

Projektovanje IoT sistema

Uvod u mašinsko učenje

Vladimir Rajović, prema


C.M.Bishop *Pattern Recognition and Machine Learning*

Uvod u mašinsko učenje

- Oblast istraživanja koja daje računarima mogućnost da uče bez da budu eksplicitno programirani
- Tehnička definicija: računarski problem uči na osnovu iskustva E u odnosu na neki zadatak T i neku meru performansi P , ako se njegove performanse u izvršavanju T , merene sa P , povećavaju sa iskustvom E .

Uvod u mašinsko učenje


- Primer prepoznavanje pisanih cifara



- Svaka cifra 28x28 tačaka, vektor \mathbf{x} 784 realnih brojeva
- Cilj napraviti mašinu koja će na osnovu ulaza \mathbf{x} na izlazu dati koja je cifra u pitanju

Uvod u mašinsko učenje


- Primer prepoznavanje pisanih cifara



- Pristup mašinskog učenja – koristi se veliki skup N cifara $\{\mathbf{x}_1, \dots, \mathbf{x}_N\}$ kao obučavajući skup za podešavanje parametara adaptivnog modela.
- Kategorije u obučavajućem skupu su unapred poznate.
 - Kategorije se označavaju ciljnim vektorom \mathbf{t} koji predstavlja identitete odgovarajućih cifara

Uvod u mašinsko učenje

- Primer prepoznavanje pisanih cifara



- Rezultat algoritma mašinskog učenja može da se predstavi kao fja $y(x)$ koja se određuje tokom faze obučavanja (učenja) na osnovu obučavajućih podataka.
- Nakon što je model obučen, može određivati identitet novih slika cifara, koje predstavljaju skup za testiranje
- Ova mogućnost se naziva *uopštavanje*.
 - U praktičnim primenama obučavajući skup je samo mali podskup svih mogućih podataka i uopštavanje je glavni cilj.

Uvod u mašinsko učenje

- U najvećem broju primena ulazni podaci se *predobrađuju*
 - Transformacija u novi prostor podataka u kome će biti lakše ispuniti zadatak
 - U primeru sa prepoznavanjem cifara ulazni podaci se transliraju i skaliraju tako da je svaka cifra u pravougaoniku iste veličine – to drastično umanjuje različitost u okviru klase cifara, tako da je algoritmima za prepoznavanje lakše da razlikuju različite cifre.
 - Ovo se nekad naziva *izdvajanje odlika* (feature extraction)

Uvod u mašinsko učenje

- U najvećem broju primena ulazni podaci se *predobrađuju*
 - Predobrada se koristi i za ubrzavanje izračunavanja, primer detekcije lica u sekvenci slika visoke rezolucije. Direktan rad sa velikom količinom podataka je problematičan.
 - Pronalaze se korisne odlike koje se lako računaju, a čuvaju korisne informacije za izdvajanje lica, koje se potom koriste u samom algoritmu.
 - Broj takvih odlika je manji od broja tačaka -> ovo predstavlja oblik smanjenja broja dimenzija.
 - Pažljivo, da ne dođe do gubitka bitnih informacija.

Uvod u mašinsko učenje

- Nadgledano učenje
 - Obučavajući skup sadrži primere ulaznih podataka sa njihovim ciljnim vektorima (labelama, oznakama).
 - Ako je skup mogućih izlaza konačan u pitanju je *klasifikacija* (primer prepoznavanje cifara)
 - Ako je beskonačan u pitanju je *regresija* (primer predviđanje prinosa hemijskog postrojenja na osnovu koncentracije reagenasa, temperature i pritiska).

Uvod u mašinsko učenje

- Nenadgledano učenje
 - Obučavajući skup sadrži primere ulaznih podataka ali bez njihovih oznaka.
 - Grupisanje (*clustering*) je pronalaženje grupe sličnih podataka u skupu
 - Određivanje raspodele podataka (procena gustine, *density estimation*)
 - Vizuelizacija – transformacija podataka iz više dimenzija u dve ili tri

Uvod u mašinsko učenje

- Učenje podsticanjem (*reinforcement*)
 - Naći odgovarajuće postupke u datoј situaciji kako bi se maksimizirala nagrada
 - Algoritam ne dobija primere optimalnog izlaza, već ih sam nalazi pokušajima i pogreškama
 - Postoji sekvenca stanja i postupaka kojima algoritam deluje na okolinu.
 - Trenutna akcija najčešće ima uticaj na sva naredna stanja, ne samo na sledeće

Uvod u mašinsko učenje

- Učenje podsticanjem (*reinforcement*)
 - Kod ove vrste učenja pravi se kompromis između korišćenja (*exploitation* – korišćenje dokazanih akcija) i probanja (*exploration* – proba novih akcija)

Uvod u mašinsko učenje


- Razni zadaci mašinskog učenja imaju svoje metode i alate, ali postoje koncepti koji su im zajednički

Uvod u mašinsko učenje

- Fitovanje krive polinomom
 - Jednostavan regresioni problem: ulazna realna promenljiva x , na osnovu koje se predviđa vrednost izlaza t
 - Veštački primer, jer se zna tačno proces koji je generisao podatke: $\sin(2\pi x)$ uz dodat slučajni šum
 - Obučavajući skup od N obzervacija (merenja, uzoraka, odbiraka) $\hat{\mathbf{x}}$, $\hat{\mathbf{x}} \equiv \hat{(x_1, \dots, x_N)}^T$ sa odgovarajućim obzervacijama t , $\hat{\mathbf{t}} \equiv \hat{(t_1, \dots, t_N)}^T$

