno konvergenco za manjšo robustnost

Kombinacija z Zlatim rezom za varnost

Uporabni napotki:

Skozi 3 točke položimo parabolo in poiščemo minimum

Izračunamo odvode in položaje, uporabimo kubično prilagajanje

Uporabimo druge odvode: Newton

Iskalne metode

Začnemo s takšnim intervalom $[x_L, x_U]$, v katerem leži iskani minimum x^* .

Določimo vrednost $f(x)$ v dveh točkah na intervalu.


Zmanjšamo interval.

Ponovimo proces.





- Lahko uporabimo pri vsaki funkciji, odvedljivost ni ovira.

Iskalne metode



Dichotomous





Fibonacci: 1 1 2 3 5 8 ...

1D funkcije

Kot primer vzemimo funkcijo

$$f(x) = 0.1 + 0.1x + x^2 / (0.1 + x^2)$$



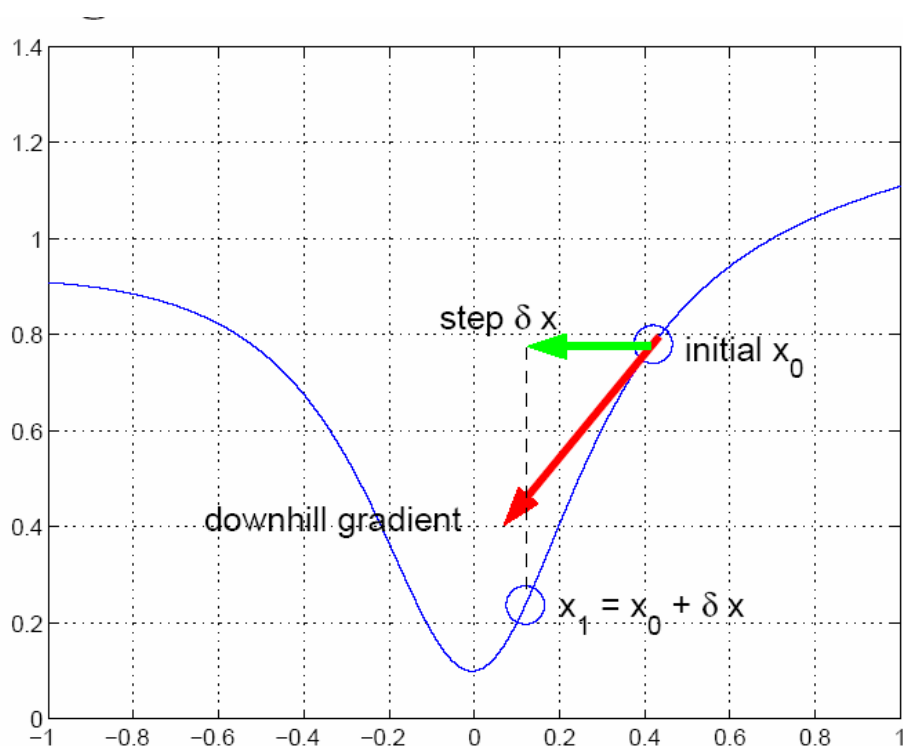
(od sedaj naprej predpostavljamo, da ne poznamo dejanskega funkcijskega izraza)

Zmanjševanje gradienta

Glede na začetno lokacijo, x_0 , določimo df/dx

In se pomikamo navzdol po krivulji odvoda

da ustvarimo nov približek, $x_1 = x_0 + \delta x$



Kako določimo velikost koraka δx ?

Metode zmanjševanja

$$x^{(k+1)} = x^{(k)} + t^{(k)} \Delta x^{(k)} \quad \text{with } f(x^{(k+1)}) < f(x^{(k)})$$

- other notations: $x^+ = x + t\Delta x$, $x := x + t\Delta x$
- Δx is the *step*, or *search direction*; t is the *step size*, or *step length*
- from convexity, $f(x^+) < f(x)$ implies $\nabla f(x)^T \Delta x < 0$
(i.e., Δx is a *descent direction*)

General descent method.

given a starting point $x \in \text{dom } f$.

repeat

1. Determine a descent direction Δx .
2. *Line search.* Choose a step size $t > 0$.
3. *Update.* $x := x + t\Delta x$.

until stopping criterion is satisfied.

Linijsko iskanje


Natančno linijsko iskanje: $t = \operatorname{argmin}_{t>0} f(x + t\Delta x)$

Vzvratno linijsko iskanje (parametri $\alpha \in (0, 1/2)$, $\beta \in (0, 1)$)

- začetek $t = 1$, ponavljaj $t := \beta t$ dokler

$$f(x + t\Delta x) < f(x) + \alpha t \nabla f(x)^T \Delta x$$

- Grafična interpretacija : vzvratno dokler $t \leq t_0$



Metoda zmanjševanja gradienta

Splošna gradientna metoda

$$\Delta x = -\nabla f(x)$$

glede na začetno točko $x \in \text{dom } f$.

ponavlja

1. $\Delta x := -\nabla f(x)$.
2. Linijsko iskanje. Izberi korak t glede na natančno ali vzvratno linijsko iskanje
3. Posodobi $x := x + t\Delta x$.

Dokler ni zadoščten ustavitveni kriterij

- Ustavitveni kriterij je običajno podan v obliki $\|\nabla f(x)\|_2 \leq \epsilon$
- Rezultat konvergence: za močno koveksne f

$$f(x^{(k)}) - p^* \leq c^k (f(x^{(0)}) - p^*)$$

$c \in (0, 1)$ odvisno od $m, x^{(0)}$, tipa linijskega iskanja

- Zelo preprosto, vendar pogosto počasno, redko uporabljano



Polinomska interpolacija

- Zajem minimuma v intervalu.
- Uporaba kvadratne ali kubične funkcije za interpolacijo nekaterih točk $f(x)$ na intervalu.
- Pomik na lahko določljiv minimum izbranega polinoma.
- Zavržemo najslabšo točko in ponovimo proces.





Newton-ova metoda

- Globalno gledano je konvergenca Newton-ove metode slaba.
- Pogosto odpove, če je začetna točka preveč oddaljena od minimuma.



Razširitev na N (multivariantne) dimenzije

- Kako velik je lahko N?
 - Velikosti variirajo od zgolj nekaj do več tisoč parametrov
- Obravnavali bomo primer za $N=2$, da bo lahko vizualizirana stroškovna funkcija.

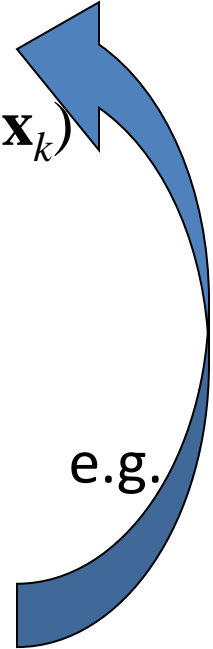


Optimizacijski algoritem

- Začetna točka \mathbf{x}_0 , $k = 0$.
1. Izračunamo smer iskanja \mathbf{p}_k
 2. Izračunamo dolžino koraka α_k , da bo $f(\mathbf{x}_k + \alpha_k \mathbf{p}_k) < f(\mathbf{x}_k)$
 3. Določimo $\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{p}_k$
 4. Preverimo približevanje (kriteriji)
 $df/d\mathbf{x} = \mathbf{0}$

e.g.