Uvod u mašinsko učenje

- Fitovanje krive polinomom
 - Predvideti \hat{t} za neko \hat{x}
 - Implicitno, prepoznati $\sin(2\pi x)$
 - Problemi:
 - Uopštavanje na osnovu konačnog skupa podataka
 - Podaci zagađeni šumom, tako da postoji nesigurnost
 - Teorija verovatnoće daje okvir za merenje te nesigurnosti, a teorija odlučivanja koristi ta merenja za optimalna predviđanja prema nekom kriterijumu




$$N = 10$$

Uvod u mašinsko učenje

- Fitovanje krive polinomom
 - Jednostavan primer fitovanja

$$y(x, \mathbf{w}) = w_0 + w_1 x + w_2 x^2 + \dots + w_M x^M = \sum_{j=0}^M w_j x^j$$

- Fja nelinearna po x , ali linearna po koeficijentima \mathbf{w} (linearni model)
- Koeficijenti se određuju fitovanjem polinoma, npr minimizacijom funkcije greške između $y(x, \mathbf{w})$ i obučavajućeg skupa




Uvod u mašinsko učenje

- Fitovanje krive polinomom
 - Primer fje greške

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


- Nula samo ako predviđanje tačno prolazi kroz obučavajuće podatke
- Problem se rešava nalaženjem \mathbf{w}^* za koje je greška najmanja moguća
- Moguće je u zatvorenoj formi, greška zavisi kvadratno od koeficijenata, lako rešavanje



Uvod u mašinsko učenje

- Fitovanje krive polinomom
 - Mnogo veći problem naći red polinoma M

- preveliko fitovanje za $M = 9$, fja prolazi kroz sve tačke, ali loše predstavlja pravu fju




Uvod u mašinsko učenje

- Fitovanje krive polinomom
 - Skup za testiranje od 100 članova


$$E_{\text{RMS}} = \sqrt{2E(\mathbf{w}^*)/N}$$

- Greška na skupu za testiranje dobra mera koliko je dobro predviđanje
- Za $M = 9$ polinom postaje podešen na šum!



Uvod u mašinsko učenje

- Fitovanje krive polinomom
 - Kako veličina obučavajućeg skupa utiče na fitovanje, primer za $M = 9$



- Za datu složenost modela, prefitovanje postaje manje ukoliko ima više obučavajućih podataka

Uvod u mašinsko učenje

- Fitovanje krive polinomom
 - Empirija kaže da broj podataka treba da bude umnožak (5-10) broja adaptivnih parametara
 - Ograničenje broja parametara u zavisnosti od veličine obučavajućeg skupa je nezadovoljavajuće, razumnije je da kompleksnost modela zavisi od kompleksnosti problema (ovo rešava bajesovski pristup)

Uvod u mašinsko učenje

- Fitovanje krive polinomom
 - Da bi koristili složene modele sa ograničenim skupom obučavajućih podataka, jedna od tehnika je *regularizacija*, dodavanje kaznenog člana funkciji greške kako bi se sprečilo da koeficijenti dobijaju prevelike vrednosti i tako se podešavaju prema šumu.
 - Najprostiji primer


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

$$\|\mathbf{w}\|^2 \equiv \mathbf{w}^T \mathbf{w} = w_0^2 + w_1^2 + \dots + w_M^2$$

» Koeficijent λ definiše relativnu važnost regularizacionog člana

Uvod u mašinsko učenje


- Fitovanje krive polinomom
 - Regularizacija, $M = 9$, $N = 10$



- Prevelika regularizacija uzrokuje loše fitovanje

Uvod u mašinsko učenje

- Fitovanje krive polinomom
 - Regularizacija, $M = 9, N = 10$



- Efektivna složenost modela i količina prefitovanja kontrolisana koeficijentom λ

Uvod u mašinsko učenje

- Fitovanje krive polinomom
 - Ako bi se konkretan problem rešavao minimizacijom funkcije greške, potrebno je naći odgovarajuću vrednost složenosti modela.
 - Jednostavan način je deljenje dostupnih podataka na obučavajući i validacioni skup
 - » Obučavajući skup se koristi za određivanje koeficijenata
 - » Validacioni skup za optimizaciju složenosti
 - U mnogim primenama je ovo traćenje vrednih podataka, potrebno je nešto pametnije...

Uvod u mašinsko učenje

- Teorija verovatnoće

- Pravila

$$p(X) = \sum_Y p(X, Y)$$

$$p(X, Y) = p(Y|X)p(X)$$

- $p(X, Y)$ zajednička verovatnoća
 - $p(Y|X)$ uslovna verovatnoća
 - $p(X)$ marginalna verovatnoća
 - Ova dva pravila osnova za dalja razmatranja

Uvod u mašinsko učenje

- Teorija verovatnoće
 - Posledice pravila





$$p(Y|X) = \frac{p(X|Y)p(Y)}{p(X)} \quad \text{Bajesova teorema}$$

$$p(X) = \sum_Y p(X|Y)p(Y)$$

Uvod u mašinsko učenje

- Teorija verovatnoće

– Ako važi
 $p(X, Y) = p(X)p(Y)$
slučajne promenljive
su nezavisne



Uvod u mašinsko učenje

- Teorija verovatnoće
 - Ako su u putanju kontinualne slučajne promenljive $p(x)$ se naziva gustina verovatnoće


$$p(x \in (a, b)) = \int_a^b p(x) dx$$

- gustina mora da zadovoljava uslove

$$p(x) \geq 0$$

$$\int_{-\infty}^{\infty} p(x) dx = 1$$

- Kumulativna raspodela verovatnoće



$$P(z) = \int_{-\infty}^z p(x) dx$$

Uvod u mašinsko učenje

- Teorija verovatnoće
 - U slučaju više kontinualnih promenljivih x_1, \dots, x_D (označavamo kao vektor \mathbf{x}), zajednička raspodela gustine $p(\mathbf{x}) = p(x_1, \dots, x_D)$, za koju takođe mora da važi
$$p(\mathbf{x}) \geq 0$$
$$\int p(\mathbf{x}) d\mathbf{x} = 1$$
 - Važe pravila
$$p(x) = \int p(x, y) dy$$
$$p(x, y) = p(y|x)p(x).$$
 - Ekvivalentno za kombinaciju diskretnih i kontinualnih promenljivih

Uvod u mašinsko učenje

- Teorija verovatnoće

- Usrednjena vrednost fje po njenoj raspodeli
očekivanje fje

$$\mathbb{E}[f] = \sum_x p(x)f(x) \quad \mathbb{E}[f] = \int p(x)f(x) dx.$$

- Ako imamo N podataka aproksimacija

$$\mathbb{E}[f] \simeq \frac{1}{N} \sum_{n=1}^N f(x_n)$$

- Uslovno učekivanje

$$\mathbb{E}_x[f|y] = \sum_x p(x|y)f(x)$$

Uvod u mašinsko učenje

- Teorija verovatnoće
 - *Varijansa* f-je pokazuje koliko je promenljivosti u fji oko njene srednje vrednosti
$$\text{var}[f] = \mathbb{E} [(f(x) - \mathbb{E}[f(x)])^2]$$
 - Varijansa same promenljive $\text{var}[x] = \mathbb{E}[x^2] - \mathbb{E}[x]^2$
 - Za dve slučajne promenljive *kovarijansa* pokazuje koliko se dve promenljive zajedno menjaju

$$\begin{aligned}\text{cov}[x, y] &= \mathbb{E}_{x,y} [\{x - \mathbb{E}[x]\} \{y - \mathbb{E}[y]\}] \\ &= \mathbb{E}_{x,y}[xy] - \mathbb{E}[x]\mathbb{E}[y]\end{aligned}$$

- Ako su nezavisne, kovarijansa nestaje

Uvod u mašinsko učenje

- Teorija verovatnoće
 - U slučaju dva vektora slučajnih promenljivih, kovarijansa

$$\begin{aligned}\text{cov}[\mathbf{x}, \mathbf{y}] &= \mathbb{E}_{\mathbf{x}, \mathbf{y}} [\{\mathbf{x} - \mathbb{E}[\mathbf{x}]\}\{\mathbf{y}^T - \mathbb{E}[\mathbf{y}^T]\}] \\ &= \mathbb{E}_{\mathbf{x}, \mathbf{y}} [\mathbf{x}\mathbf{y}^T] - \mathbb{E}[\mathbf{x}]\mathbb{E}[\mathbf{y}^T].\end{aligned}$$

Uvod u mašinsko učenje

- Teorija verovatnoće
 - **Bajesovska verovatnoća**
 - Klasična ili frekvencijska verovatnoća se bavi učestanostima slučajnih ponovljivih događaja.
 - Kod Bajevskog pristupa verovatnoće daju meru nesigurnosti.
 - Da li će se polarna kapa otopiti do kraja veka?
 - Događaj koji se ne ponavlja
 - Postoji ideja o tome koliko brzo se led topi
 - Novi podaci dovode do revidiranja predviđanja
 - » Preduzimaju se neke akcije kako bi se topljenje leda smanjilo
 - Potrebno je imati način da se izrazi nesigurnost, da se ona revidira kada imamo nove podatke, i da se kao posledica donesu neke odluke i preduzmu neke akcije
 - Bayesova interpretacija verovatnoće to omogućava

Uvod u mašinsko učenje

- Teorija verovatnoće
 - **Bajesovska verovatnoća**
 - Kod fitovanja krivih klasična verovatnoća ima smisla kod slučajnih vrednosti podataka koje merimo/dobijamo
 - Ali NE pomaže kod nesigurnosti oko parametara modela (koeficijenata) ili samog modela
 - Bajesova teorema konvertuje prethodnu (a prori) verovatnoću u sledeću (a posteriori) na osnovu novih podataka
 - Slično se može koristiti za zaključivanje o parametrima kao što su koeficijenti kod fitovanja krivih

Uvod u mašinsko učenje

- Teorija verovatnoće
 - **Bajesovska verovatnoća**
 - Prepostavke o koeficijentima su prethodna verovatnoća $p(\mathbf{w})$
 - Uslovna verovatnoća $p(\mathcal{D}|\mathbf{w})$ uključuje efekat dobijenih podataka $\mathcal{D} = \{t_1, \dots, t_N\}$
 - Procena nesigurnosti koeficijenata predstavljena je narednom verovatnoćom $p(\mathbf{w}|\mathcal{D})$, korišćenjem Bajesove teoreme

$$p(\mathbf{w}|\mathcal{D}) = \frac{p(\mathcal{D}|\mathbf{w})p(\mathbf{w})}{p(\mathcal{D})}$$

Uvod u mašinsko učenje

- Teorija verovatnoće

- **Bajesovska verovatnoća**

- $p(\mathcal{D}|\mathbf{w})$ se može posmatrati kao fja parametara, i tada se naziva fja verovatnoće (likelihood function).
 - Koliko je verovatan izmereni skup podataka za date parametre. Ovo nije distribucija verovatnoće na \mathbf{w} , integral po \mathbf{w} ne mora biti 1.

$$\text{posterior} \propto \text{likelihood} \times \text{prior}$$

- Sve veličine funkcije \mathbf{w}

$$p(\mathcal{D}) = \int p(\mathcal{D}|\mathbf{w})p(\mathbf{w}) d\mathbf{w}$$

Uvod u mašinsko učenje

- Teorija verovatnoće
 - **Bajesovska verovatnoća**
 - $p(\mathcal{D}|\mathbf{w})$ ima centralno mesto u oba pristupa verovatnoći, ali se koristi na različite načine
 - U klasičnom pristupu \mathbf{w} je fiksni parametar određen nekim estimatorom, i greške se razmatraju na svim mogućim skupovima podataka.
 - U Bajesovom pristupu postoji samo jedan skup podataka (koji se trenutno posmatra), a nesigurnost parametara se izražava preko distribucije verovatnoće parametara \mathbf{w}

Uvod u mašinsko učenje


- Teorija verovatnoće

- **Gausova raspodela**

$$\mathcal{N}(x|\mu, \sigma^2) = \frac{1}{(2\pi\sigma^2)^{1/2}} \exp\left\{-\frac{1}{2\sigma^2}(x - \mu)^2\right\}$$