$k = k+1$



Taylor-jeva razširitev

Vsako funkcijo lahko razvijemo v Taylorjevo vrsto okrog točke \mathbf{x}^*

$$f(\mathbf{x}^* + \mathbf{x}) \approx f(\mathbf{x}^*) + \nabla f^T \mathbf{x} + \frac{1}{2} \mathbf{x}^T \mathbf{H} \mathbf{x}$$

Kjer je gradient $\nabla f(\mathbf{x}^*)$ vektor

$$\nabla f(\mathbf{x}^*) = \left[\frac{\partial f}{\partial x_1} \cdots \frac{\partial f}{\partial x_N} \right]^T$$

In $\mathbf{H}(\mathbf{x}^*)$ Hessova simetrična matrika

$$\mathbf{H}(\mathbf{x}^*) = \begin{bmatrix} \frac{\partial^2 f}{\partial x_1^2} & \cdots & \frac{\partial^2 f}{\partial x_1 \partial x_N} \\ \vdots & & \vdots \\ \frac{\partial^2 f}{\partial x_N \partial x_1} & \cdots & \frac{\partial^2 f}{\partial x_N^2} \end{bmatrix}$$

Kvadratne funkcije

$$f(\mathbf{x}) = a + \mathbf{g}^T \mathbf{x} + \frac{1}{2} \mathbf{x}^T \mathbf{H} \mathbf{x}$$

- Vektor \mathbf{g} in Hessova matrika \mathbf{H} sta constantna.
- Aproksimacija drugega reda katerekoli funkcije s Taylorjevo razširitvijo je kvadratna funkcija.

Predpostavili bomo samo kvadratne funkcije.

Potrebni pogoji za minimum

$$f(\mathbf{x}) = a + \mathbf{g}^T \mathbf{x} + \frac{1}{2} \mathbf{x}^T \mathbf{H} \mathbf{x}$$

Razširimo $f(\mathbf{x})$ okrog stacionarne točke \mathbf{x}^* v smeri \mathbf{p}

$$\begin{aligned} f(\mathbf{x}^* + \alpha \mathbf{p}) &= f(\mathbf{x}^*) + \mathbf{g}(\mathbf{x}^*)^T \alpha \mathbf{p} + \frac{1}{2} \alpha^2 \mathbf{p}^T \mathbf{H} \mathbf{p} \\ &= f(\mathbf{x}^*) + \frac{1}{2} \alpha^2 \mathbf{p}^T \mathbf{H} \mathbf{p} \end{aligned}$$

Ker v stacionarni točki velja $\mathbf{g}(\mathbf{x}^*) = 0$

V stacionarni točki je obnašanje funkcije določeno s \mathbf{H}

-
- \mathbf{H} je simetrična matrika, zato ima ortogonalne lastne vektorje

$$\mathbf{H}\mathbf{u}_i = \lambda_i \mathbf{u}_i \quad \|\mathbf{u}_i\| = 1$$

$$\begin{aligned} f(\mathbf{x}^* + \alpha \mathbf{u}_i) &= f(\mathbf{x}^*) + \frac{1}{2} \alpha^2 \mathbf{u}_i^T \mathbf{H} \mathbf{u}_i \\ &= f(\mathbf{x}^*) + \frac{1}{2} \alpha^2 \lambda_i \end{aligned}$$

- Ko se $|\alpha|$ povečuje, se $f(\mathbf{x}^* + \alpha \mathbf{u}_i)$ povečuje, zmanjšuje ali je nespremenljiva glede na to, ali je λ_i pozitiven, negativen ali nič


Primeri kvadratnih funkcij

Primer1: obe lastni vrednosti sta pozitivni


$$f(\mathbf{x}) = a + \mathbf{g}^T \mathbf{x} + \frac{1}{2} \mathbf{x}^T \mathbf{H} \mathbf{x}$$

z

$$a = 0, \quad \mathbf{g} = \begin{bmatrix} -50 \\ -50 \end{bmatrix}, \quad \mathbf{H} = \begin{bmatrix} 6 & 4 \\ 4 & 6 \end{bmatrix} \begin{array}{l} \text{Pozitivno} \\ \text{določeno} \end{array}$$



minimum




Primeri kvadratnih funkcij

Primer1: lastni vrednosti imata različen predznak


$$f(\mathbf{x}) = a + \mathbf{g}^T \mathbf{x} + \frac{1}{2} \mathbf{x}^T \mathbf{H} \mathbf{x}$$

z

$$a = 0, \quad \mathbf{g} = \begin{bmatrix} -30 \\ 20 \end{bmatrix}, \quad \mathbf{H} = \begin{bmatrix} 6 & 0 \\ 0 & -4 \end{bmatrix} \text{ nedoločeno}$$



sedlo




Primeri kvadratnih funkcij

Primer1: obe lastni vrednosti sta enaki 0


$$f(\mathbf{x}) = a + \mathbf{g}^T \mathbf{x} + \frac{1}{2} \mathbf{x}^T \mathbf{H} \mathbf{x}$$

z

$$a = 0, \quad \mathbf{g} = \begin{bmatrix} 0 \\ 0 \end{bmatrix}, \quad \mathbf{H} = \begin{bmatrix} 6 & 0 \\ 0 & 0 \end{bmatrix} \quad \begin{array}{l} \text{Pozitivno} \\ \text{poldoločeno} \end{array}$$



parabolični cilinder



Optimizacija kvadratnih funkcij

Predpostavimo, da je \mathbf{H} pozitiven in določen

$$f(\mathbf{x}) = a + \mathbf{g}^T \mathbf{x} + \frac{1}{2} \mathbf{x}^T \mathbf{H} \mathbf{x}$$

$$\nabla f(\mathbf{x}) = \mathbf{g} + \mathbf{H} \mathbf{x}$$

Obstaja edinstven minimum

$$\mathbf{x}^* = -\mathbf{H}^{-1} \mathbf{g}$$

Če je N velik, potem ta inverzija ni direktno mogoča.

Najstrmejše zmanjševanje

- Osnovni princip je minimizirati N-dimenzionalno funkcijo s serijo 1D premočrtnih-minimizacij:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{p}_k$$

- Metoda najstrmejšega zmanjševanja izbere \mathbf{p}_k tako, da je vzporeden z gradientom

$$\mathbf{p}_k = -\nabla f(\mathbf{x}_k)$$

- Korak α_k je izbran tako da minimizira $f(\mathbf{x}_k + \alpha_k \mathbf{p}_k)$.


Za kvadratične oblike obstaja rešitev:

$$\alpha_k = \frac{\mathbf{p}_k^T \mathbf{p}_k}{\mathbf{p}_k^T \mathbf{H} \mathbf{p}_k}$$



Dokaži!

Najstrmejšje zmanjševanje



- Gradient je povsod pravokoten na linije.
- Po vsaki premočrtni minimizaciji je novi gradient vedno ortogonalen na smer predhodnega koraka.
- Posledično, imajo iteracije cik-cak smer.

Konjugirani gradient

- Vsak \mathbf{p}_k je določen kot konjugirana vrednost prejšnjih smeri glede na \mathbf{H} :


$$\mathbf{p}_i^T \mathbf{H} \mathbf{p}_j = 0, \quad i \neq j$$

- Sledi: linearna neodvisnost smeri iskanja.
- \mathbf{p}_k lahko izberemo zgolj glede na poznavanje \mathbf{p}_{k-1} , $\nabla f(\mathbf{x}_{k-1})$, and $\nabla f(\mathbf{x}_k)$

$$\mathbf{p}_k = \nabla f_k + \left(\frac{\nabla f_k^T \nabla f_k}{\nabla f_{k-1}^T \nabla f_{k-1}} \right) \mathbf{p}_{k-1}$$

Konjugirani gradient



- N-dimenzionalno kvadratno obliko je mogoče minimizirati v največ N korakih konjugiranega gradienta.



- Primer s tremi različnimi začetnimi točkami.
- Minimum je dosežen v natanko dveh korakih.

Optimizacija za splošne funkcije



$$f(x, y) = \exp(x)(4x^2 + 2y^2 + 4xy + 2x + 1)$$



Metode, ki uporabljajo kvadratično Taylorjevo razširitev v vrsto

Rosenbrock-ova funkcija



$$f(x, y) = 100(y - x^2)^2 + (1 - x)^2$$



Minimum pri [1, 1]

Najstrmejši spusta


- 1-D premočrtna minimizacije je izvedena z uporabo ene od prej navedenih metod (običajno kubična polinomska interpolacija)



- Razvidno je cik-cak obnašanje (levo)
- Algoritem počasi napreduje proti minimumu ("down the valey")

Konjugirani gradient

- Ponovno je potrebna uporaba eksplicitne premočrtne minimizacije v vsakem koraku



- Algoritem je končan po 98 iteracijah
- Boljše kot metoda najstrmejšega zmanjševanja

Newtonova metoda

Razširimo $f(\mathbf{x})$ v Taylorjevo vrsto okrog točke \mathbf{x}_k

$$f(\mathbf{x}_k + \delta\mathbf{x}) \approx f(\mathbf{x}_k) + \mathbf{g}_k^T \delta\mathbf{x} + \frac{1}{2} \delta\mathbf{x}^T \mathbf{H}_k \delta\mathbf{x}$$

Pri tem je gradientni vektor

$$\mathbf{g}_k = \nabla f(\mathbf{x}_k) = \left[\frac{\partial f}{\partial x_1} \cdots \frac{\partial f}{\partial x_N} \right]^T$$

In Hessova simetrična matrika

$$\mathbf{H}_k = \mathbf{H}(\mathbf{x}_k) = \begin{bmatrix} \frac{\partial^2 f}{\partial x_1^2} & \cdots & \frac{\partial^2 f}{\partial x_1 \partial x_N} \\ \vdots & \ddots & \vdots \\ \frac{\partial^2 f}{\partial x_N \partial x_1} & \cdots & \frac{\partial^2 f}{\partial x_N^2} \end{bmatrix}$$

Newtonova metoda

V minimumu velja $\nabla f(\mathbf{x}) = \mathbf{0}$, torej

$$\nabla f(\mathbf{x}) = \mathbf{g}_k + \mathbf{H}_k \delta \mathbf{x} = \mathbf{0}$$

Z rešitvijo $\delta \mathbf{x} = -\mathbf{H}_k^{-1} \mathbf{g}_k$. Rezultat je iterativni izračun


$$\mathbf{x}_{k+1} = \mathbf{x}_k - \mathbf{H}_k^{-1} \mathbf{g}_k$$

- Če je $f(\mathbf{x})$ kvadratna, potem najdemo rešitev v enem koraku.
- Metoda ima kvadratno konvergenco (kot v 1D primeru).
- Rešitev $\delta \mathbf{x} = -\mathbf{H}_k^{-1} \mathbf{g}_k$ je gotovo v smeri zmanjševanja.
- Boljše, kot skočiti direktno v minimum, je uporabiti premočrtno minimizacijo, ki zagotavlja globalno konvergenco

$$\mathbf{x}_{k+1} = \mathbf{x}_k - \alpha_k \mathbf{H}_k^{-1} \mathbf{g}_k$$

- Če je $\mathbf{H}=\mathbf{I}$ potem se to poenostavi v najstrmejše zmanjševanje.

Newtonova metoda – primer



- Algoritem najde minimum po samo 18 iteracijah v primerjavi z 98-imi konjugiranega gradienta.
- Kljub temu pa metoda zahteva izračun Hessove matrike pri vsaki iteraciji, kar pa ni vedno izvedljivo.

Kvazi-Newtonove metode

- Če je velikost problema velika in je Hessova matrika gosta, potem je lahko direkten izračun neizvedljiv.
- Kvazi-Newtonove metode zaobidejo ta problem z uporabo približka matrike $H(x)$, ki ga posodablja ob vsaki iteraciji.
- Skupne sheme so Broyden, Goldfarb, Fletcher and Shanno (BFGS) in Davidson, Fletcher and Powell (DFP).
- Osnovni princip izkorišča, da lahko pri kvadratnih funkcijah določimo \mathbf{H} na podlagi \mathbf{g}_k in \mathbf{x}_k .

$$\mathbf{g}^{k+1} - \mathbf{g}^k = \mathbf{H}(\mathbf{x}_{k+1} - \mathbf{x}_k)$$

Metode konjugiranega gradienta

- Konjugirani gradient implicitno pridobi informacijo o Hessovi matriki
- Za kvadratno funkcijo v n dimenzijah pridobi natančno rešitev v n korakih (ob neupoštevanju napake zaokroževanja)
- Deluje dobro v praksi...

Metode vrednotenja v več dimenzijah

- Če ni mogoče ovrednotiti gradienta, imamo težave
- Lahko uporabimo približne (numerično ocenjene) gradiente:

$$\nabla f(x) = \begin{pmatrix} \frac{\partial f}{\partial e_1} \\ \frac{\partial f}{\partial e_2} \\ \frac{\partial f}{\partial e_3} \\ \vdots \end{pmatrix} \approx \begin{pmatrix} \frac{f(x+\delta \cdot e_1) - f(x)}{\delta} \\ \frac{f(x+\delta \cdot e_2) - f(x)}{\delta} \\ \frac{f(x+\delta \cdot e_3) - f(x)}{\delta} \\ \vdots \end{pmatrix}$$

Strategije generične optimizacije

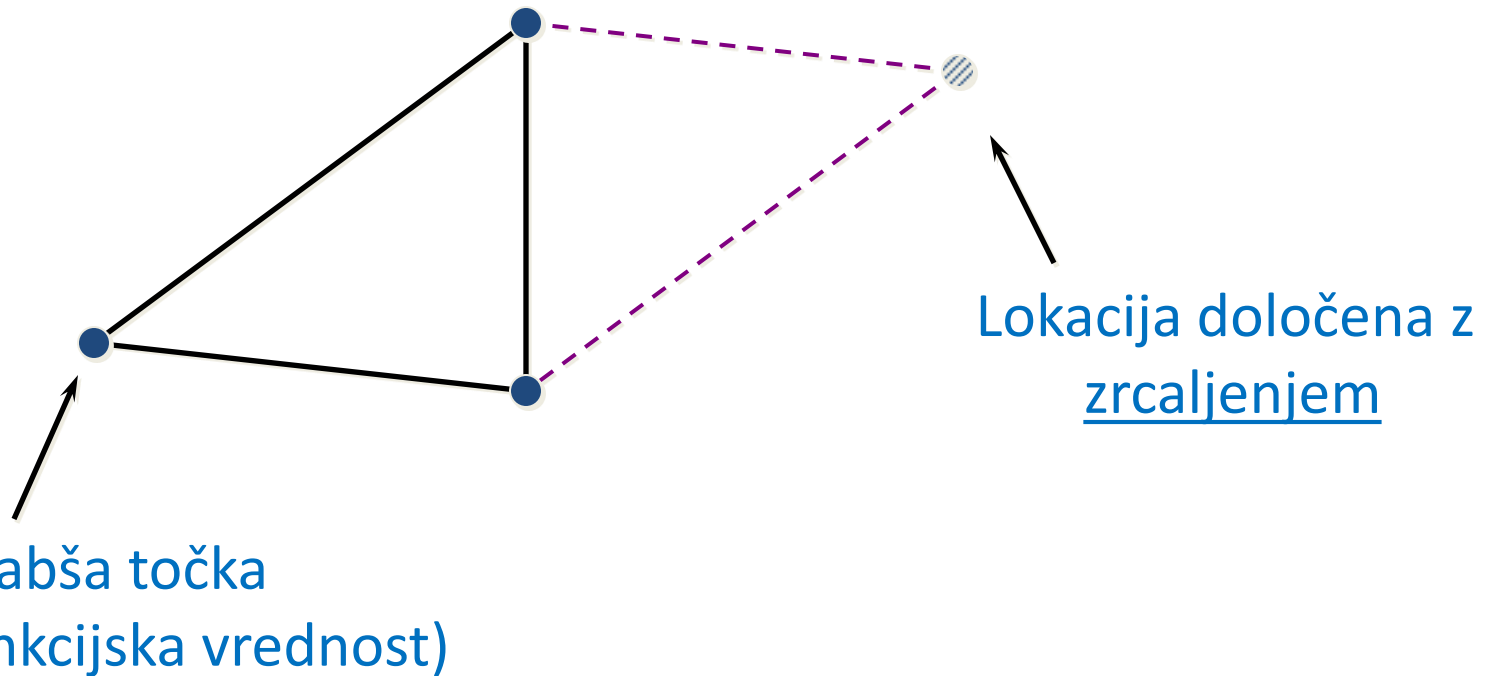
- Enotno vzorčenje:
 - Zahtevnost narašča eksponentno s številom dimenzij
- Simulirano žarjenje:
 - Iskanje v naključnih smereh
 - Na začetku z velikimi koraki, ki jih postopno zmanjšujemo
 - “Razpored žarjenja” – kako hitro upočasniti?