μ srednja vrednost, σ^2 varijansa

σ standardna devijacija, $\beta = 1/\sigma^2$ preciznost



Uvod u mašinsko učenje

- Teorija verovatnoće

- **Gausova raspodela**

- Vektor D slučajnih promenljivih

$$\mathcal{N}(\mathbf{x}|\boldsymbol{\mu}, \boldsymbol{\Sigma}) = \frac{1}{(2\pi)^{D/2}} \frac{1}{|\boldsymbol{\Sigma}|^{1/2}} \exp \left\{ -\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu}) \right\}$$

- Skup opažanja skalarne promenljive $\mathbf{x} = (x_1, \dots, x_N)^T$

- Dobijena nezavisnim opažanjima iz Gausove raspodele nepoznatih parametara

- Namera je odrediti parametre na osnovu podataka

- Verovatnoća skupa opažanja $p(\mathbf{x}|\boldsymbol{\mu}, \sigma^2) = \prod_{n=1}^N \mathcal{N}(x_n|\boldsymbol{\mu}, \sigma^2)$


Uvod u mašinsko učenje

- Teorija verovatnoće
 - Skup opažanja skalarne promenljive

$$p(\mathbf{x}|\mu, \sigma^2) = \prod_{n=1}^N \mathcal{N}(x_n|\mu, \sigma^2)$$

- Ovo je funkcija verovatnoće (likelihood) za Gausovu distribuciju kada se gleda u odnosu na parametre

- Maksimizacijom ove fje moguće je odrediti parametre
- U praksi lakše raditi sa logaritmom



Uvod u mašinsko učenje

- Teorija verovatnoće
 - U praksi lakše raditi sa logaritmom

$$\ln p(\mathbf{x}|\mu, \sigma^2) = -\frac{1}{2\sigma^2} \sum_{n=1}^N (x_n - \mu)^2 - \frac{N}{2} \ln \sigma^2 - \frac{N}{2} \ln(2\pi)$$


$$\mu_{\text{ML}} = \frac{1}{N} \sum_{n=1}^N x_n \quad \sigma_{\text{ML}}^2 = \frac{1}{N} \sum_{n=1}^N (x_n - \mu_{\text{ML}})^2$$

- Ovaj pristup sistemski potcenjuje varijansu (pomeraj/bias)


$$\mathbb{E}[\mu_{\text{ML}}] = \mu \quad \mathbb{E}[\sigma_{\text{ML}}^2] = \left(\frac{N-1}{N}\right) \sigma^2$$

- Procena varijanse bez pomeraja


$$\tilde{\sigma}^2 = \frac{N}{N-1} \sigma_{\text{ML}}^2 = \frac{1}{N-1} \sum_{n=1}^N (x_n - \mu_{\text{ML}})^2$$



(a)



(b)



(c)

Uvod u mašinsko učenje

- Fitovanje krive 2
 - Iz perspektive verovatnoće
 - Cilj predvideti vrednost izlazne promenljive t na osnovu nove vrednosti ulazne promenljive x i skupa obučavajućih podataka od N opažanja i njihovih oznaka, $\mathbf{x} = (\hat{x}_1, \dots, \hat{x}_N)^T$ i $\mathbf{t} = (t_1, \dots, t_N)^T$
 - Za dato x , t ima Gausovu raspodelu (pp) sa srednjom vrednošću $y(x, \mathbf{w})$


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

$$p(t|x, \mathbf{w}, \beta) = \mathcal{N}(t|y(x, \mathbf{w}), \beta^{-1})$$

Uvod u mašinsko učenje

- Fitovanje krive 2

$$p(t|x, \mathbf{w}, \beta) = \mathcal{N}(t|y(x, \mathbf{w}), \beta^{-1})$$



Uvod u mašinsko učenje

- Fitovanje krive 2
 - Koriste se obučavajući podaci $\{\mathbf{x}, \mathbf{t}\}$ radi maksimizacije fje verovatnoće, odnosno njenog logaritma

$$p(\mathbf{t}|\mathbf{x}, \mathbf{w}, \beta) = \prod_{n=1}^N \mathcal{N}(t_n | y(x_n, \mathbf{w}), \beta^{-1})$$

$$\ln p(\mathbf{t}|\mathbf{x}, \mathbf{w}, \beta) = -\frac{\beta}{2} \sum_{n=1}^N \{y(x_n, \mathbf{w}) - t_n\}^2 + \frac{N}{2} \ln \beta - \frac{N}{2} \ln(2\pi)$$

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

Uvod u mašinsko učenje

- Fitovanje krive 2
 - Sada je moguće praviti predviđanja kada dobijemo nove vrednosti x
 - Kako sada imamo probabilistički model, predviđanja se izražavaju kao prediktivna distribucija koja daje distribuciju verovatnoće t , a ne jednu tačku
$$p(t|x, \mathbf{w}_{\text{ML}}, \beta_{\text{ML}}) = \mathcal{N}(t|y(x, \mathbf{w}_{\text{ML}}), \beta_{\text{ML}}^{-1})$$

Uvod u mašinsko učenje

- Fitovanje krive 2

- Za koeficijente, uvodimo a priori raspodelu za koeficijente polinoma, neka bude Gausova sa preciznošću α i $M+1$ koeficijenata

$$p(\mathbf{w}|\alpha) = \mathcal{N}(\mathbf{w}|\mathbf{0}, \alpha^{-1}\mathbf{I}) = \left(\frac{\alpha}{2\pi}\right)^{(M+1)/2} \exp\left\{-\frac{\alpha}{2}\mathbf{w}^T\mathbf{w}\right\}$$

- A posteriori raspodela proporcionalna a priori raspodeli i funkciji verovatnoće

$$p(\mathbf{w}|\mathbf{x}, \mathbf{t}, \alpha, \beta) \propto p(\mathbf{t}|\mathbf{x}, \mathbf{w}, \beta)p(\mathbf{w}|\alpha).$$

Uvod u mašinsko učenje

- Fitovanje krive 2
 - Sada se može naći najverovatnija vrednost koeficijenata maksimiziranjem a posteriori raspodele (tehnika *maximum posterior – MAP*), što je minimum izraza

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

- Ovo je već viđeno, kod regularizacije prilikom fitovanja krive, sa parametrom regularizacije $\lambda = \alpha/\beta$

Uvod u mašinsko učenje

- Bajesovo fitovanje
 - Pretpostavimo da su parametri raspodele poznati i fiksni i evaluiramo raspodelu

$$p(t|x, \mathbf{x}, \mathbf{t}) = \int p(t|x, \mathbf{w})p(\mathbf{w}|\mathbf{x}, \mathbf{t}) d\mathbf{w}$$

$$p(t|x, \mathbf{w}, \beta) = \mathcal{N}(t|y(x, \mathbf{w}), \beta^{-1})$$

- $p(\mathbf{w}|\mathbf{x}, \mathbf{t})$ a posteriori distribucija parametara, dobija se normalizacijom $p(\mathbf{w}|\mathbf{x}, \mathbf{t}, \alpha, \beta) \propto p(\mathbf{t}|\mathbf{x}, \mathbf{w}, \beta)p(\mathbf{w}|\alpha)$
 - Gausova i može se analitički odrediti

Uvod u mašinsko učenje

- Bajesovo fitovanje

- Dobija se

$$p(t|x, \mathbf{x}, \mathbf{t}) = \mathcal{N}(t|m(x), s^2(x))$$

$$m(x) = \beta \boldsymbol{\phi}(x)^T \mathbf{S} \sum_{n=1}^N \boldsymbol{\phi}(x_n) t_n$$

$$s^2(x) = \beta^{-1} + \boldsymbol{\phi}(x)^T \mathbf{S} \boldsymbol{\phi}(x).$$

$$\mathbf{S}^{-1} = \alpha \mathbf{I} + \beta \sum_{n=1}^N \boldsymbol{\phi}(x_n) \boldsymbol{\phi}(x_n)^T$$

$$\boldsymbol{\phi}(x_n) = (x_n^0, \dots, x_n^M)^T$$

Uvod u mašinsko učenje

- Bajesovo fitovanje


- Varijansa

$$s^2(x) = \beta^{-1} + \phi(x)^T \mathbf{S} \phi(x).$$

- Prvi član posledica šuma u podacima, drugi nesigurnost parametara

Uvod u mašinsko učenje

- Bajesovo fitovanje
 - Prediktivna raspodela $M = 9$ $\alpha = 5 \times 10^{-3}$ $\beta = 11.1$



Uvod u mašinsko učenje

- **Izbor modela**
 - U praksi je potrebno odrediti parametre modela, sa ciljem da se postigne što bolje predviđanje novih podataka
 - Ali, nekad je potrebno i izabrati najbolji model za datu primenu

Uvod u mašinsko učenje


- **Izbor modela**

- Učinak predviđanja na obučavajućem skupu nije dobar pokazatelj kakvo je predviđanje, zbog prefitovanja (već viđeno)
- Ako ima dosta podataka: neke podatke iskoristiti kao obučavajući skup za više modela, ili za više parametara jednog modela, i onda koristiti validacioni skup za poređenje i izabrati najbolji
- Može doći i do prefitovanja sa validacionim skupom, tako da se ponekad izdvaja treći skup, za testiranje i procenu izabranog modela.

Uvod u mašinsko učenje

- **Izbor modela**

- Često podataka nema puno, i namera je da se što više podataka iskoristi za obučavanje.
 - Ali ako je validacioni skup mali, to dovodi do loše procene učinka predviđanja
- Zato se može koristiti S-to struka unakrsna validacija
 - Podaci se dele na S grupa, $(S-1)$ grupa se koristi za obučavanje, a onda evaluira na preostaloj grupi. Usrednjavanje rezultata
 - Ako ima malo podataka, onda $S=N$ (leave one out)




Uvod u mašinsko učenje

- **Izbor modela**
 - Problem S-tostrukture unakrsne validacije je što broj prolazaka raste sa S ako je obučavanje računarski zahtevno
 - Ako u modelu imamo više parametara, onda broj prolazaka eksponencijalno zavisi od broja parametara
 - Potreban pristup u kome se idealno u jednom prolasku porede modeli i parametri na osnovu podataka za obučavanje, i treba naći meru učinka koja zavisi samo od podataka za obuku i ne trpi zbog pomeraja usled prefitovanja, npr maksimizacija $\ln p(\mathcal{D}|\mathbf{w}_{\text{ML}}) - M$
(fja verovatnoće i broj parametara)

Uvod u mašinsko učenje

- **Više dimenzija**
 - U praksi se često radi sa višedimenzionim podacima
 - ozbiljan izazov
 - Primer, iz problema koji ima 12 ulaznih veličina i tri moguća izlaza, posmatraju se sada dva ulaza
 - Novi podatak okružen crvenim, ali ima prilično i zelenih – intuicija




Uvod u mašinsko učenje

- **Više dimenzija**

- Kako intuiciju preneti u algoritam?

- Jedan pristup je da se ulazni prostor podeli na ćelije
 - Ulazni podatak je istog tipa kao i većina podataka u ćeliji u kojoj se nalazi
 - Najočigledniji problem sa ovim pristupom je povećanje broja dimenzija ulaza, koji uzrokuje eksponentasti porast broja ćelija
 - Potrebno je eksponentno više podataka kako bi osigurali da nema praznih ćelija



Uvod u mašinsko učenje

- **Više dimenzija**

- Fitovanje krive polinomom III reda u slučaju D ulaznih promenljivih

$$y(\mathbf{x}, \mathbf{w}) = w_0 + \sum_{i=1}^D w_i x_i + \sum_{i=1}^D \sum_{j=1}^D w_{ij} x_i x_j + \sum_{i=1}^D \sum_{j=1}^D \sum_{k=1}^D w_{ijk} x_i x_j x_k$$

- Kako raste D , broj nepoznatih koeficijenata raste sa D^3
- Za polinomom reda M raste sa D^M
 - Nije eksponencijalna zavisnost, ali je opet praktična upotrebljivost metoda dovedena u pitanje

Uvod u mašinsko učenje


- **Više dimenzija**

- Geometrijska intucija, zasnovana na 3D, pada u vodu na više dimenzija

- D -dimenzionalna sfera poluprečnika $r = 1$; koji deo zapremine sfere leži između $r = 1 - \epsilon$ i $r = 1$?


$$\frac{V_D(1) - V_D(1 - \epsilon)}{V_D(1)} = 1 - (1 - \epsilon)^D$$

- U više dimenzija, veći deo zapremine sfere se nalazi uz spoljašnju površinu!