Simplex metoda (Nelder-Mead)

- Sledimo $n+1$ točkam v n dimenzijah
 - Vozlišča *simplex* (trikotnik v 2D tetraeder v 3D, itd.)
- Pri vsaki iteraciji: simplex se lahko premakne, razširi ali skrči
 - Poznana tudi kot *ameba metoda*: simplex “izžareva” vzdolž funkcije


Simplex metoda (Nelder-Mead)

- Osnovna operacija: zrcaljenje



Simplex metoda (Nelder-Mead)


- Če je zrcaljenje določilo najboljšo (najmanjšo) vrednost do sedaj, potem poskusimo še z razširjanjem



- V nasprotnem primeru, če je zrcaljenje učinkovalo v kakršni koli meri, ga nadaljujemo

Simplex metoda (Nelder-Mead)

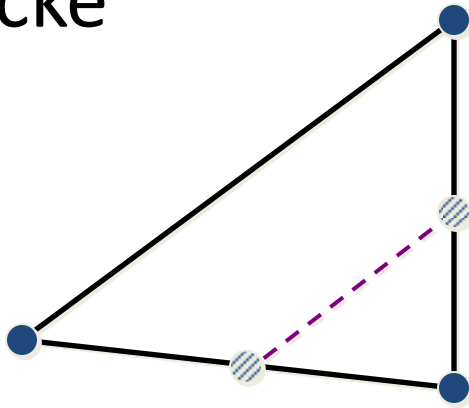
- Če zrcaljenje ni učinkovalo (zrcaljena točka je še vedno najslabša) poskusimo s krčenjem



Lokacija določena s
krčenjem

Simplex metoda (Nelder-Mead)

- Če ni delovala nobena od prej omenjenih operacij, zmanjšamo simplex okrog *najboljše* točke




Simplex metoda (Nelder-Mead)

- Metoda je precej učinkovita ob vsaki iteraciji (tipično 1 – 2 oceni funkcije)
- Lahko zahteva *veliko* iteracij
- Nekoliko nezanesljiva – včasih je potreben *ponoven začetek* zaradi sesedanja simplex-a
- Prednosti: preprosta za implementacijo, ne potrebuje odvoda, ni odvisna od gladkosti funkcije itd.



Rosenbrock-ova funkcija

- Oblikovana posebej za preizkušanje optimizacijskih tehnik
- Ukrivljena, ozka dolina

$$f(x, y) = 100(y - x^2)^2 + (1 - x)^2$$



Metoda Simplex



Optimizacije z omejitvijo

$$f(\mathbf{x}) : \mathbb{R}^N \longrightarrow \mathbb{R}$$

$$\mathbf{x}^* = \arg \min_{\mathbf{x}} f(\mathbf{x})$$


Glede nas:

- Omejitvene enačbe: $a_i(\mathbf{x}) = 0 \quad i = 1, 2, \dots, p$
- Omejitvene neenačbe : $c_j(\mathbf{x}) \geq 0 \quad j = 1, 2, \dots, q$
- Omejitve določajo dopustna področja, ki so neprazna.
- Osnovna ideja je pretvorba problema z omejitvijo v problem brez omejitve.

Omejitvene enačbe

- Minimizirajmo $f(\mathbf{x})$ glede na: $a_i(\mathbf{x}) = 0$ za $i = 1, 2, \dots, p$
- Gradient funkcije $f(\mathbf{x})$ v lokalni točki minimizacije je enak linearni kombinaciji gradientov omejitev $a_i(\mathbf{x})$ z **Lagrange-ovimi multiplikatorji kot** koeficienti.


$$\nabla f(\mathbf{x}^*) = \sum_{i=1}^p \lambda_i^* \nabla a_i(\mathbf{x}^*)$$



$$f_3 > f_2 > f_1$$


$\tilde{\mathbf{x}}$ ni točka minimuma

\mathbf{x}^* je točka minimuma,
 $\lambda^* > 0$



$$f_3 > f_2 > f_1$$


\mathbf{x}^* je točka minimuma,
 $\lambda^* < 0$



$$f_3 > f_2 > f_1$$

\mathbf{x}^* ni točka minimuma

3D Primer




$$a_1(\mathbf{x}) = -x_1 + x_3 - 1 = 0$$

$$a_2(\mathbf{x}) = x_1^2 + x_2^2 - 2x_1 = 0$$

3D Primer

$$f(\mathbf{x}) = x_1^2 + x_2^2 + \frac{1}{4}x_3^2$$




$$f(\mathbf{x}) = 3$$

Gradienti omejitev in kriterijske funkcije so linearno neodvisni.

3D Primer

$$f(\mathbf{x}) = x_1^2 + x_2^2 + \frac{1}{4}x_3^2$$

-





$$f(\mathbf{x}) = 1$$

Gradienti omejitev in kriterijske funkcije so linearno odvisni.


Omejitvene neenačbe

- minimiziraj $f(\mathbf{x})$ glede na: $c_j(\mathbf{x}) \geq 0$ za $j = 1, 2, \dots, q$
- Gradient funkcije $f(\mathbf{x})$ v točki lokalnega minimuma je enak linerani kombinaciji gradientov omejitve $c_j(\mathbf{x})$, ki je aktivna v ($c_j(\mathbf{x}) = 0$)
- in **Lagrange-ovi multiplikatorji** morajo biti pozitivni, $\mu_j \geq 0, j \in A$

$$\nabla f(\mathbf{x}^*) = \sum_{j \in A} \mu_j^* \nabla c_j(\mathbf{x}^*)$$



V točki \mathbf{x}^* ni aktivnih omejitev, tam je
 $\nabla f(\mathbf{x}) = \mathbf{0}$



\mathbf{x}^* ni optimalna, $\mu < 0$

$f_3 > f_2 > f_1$

Xje optimalna, $\mu > 0$

Lagrangien

- Uvedimo novo funkcijo (Lagrangien)

$$L(\mathbf{x}, \boldsymbol{\lambda}, \boldsymbol{\mu}) = f(\mathbf{x}) - \sum_{i=1}^p \lambda_i a_i(\mathbf{x}) - \sum_{j=1}^q \mu_j c_j(\mathbf{x})$$

- Potreben pogoj za obstoj lokalnega minimuma

$$\nabla_x L(\mathbf{x}, \boldsymbol{\lambda}, \boldsymbol{\mu}) = \mathbf{0}$$

in mora biti dovoljena točka(i.e. znotraj omejitev).

- To so znani Karush-Kuhn-Tucker-jevi pogoji

Kvadratično programiranje (QP)

- Zakaj je pomembno?
- Ker generalne probleme rešujemo kot nize z njihovo kvadratično aproksimacijo.
- QP z omejitvami

Minimiziraj $f(\mathbf{x}) = \frac{1}{2}\mathbf{x}^T \mathbf{H}\mathbf{x} + \mathbf{x}^T \mathbf{p}$

glede na linearne omejitve.

- \mathbf{H} je simetrična in pozitivno semidefinitna.

QP z omejitvenimi enačbami

- Minimiziraj $f(\mathbf{x}) = \frac{1}{2}\mathbf{x}^T \mathbf{H}\mathbf{x} + \mathbf{x}^T \mathbf{p}$
Glede na: $\mathbf{A}\mathbf{x} = \mathbf{b}$

- \mathbf{A} je $p \times N$ in je polno vrstični rank($p < N$)
- Prevedemo v neomejen problem z eliminacijo spremenljivk:

$$\mathbf{x} = \mathbf{Z}\boldsymbol{\phi} + \mathbf{A}^+\mathbf{b}$$

\mathbf{Z} je ničelni prostor \mathbf{A}

\mathbf{A}^+ je pseudo-inverz.

Minimiziraj

$$\hat{f}(\boldsymbol{\phi}) = \frac{1}{2}\boldsymbol{\phi}^T \hat{\mathbf{H}}\boldsymbol{\phi} + \boldsymbol{\phi}^T \hat{\mathbf{p}}$$

$$\hat{\mathbf{H}} = \mathbf{Z}^T \mathbf{H}\mathbf{Z}$$

$$\hat{\mathbf{p}} = \mathbf{Z}^T (\mathbf{H}\mathbf{A}^+\mathbf{b} + \mathbf{p})$$

Ta kvadratični problem .