Uvod u mašinsko učenje

- **Više dimenzija**
 - Višedimenziona Gausova raspodela
 - Prelazak na polarne koordinate i integracija po svim uglovima tako da ostane samo zavisnost od radijusa
 - $p(r)\delta r$ je verovatnoća u uskoj lusci na radijusu r
 - Skoncentrisana verovatnoća



Uvod u mašinsko učenje

- **Više dimenzija**
 - Ne mora biti problem
 - Realni podaci često biti ograničeni na deo prostora koji ima manje dimenzije, dok su nekad i pravci promena bitnih promenljivih takođe ograničeni
 - Realni podaci često imaju osobine glatkosti (barek lokalno), tj male promene ulaza uzrokuju male promene izlaza -> tada se mogu koristiti tehnike slične lokalnoj interpolaciji za predviđanja promene izlaznih promenljivih usled promene ulaznih promenljivih.
 - Primer za oba, identični objekti na pokretnoj traci, različito postavljeni. Svaka slika je tačka u prostoru koji ima dimenzija koliko ima piksela. Postoje tri stepena slobode (pozicija na slici i orijentacija) između slika, ali je samo jedan bitan - orijentacija.

Uvod u mašinsko učenje

- **Teorija odlučivanja**
 - Vektor ulaza \mathbf{x} i vektor izlaza \mathbf{t} , cilj je predvideti izlaz \mathbf{t} za novi ulaz \mathbf{x}
 - Zajednička raspodela $p(\mathbf{x}, \mathbf{t})$ daje nesigurnost koja prati ove promenljive
 - Određivanje raspodele na osnovu podataka za obučavanje je primer *zaključivanja*
 - Praktično je potrebno predvideti \mathbf{t} odnosno preuzeti neku akciju na osnovu vrednosti koju \mathbf{t} verovatno ima – teorija odlučivanja

Uvod u mašinsko učenje

- **Teorija odlučivanja**
 - Rendgen snimak na osnovu koga treba odrediti da li pacijent ima rak.
 - Ulaz \mathbf{x} skup intenziteta piksela, izlazna promenljiva t određuje da li pacijent ima rak (klasa \mathcal{C}_1) ili ne (klasa \mathcal{C}_2)
 - Opšti problem zaključivanja uključuje određivanje zajedničke raspodele $p(\mathbf{x}, \mathcal{C}_k)$ (tj. $p(\mathbf{x}, t)$), koja nam daje probabilistički opis situacije
 - Ali, na kraju se mora odlučiti da li da se pacijentu uradi neka intervencija ili ne, i ovaj izbor bi trebalo da bude optimalan u nekom smislu
 - *Odluka* – predmet teorije odlučivanja je kako donositi optimalne odluke na osnovu verovatnoća
 - Kada se reši problem zaključivanja, odluka je u opštem slučaju trivijalna

Uvod u mašinsko učenje

- **Teorija odlučivanja**

- Kako to verovatnoće imaju veze sa donošenjem odluka?
- Kada se dobije snimak \mathbf{x} novog pacijenta, potrebno je odrediti kojoj klasi snimak pripada
- Bitne su verovatnoće $p(\mathcal{C}_k|\mathbf{x})$, koje određujemo preko Bajesove teoreme
$$p(\mathcal{C}_k|\mathbf{x}) = \frac{p(\mathbf{x}|\mathcal{C}_k)p(\mathcal{C}_k)}{p(\mathbf{x})}$$
- Ako hoćemo da minimiziramo mogućnost da snimak loše interpretiramo, intuitivno biramo klasu koja ima veću a posteriornu verovatnoću


Uvod u mašinsko učenje

- **Teorija odlučivanja**
 - **Minimizacija loše klasifikacije**
 - Cilj je što manje moguće loših klasifikacija
 - Potrebno pravilo koje dodeljuje \mathbf{x} nekoj od klase/mogućnosti
 - Pravilo deli ulazni prostor na oblasti odlučivanja \mathcal{R}_k koje odgovaraju klasama \mathcal{C}_k i ne moraju biti neprekidne
 - » Granice između oblasti *granice* ili *površi odlučivanja*
 - Primer sa dve klase
 - » Greška se javlja kada se ulazni vektor dodeli pogrešnoj klasi, sa verovatnoćom

$$\begin{aligned} p(\text{mistake}) &= p(\mathbf{x} \in \mathcal{R}_1, \mathcal{C}_2) + p(\mathbf{x} \in \mathcal{R}_2, \mathcal{C}_1) \\ &= \int_{\mathcal{R}_1} p(\mathbf{x}, \mathcal{C}_2) d\mathbf{x} + \int_{\mathcal{R}_2} p(\mathbf{x}, \mathcal{C}_1) d\mathbf{x} \end{aligned}$$

Uvod u mašinsko učenje

- **Teorija odlučivanja**
 - **Minimizacija loše klasifikacije**
 - Da bi se minimizirala greška, pravilo odlučivanja: ako $p(\mathbf{x}, \mathcal{C}_1) > p(\mathbf{x}, \mathcal{C}_2)$ za neki ulaz, onda taj ulaz dodeljujemo klasi \mathcal{C}_1 , drugim rečima ulaz dodeljujemo klasi za koju je $p(\mathcal{C}_k|\mathbf{x})$ veće