QP omejitvenimi neenačbami

- Minimiziraj $f(\mathbf{x}) = \frac{1}{2}\mathbf{x}^T \mathbf{H}\mathbf{x} + \mathbf{x}^T \mathbf{p}$

Subject to: $\mathbf{A}\mathbf{x} \geq \mathbf{b}$

- Prvo verificiraj dopustnost rešitve enačbe $\mathbf{x}^* = -\mathbf{H}^{-1}\mathbf{p}$

- Če je tako, potem je rešitev znana.

Če je tako potem rešitev leži na meji omejitve tako da nadaljujemo z **metodo aktivnega-niza**.

- \mathbf{x}_k trenutna dopustna točka
- \mathcal{A}_k je indeks aktivnih omejitev v \mathbf{x}_k
- Naslednja točka je dana z

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{d}_k$$

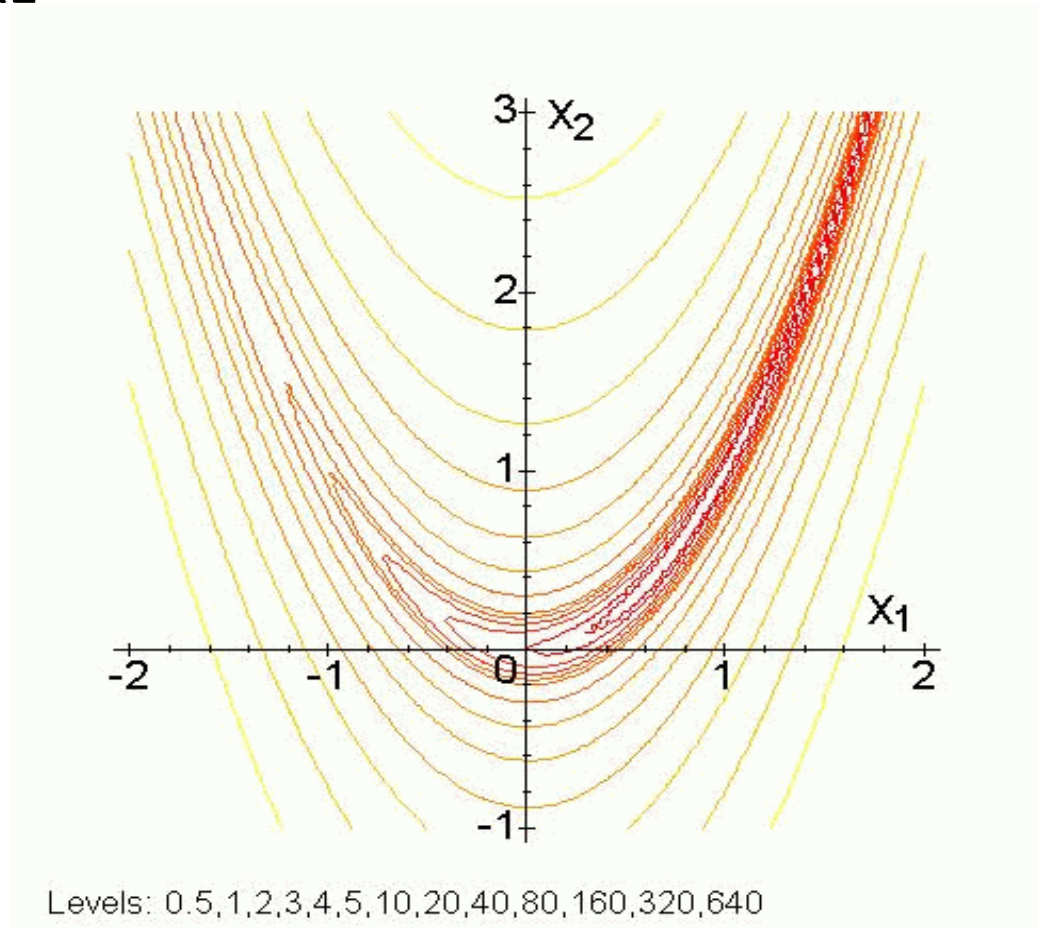
OPTIMIZACIJSKE TEHNIKE

Neomejena
multiparameterska
optimizacijska metoda.

Težave s tipičnimi problemi.



Rosenbrockova “banana”
funkcija

$$F=100(x_2-x_1^2)^2+(x_1-1)^2$$





OPTIMIZACIJSKE TEHNIKE

Nelder-Mead-ova sekvenčna metoda Simplex





OPTIMIZACIJSKE TEHNIKE

Metoda najhitrejšega spusta





OPTIMIZACIJSKE TEHNIKE

Efekt skaliranja





OPTIMIZACIJSKE TEHNIKE

Powellova metoda konjugiranih smeri





OPTIMIZACIJSKE TEHNIKE

Fletcher-Reeves-ova metoda Konjugiranih Gradientov





OPTIMIZACIJSKE TEHNIKE

Newtonova Metoda




OPTIMIZACIJSKE TEHNIKE

Kvazi Newtonova Metoda



OPTIMIZACIJSKE TEHNIKE

Primer kriterijske funkcije znotraj dopustnega področja.



- Minimiziraj funkcijo

$$f(x, y) = 0.5(\alpha x^2 + y^2)$$
$$-11 \leq x, y \leq 11$$

- Minimiziraj funkcijo

$$f(x, y) = \cos(x) \cos(y)$$
$$-4 \leq x, y \leq 4$$

Začetna točka

Konvergenca k globalnemu min/max.

Razredi lepih optimizacijskih problemov problems

Primer: $f(x,y) = 0.5(\alpha x^2 + y^2)$, $\alpha > 0$


Vsak lokalni, je tudi globalni minimum.

**Nezvezna in neodvedljiva funkcija \Rightarrow
ne moremo izračunati gradienta \Rightarrow
ne moremo uporabiti gradientne metode**

Nelder-Mead Metoda

Druge

Niz C je **konveksen** če je vsaka točka segmenta linije, ki povezuje točki x in y znotraj C .




convex



concave

Konveksno telo - hull niza točk X je minimalni konveksni niz, ki vsebuje točke X .



Simplex ali **n -simplex** je konveksno telo reda $(n + 1)$.

Simplex je n -dimenzionalno telo trikotne oblike.


Primer:

1-simplex je linijski segment

2-simplex je trikotnik

3-simplex je tetraeder

4-simplex je pentatope





n = število spremenljivk, $n+1$ točk


Oblikujemo metodo Simplex za vse točke; konveksno telo pomikamo v smeri proč od najslabše točke, z najslabšo vrednostjo kriterijske funkcije in sicer z operacijami: zrcaljenja, širjenja, krčenja, zmanjševanja reda


Primer:


2 spremenljivki \Rightarrow 3 točke \Rightarrow simplex je trikotnik


3 spremenljivke \Rightarrow 4 točke \Rightarrow simplex je tetraeder























Matematične osnove Optimizacije pomenijo Kuhn Tucker-jeve potrebne pogoje

Primer problema matematičnega programiranja

Minimiziraj: $y(x)$

Glede na: $f_i(x) \leq 0$ za $i = 1, 2, \dots, h$

$f_i(x) = 0$ za $i = h+1, \dots, m$

$y(x)$ in $f_i(x)$ so dvakrat odvedljive realne funkcije.

Kuhn Tucker potrebni pogoji

Lagrangeova Funkcija

– pretvori omejen problem v neomejenega

$$L(x, \lambda) = y(x) + \sum_{i=1}^h \lambda_i \left[f_i(x) + x_{n+i}^2 \right] + \sum_{i=1}^m \lambda_i f_i(x)$$

λ_i so Lagrangeovi multiplikatorji

x_{n+i} so pomožne spremenljivke uporabne pri pretvorbi omejitvenih neenačb v enačbe.

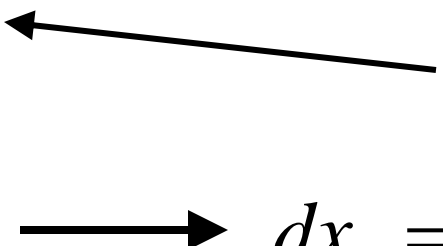
Lagrangeovi Multiplikatorji

Uporabljeni kot:

- **Nedoločeni multiplikatorji** – pomnoži omejitve z λ_i in jih prišteje k $y(\mathbf{x})$
- **Spremenljivke** - $L(x, \lambda)$
- **Konstante** – numerične vrednosti v točki optimuma.

Lagrangeovi Multiplikatorji

optimiziraj: $y(x_1, x_2)$
glede na: $f(x_1, x_2) = 0$

$$dy = \frac{\partial y}{\partial x_1} dx_1 + \frac{\partial y}{\partial x_2} dx_2$$
$$0 = \frac{\partial f}{\partial x_1} dx_1 + \frac{\partial f}{\partial x_2} dx_2 \quad \longrightarrow \quad dx_2 = -\frac{\frac{\partial f}{\partial x_1}}{\frac{\partial f}{\partial x_2}} dx_1$$


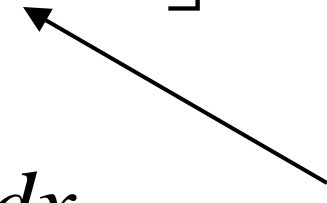
Lagrangeovi Multiplikatorji

$$dy = \frac{\partial y}{\partial x_1} dx_1 - \frac{\partial y}{\partial x_2} \frac{\frac{\partial f}{\partial x_1}}{\frac{\partial f}{\partial x_2}} dx_1$$

Preuredi delne odvode v drugem izrazu

Lagrangeovi Multiplikatorji

$$dy = \left[\frac{\partial y}{\partial x_1} + \left(\frac{-\frac{\partial y}{\partial x_2}}{\frac{\partial f}{\partial x_2}} \right) \frac{\partial f}{\partial x_1} \right] dx_1$$

$$dy = \left[\frac{\partial y}{\partial x_1} + \lambda \frac{\partial f}{\partial x_1} \right] dx_1 \quad () = \lambda$$


Prispeva razmerje delnih odvodov v () kot Lagrangeove multiplikatorje λ

Lagrangeovi multiplikatorji λ so razmerje delnih odvodov v točki optimuma.

Lagrangeovi multiplikatorji λ

$$dy = \frac{\partial(y + \lambda f)}{\partial x_1} dx_1 = 0$$

Določi $L = y + \lambda f$, neomejeno funkcijo

$$\frac{\partial L}{\partial x_1} = 0 \quad \text{in po istem postopku} \quad \frac{\partial L}{\partial x_2} = 0$$

Interpretirajmo L kot neomejeno funkcijo, delni odvodi, katerih vrednost je nič, predstavljajo potrebne pogoje te neomejene funkcije.

Lagrangeovi multiplikatorji λ

Optimirajmo: $y(x_1, x_2)$
glede na: $f(x_1, x_2) = b$

Glede na zahteve dobimo:

$$\frac{\partial y}{\partial b} = -\lambda$$

Oz po sposameznih i :

$$\frac{\partial y}{\partial b_i} = -\lambda_i \quad \text{delni strošek (cena na enoto } b_i)$$

Splošne zahteve linearnega programiranja

kriterijska funkcija:

$$\text{Maksimiraj: } c_1x_1 + c_2x_2 + \dots + c_nx_n = p \quad (4-1a)$$

Omejitvene enačbe:

$$\text{glede na: } a_{11}x_1 + a_{12}x_2 + \dots + a_{1n}x_n \leq b_1 \quad (4-1b)$$

$$a_{21}x_1 + a_{22}x_2 + \dots + a_{2n}x_n \leq b_2$$

$$\dots \quad \dots \quad \dots$$

$$\dots \quad \dots \quad \dots$$

$$a_{m1}x_1 + a_{m2}x_2 + \dots + a_{mn}x_n \leq b_m$$

$$x_j \geq 0 \quad \text{za } j = 1, 2, \dots, n \quad (4-1c)$$

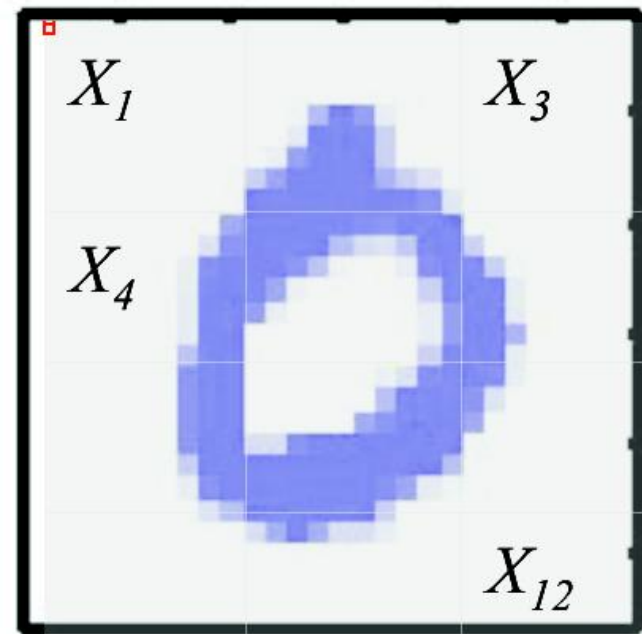

Pregled strojnega učenja

Vsebina

1. Kaj je strojno učenje (Machine Learning - ML)?
2. Tipi obdelave informacij
 - Rešeni problemi
 1. Regresija
 2. Klasifikacija
 3. Grozdenje
 4. Verjetnostno sklepanje
3. Nova gibanja
 1. Popoln Bayesov pristop
4. Povzetek

Klasifikacija: Prepoznavna števil

- Vhod (X_i): Značilke slike
- Izhod (Y): Labele razredov $\{y_0, y_1, \dots, y_9\}$



Značilke (X_i):

$X_i \ i=1, \dots, 12$

$x_i^0 = 0-10\%$

$x_i^1 = 10-20\%$

....

} $Val(X_i) = 10$

Število parametrov = $10^{12} - 1$

Široka variabilnost

- Ročno ustvarjena pravila povzročajo veliko število pravil in izjem
- Bolje je imeti stroj, ki se uči iz velike učne množice

ML in PR

- ML izvira iz računalništva
- PR izvira iz elektrotehnike
- Različne plati istega področja
- Prisotne več kot 50 let
- Oživitev Bayesovih metod
 - Zaradi razpoložljivih računalniških metod

Zgodovina ML in DAR

- Vhod je perceptualen (slike, tekst)
 - Ni popolnega ujemanja: zahtevane so verjetnostne metode
- ML najprej s slikami/tekstom
 - Perceptroni/nevronske mreže
 - Prepoznavna števil
- – SVM
 - Ročno napisane poštne številke
- – Skriti modeli Markova (Hidden Markov Models)
 - Prepoznavna govora
- – Pogojna naključna polja:
 - Segmentacija slik , analiza teksta (NE Tagging)

Kaj je strojno učenje?