Uvod u mašinsko učenje

- **Teorija odlučivanja**
 - **Minimizacija loše klasifikacije**
 - Ako imamo K klase, nešto je jednostavnije maksimizirati verovatnoću tačne klasifikacije

$$\begin{aligned} p(\text{correct}) &= \sum_{k=1}^K p(\mathbf{x} \in \mathcal{R}_k, \mathcal{C}_k) \\ &= \sum_{k=1}^K \int_{\mathcal{R}_k} p(\mathbf{x}, \mathcal{C}_k) d\mathbf{x} \end{aligned}$$

- Odlučivanje ekvivalentno, ulaz se dodeljuje klasi koja ima najveće $p(\mathcal{C}_k | \mathbf{x})$

Uvod u mašinsko učenje

- **Teorija odlučivanja**
 - **Minimizacija očekivanog gubitka**
 - Nije svaka greška ista, zato se uvodi pojam fje gubitka (loss) ili troška (cost) koja daje meru gubitka prilikom bilo koje od mogućih odluka
- Nekom ulazu \mathbf{x} čija je klasa \mathcal{C}_k dodeljujemo klasu \mathcal{C}_j sa gubitkom L_{kj}
- Optimalno rešenje minimizuje fju gubitka
 - Ona zavisi od prave klase, koja je nepoznata

Uvod u mašinsko učenje

- **Teorija odlučivanja**
 - **Minimizacija očekivanog gubitka**
 - Optimalno rešenje minimizuje fju gubitka
 - Ona zavisi od prave klase, koja je nepoznata
 - » Ta nesigurnost je opisana sa $p(\mathbf{x}, \mathcal{C}_k)$
 - » Minimizira se usrednjeni gubitak
$$\mathbb{E}[L] = \sum_k \sum_j \int_{\mathcal{R}_j} L_{kj} p(\mathbf{x}, \mathcal{C}_k) d\mathbf{x}$$
 - » Oblasti odlučivanja se biraju tako da za svaki novi ulaz bude minimalno
$$\sum_k L_{kj} p(\mathcal{C}_k | \mathbf{x})$$

Uvod u mašinsko učenje

- **Teorija odlučivanja**


- **Odbacivanje**

- Greške klasifikacije u oblastima gde je najveća posteriori verovatnoća $p(\mathcal{C}_k|\mathbf{x})$ dosta manja od jedinice, odnosno gde su zajedničke verovatnoće $p(\mathbf{x}, \mathcal{C}_k)$ uporedive
 - Oblasti u kojima smo relativno nesigurni oko pripadnosti klasama
 - U nekim primenama u ovakvim slučajevima može se odustati od donošenja odluke, kako bi se smanjila greška na ulazima za koje je greška doneta.
 - Kod primera sa rendgen snimcima automatski sistem može u nekim slučajevima odustati od odlučivanja i prepustiti čoveku da doneše odluku

Uvod u mašinsko učenje

- **Teorija odlučivanja**
 - Odbacivanje

- Ovo se postiže uvođenjem praga θ i onda odustajati od odlučivanja za onaj ulaz za koji je najveća od posteriornih verovatnoća $p(\mathcal{C}_k|\mathbf{x})$ manja od praga
- Za $\theta = 1$ nema odbacivanja, za $\theta < 1/K$ i K klase odbacuju se svi ulazi



Uvod u mašinsko učenje


- **Teorija odlučivanja**
 - **Zaključivanje i odlučivanje**
 - Problem klasifikacije se deli na dva koraka
 - Zaključivanje kako bi se na osnovu obučavajućeg skupa odredio model $p(\mathcal{C}_k|\mathbf{x})$
 - Odlučivanje u kome se posteriorne verovatnoće koriste za optimalnu klasifikaciju
 - Alternativno se oba koraka izvršavaju istovremeno i uči fja koja ulaze direktno preslikava na odluke (*diskriminanta*)

Uvod u mašinsko učenje

- **Teorija odlučivanja**
 - **Zaključivanje i odlučivanje, 3 pristupa**
 - Generativni modeli
 - Najpre se za svaku klasu pojedinačno odrede $p(\mathbf{x}|\mathcal{C}_k)$ i $p(\mathcal{C}_k)$.
Zatim Bajesova teorema
$$p(\mathcal{C}_k|\mathbf{x}) = \frac{p(\mathbf{x}|\mathcal{C}_k)p(\mathcal{C}_k)}{p(\mathbf{x})}$$
uz $p(\mathbf{x}) = \sum p(\mathbf{x}|\mathcal{C}_k)p(\mathcal{C}_k)$, ili se posteriorne verovatnoće dobijaju iz procene $p(\mathbf{x}, \mathcal{C}_k)$.
 - Na osnovu posteriornih verovatnoća donose se odluke
 - Diskriminativni modeli
 - Direktno se određuju posteriorne verovatnoće $p(\mathcal{C}_k|\mathbf{x})$ i na osnovu njih donose odluke
 - Određivanje diskriminante $f(\mathbf{x})$
 - Mapira ulaz direktno u klasu; ovde verovatnoće nemaju ulogu

Uvod u mašinsko učenje

- **Teorija odlučivanja**
 - **Zaključivanje i odlučivanje, 3 pristupa**
 - Prvi pristup najzahtevniji, ulaz u mnogim primenama ima više dimenzija i potreban je veliki obučavajući skup.
 - Ali, omogućava da se nađe $p(\mathbf{x})$, što omogućava detekciju ulaza koji imaju malu verovatnoću i moguću malu tačnost predviđanja (*outlier/novelty*)
 - Ako se traži samo klasifikacija, određivanje distribucije $p(\mathbf{x}, \mathcal{C}_k)$ je tračenje resursa ako je potrebno samo $p(\mathcal{C}_k | \mathbf{x})$




Uvod u mašinsko učenje

- **Teorija odlučivanja**
 - Zaključivanje i odlučivanje, 3 pristupa

- Treći pristup još jednostavniji.