- Problemi vključujejo negotovost
 - učenje iz podatkov in ne iz kode
- Preobremenitev z informacijami
 - Velike količine učnih podatkov
 - Omejitve človeške kognitivne sposobnosti
- Spremenljivi podatkovni tokovi
 - Iskalnik se mora neprestano prilagajati
 - Rokopisi in stili pisav niso enaki kot pred 10/25 leti
- Strojno učenje povzroča napredek v programiranju



Tipologija problematike

1. Klasifikacija (razredne oznake)

- OCR, prepoznavna števil

2. Regresija (zvezne vrednosti)

- rangiranje spletnih strani

3. Kolektivna klasifikacija

- segmentacija slik
- zaporedno
 - prepoznavna besed, POS Tagging, prepoznavna govora

4. Pridobivanje verjetnosti

- najboljše ujemanje v podatkovni bazi, redkost podatkov

Aplikacije

- Programiranje računalnikov:
 - za naloge, ki jih človek zna dobro opraviti, vendar jih je težje opisati z algoritmom
- Primaren način gradnje informacijskih sistemov visokih zmogljivosti
 - iskalniki
 - adaptivni, personalizirani uporabniški vmesniki
 - znanstvene aplikacije (računalniška znanost)

Uspešne ML aplikacije

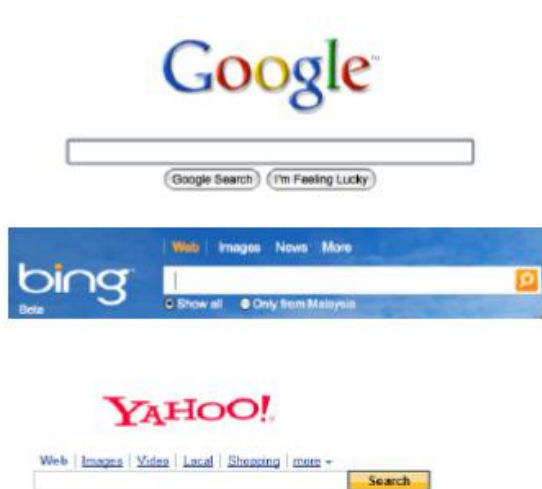
- Prepoznavna govornjenih besed
 - govorcu prilagojene strategije za prepoznavo primitivnih zvokov, fonemov in besed iz govora
 - Nevronske mreže in metode za učenje HMM za prilagajanje govorcem, bedenjakom in mikrofonskim karakteristikam

Regresija: Rangiranje spletnih iskanj

Vhod (X_i): (Query-URL) par
Izhod (Y): Vrednost relevance

Značilke (Google jih uporablja
prek 200)



- Log frequency of query word in anchor text
- Query word in color on page
- # of images on page
- # of (out) links on page
- PageRank of page
- URL length
- URL contains “~”
- Page length



Uspešne ML aplikacije

- Učenje vožnje z avtomatskim vozilom
 - Učenje računalniško vodenih vozil za avtomatsko zavijanje
 - prilagajanje hitrosti omejitvam
 - Povezava upravljanja volana s slikami

ALVINN [Pomerleau] drives 70 mph on highways



Prepoznavna rokopisa

- Naoga *T*

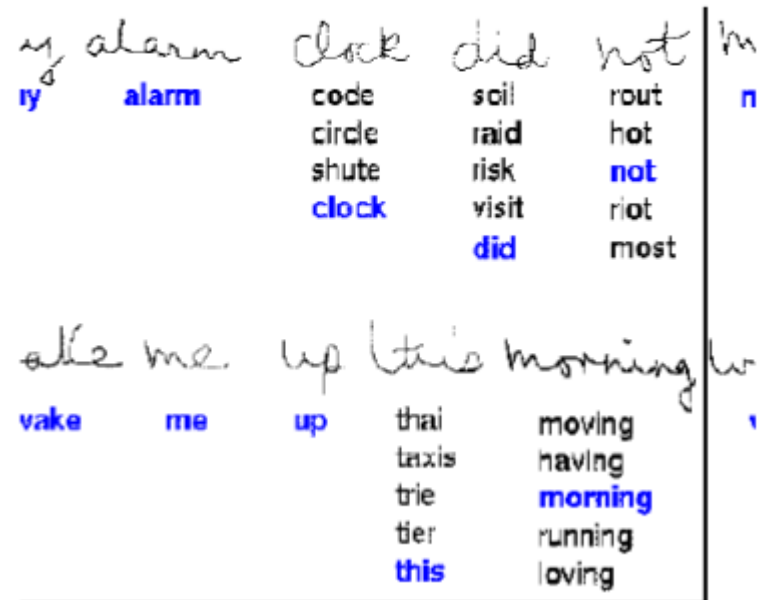
- prepoznavna in klasifikacija besed napisanih na slike

- Merilo učinkovitosti *P*

- odstotek pravilno razvrščenih besed

- Izkušnje učenja *E*

- baza že klasificiranih napisanih besed



ML pristop

- Zbiranje podatkov
- Izbira modela
 - Porazdelitev verjetnosti za modeliranje procesa
- Ocena parametrov
 - Vrednosti/porazdelitve
- Sklepanje
 - Iskanje natančnega ali približnega odgovora



Problemi, za katere je uporabljeno strojno učenje

1. Klasifikacija
2. Regresija
3. Grozdenje (Data Mining)
4. Modeliranje/Sklepanje


Primer klasifikacije

- Cevovodi (pod morjem)
- Neinvazivno merjenje razmer
 - nafta, voda in plin
- Imenuje se trofazni Nafta/Voda/Plin proces

Dvojno energijska gama densitometrija

- Žarek gama žarkov je usmerjen skozi cev
- Slabljenje podaja informacijo o gostoti materiala cevi
- En sam žarek ne zadostuje
 - Dve stopnji prostosti: delež nafte, delež vode


One beam of
Gamma rays
of two energies
(frequencies or wavelengths)



Detector


Predikcija

1. Napoved volumskih deležev nafta/voda/plin
2. Napoved geometrijske konfiguracije vseh treh faz
 - 12 značilik
 - deleži nafte in vode vzdolž poti
 - učenje razlikovanja med podatki







Prostor značil

- Trije razredi (Stratified, Annular, Homogeneous)
- Prikazani sta 2 spremenljivki
- 100 točk
 - V kateri razred spada x ?



Celična klasifikacija

- Preprosti pristop glasovanja na osnovi pripadnosti celici bo neuspešen zaradi eksponentnega naraščanja števila celic z naraščanjem dimenzije
- Malo točk v celicah



Priljubljeni statistični modeli

- Splošni


- Naive Bayes
- Mixtures of multinomials
- Mixtures of Gaussians
- Hidden Markov Models (HMM)
- Bayesian networks
- Markov random fields

- Diskriminativni

- Logistic regression
- SVMs
- Traditional neural networks
- Nearest neighbor
- Conditional Random Fields (CRF)


Regresija

Ustrezni inverzni
Problem z inverzom
 $x \text{ int}$



Ustrezno

prilagajanja avonivojske nevronske mreže z metodo najmanjših kvadratov





Zelo slabo
prilagajanje
Uporaba GMM

Grozdenje

- Old Faithful (hidrotermalni gejzir v parku Yellowstone)
 - 272 opazovanj
 - Trajanje (min, horiz os) *proti* času do naslednjega izbruha (vertikalna os)
 - Gaussov model ne more zajeti strukture
 - Linearna superpozicija dveh Gauss. se izkaže bolje
- Gaussov model ima omejitve pri modeliranju podatkov
- Gaussovi mešani modeli dajejo zelo kompleksne gostote

$$p(x) = \sum_{k=1}^K \pi_k N(x | \mu_k, \Sigma_k)$$

- π_k so mešani koeficienti



Ocena Gaussovih mešanih modelov

- Log funkcija verjetja

$$\ln p(X | \pi, \mu, \Sigma) = \sum_{n=1}^N \ln \left\{ \sum_{k=1}^K \pi_k N(x_n | \mu_k, \Sigma_k) \right\}$$

- Ni zaprte oblike rešitve
- Uporabi se iterativna numerična optimizacija ali maksimizacija pričakovanja

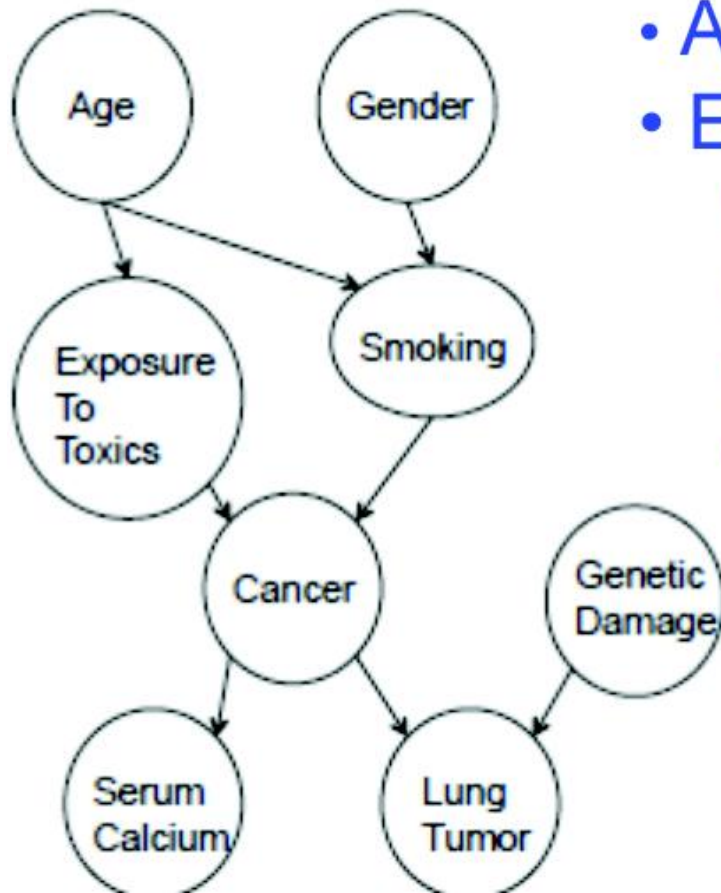
Bayesova predstavitev negotovosti

- Ne samo frekvenca naključja, tudi ponavljajoči se dogodki
- Verjetnost je kvantifikacija negotovosti
- Ali bo arktični ledeni pokrov izginil do konca stoletja
 - Imamo nekaj podatkov o hitrosti taljenja polarnega ledu
 - Preučimo jih ponovno na podlagi novih dokazov, podatkov (satelitske slike)
 - Ocena bo vplivala na prihodnja dejanja (zmanjševanje toplogrednih plinov)
- Vse to lahko dosežemo s splošno Bayesovo interpretacijo

Predstavitev negotovosti z verjetnostjo ni "ad-hoc" izbira

Če za predstavitev stopnje verjetja uporabimo numerične vrednosti, potem preprosti aksiomi za spreminjanje stopnje verjetja vodijo k pravilom vsote in produkta za verjetnost

Modeliranje negotovosti



- A Causal Bayesian Network
- Example of Inference:
Cancer is independent of Age and Gender given exposure to Toxics and Smoking


Popoln Bayesov pristop

- Bayesovo pravilo
- Bayesove verjetnosti
- koncept konjugacije
- Monte Carlo vzorčenje

Pravila verjetnosti

- Imamo naključni spremenljivki X in Y
- **Pravilo vsote** daje marginalno verjetnost

$$p(X = x_i) = \sum_{j=1}^L p(X = x_i, Y = y_j) = \frac{c_i}{N}$$



- **Pravilo produkta**: skupna verjetnost glede na pogojno in marginalno

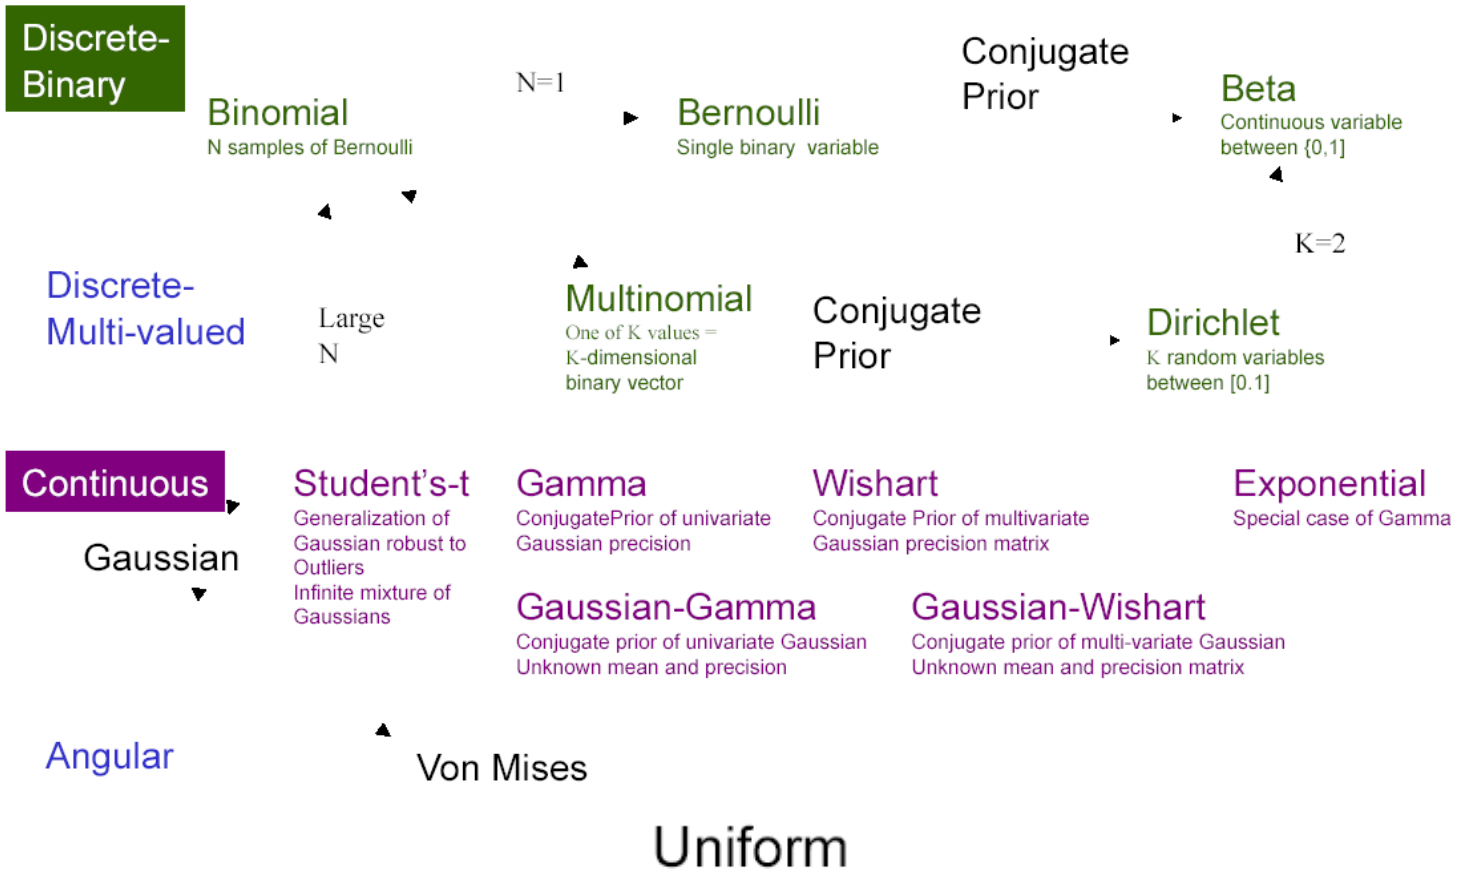
$$p(X, Y) = \frac{n_{ij}}{N} = p(Y | X)p(X) = \frac{n_{ij}}{c_i} \times \frac{c_i}{N}$$

- S kombiniranjem dobimo **Bayesov teroem**

$$p(Y | X) = \frac{p(X | Y)p(Y)}{p(X)} \quad \text{kjer je} \quad p(X) = \sum_Y p(X | Y)p(Y)$$

kot Posteriorna α verjetnost x pred

Verjetnostne porazdelitve: povezave



Popoln Bayesov pristop

- Izvedljiv s povečano računsko močjo
- A posteriori porazdelitev je lahko obravnavana z
 - variacijskim Bayesom ali
 - stohastičnim (naključnim) vzorčenjem
- npr., Markov Chain Monte Carlo, Gibbs

Povzetek

- ML je sistematičen pristop k sestavljanju sistemov za obdelavo informacij
- Upoabno za reševanje problemov klasifikacije, regresije, grozdenja in sklepanja
- popoln Bayesov pristop skupaj z Monte Carlo vzorčenjem omogoča visoko zmogljive sisteme
- velika praktična vrednost v več aplikacijah
 - Računalništvo
 - iskalniki
 - obdelava besedil
 - prepoznava dokumentov
 - Elektrotehnika

- **Literatura:**

- Sargur N. Srihari, Lecture notes, University at Buffalo, State University of New York