- » Samo odrediti granicu ->

- Ali sada nemamo info o posteriornim verovatnoćama $p(\mathcal{C}_k|\mathbf{x})$, a one su korisne



Uvod u mašinsko učenje

- **Teorija odlučivanja**
 - Zaključivanje i odlučivanje, važnost posteriornih verovatnoća
 - Minimizacija gubitka
 - Ako je potrebno s vremena na vreme ažurirati matricu gubitka, trivijalna revizija kriterijuma odlučivanja ako se znaju ove verovatnoće
$$\sum_k L_{kj} p(\mathcal{C}_k | \mathbf{x})$$
 - Ako imamo samo diskriminantu, mora se raditi ispočetka
 - Odbacivanje
 - Moguće ako znamo posteriorne verovatnoće

Uvod u mašinsko učenje

- **Teorija odlučivanja**
 - **Zaključivanje i odlučivanje, važnost posteriornih verovatnoća**
 - Kompenzacija apriori verovatnoća klasa
 - Ako se uzmu rendgen snimci opšte populacije, 1 u 1000 ima rak. Apriori verovatnoća klase jako mala i obučavanje na skupu opštег tipa je slabo.
 - » Zato se uzima balansirani skup za obučavanje sa približno istim brojem primera obe klase i određuje
$$p(\mathcal{C}_k|\mathbf{x}) = \frac{p(\mathbf{x}|\mathcal{C}_k)p(\mathcal{C}_k)}{p(\mathbf{x})}$$
 - » Zatim podeliti sa udelom date klase u obučavajućem skupu pa pomnožiti sa udelom date klase u opštoj populaciji. Na kraju normalizacija.
 - » Ovo ne može bez posteriornih verovatnoća

Uvod u mašinsko učenje

- **Teorija odlučivanja**
 - **Zaključivanje i odlučivanje, važnost posteriornih verovatnoća**
 - Kombinacija modela
 - U složenoj primeni umesto jednog supersloženog modela možemo imati dva manja modela i kombinovati njihove rezultate
 - » Testiranje na rak: rendgen i krvna slika – dva posebna modela i kombinacija (prepostavka da su za svaku klasu snimci i krvna slika nezavisni – uslovna nezavisnost)

$$p(\mathbf{x}_I, \mathbf{x}_B | \mathcal{C}_k) = p(\mathbf{x}_I | \mathcal{C}_k)p(\mathbf{x}_B | \mathcal{C}_k)$$

$$\begin{aligned} p(\mathcal{C}_k | \mathbf{x}_I, \mathbf{x}_B) &\propto p(\mathbf{x}_I, \mathbf{x}_B | \mathcal{C}_k)p(\mathcal{C}_k) \\ &\propto p(\mathbf{x}_I | \mathcal{C}_k)p(\mathbf{x}_B | \mathcal{C}_k)p(\mathcal{C}_k) \\ &\propto \frac{p(\mathcal{C}_k | \mathbf{x}_I)p(\mathcal{C}_k | \mathbf{x}_B)}{p(\mathcal{C}_k)} \end{aligned}$$

Uvod u mašinsko učenje

- **Teorija odlučivanja**
 - **Funkcija gubitka za regresiju**
 - Opći primer fitovanja
 - Određuje se procena vrednosti $t, y(\mathbf{x})$, za svaki ulaz \mathbf{x} . Pri tome se trpi gubitak $L(t, y(\mathbf{x}))$
 - Usrednjeni gubitak $\mathbb{E}[L] = \iint L(t, y(\mathbf{x}))p(\mathbf{x}, t) d\mathbf{x} dt$
 - Čest izbor je gubitka kod regresije $L(t, y(\mathbf{x})) = \{y(\mathbf{x}) - t\}^2$
 - Očekivani gubitak tada $\mathbb{E}[L] = \iint \{y(\mathbf{x}) - t\}^2 p(\mathbf{x}, t) d\mathbf{x} dt$

Uvod u mašinsko učenje


- Teorija odlučivanja
 - Funkcija gubitka za regresiju

- Opet primer fitovanja

- Potrebno izabrati $y(\mathbf{x})$ koje minimizira gubitak

$$\frac{\delta \mathbb{E}[L]}{\delta y(\mathbf{x})} = 2 \int \{y(\mathbf{x}) - t\} p(\mathbf{x}, t) dt = 0 \quad y(\mathbf{x}) = \frac{\int tp(\mathbf{x}, t) dt}{p(\mathbf{x})} = \int tp(t|\mathbf{x}) dt = \mathbb{E}_t[t|\mathbf{x}]$$

- $\mathbb{E}_t[t|\mathbf{x}]$ uslovna srednja vrednost t u odnosu na \mathbf{x} (regresiona fja)



Uvod u mašinsko učenje

- **Teorija odlučivanja**

- **Funkcija gubitka za regresiju**

- Fja gubitka može da se razvije i onda opet usrednji

$$\begin{aligned}\{y(\mathbf{x}) - t\}^2 &= \{y(\mathbf{x}) - \mathbb{E}[t|\mathbf{x}] + \mathbb{E}[t|\mathbf{x}] - t\}^2 \\ &= \{y(\mathbf{x}) - \mathbb{E}[t|\mathbf{x}]\}^2 + 2\{y(\mathbf{x}) - \mathbb{E}[t|\mathbf{x}]\}\{\mathbb{E}[t|\mathbf{x}] - t\} + \{\mathbb{E}[t|\mathbf{x}] - t\}^2\end{aligned}$$

$$\mathbb{E}[L] = \int \{y(\mathbf{x}) - \mathbb{E}[t|\mathbf{x}]\}^2 p(\mathbf{x}) d\mathbf{x} + \int \{\mathbb{E}[t|\mathbf{x}] - t\}^2 p(\mathbf{x}) d\mathbf{x}$$

- Drugi član predstavlja minimim funkcije gubitka

Uvod u mašinsko učenje

- **Teorija odlučivanja**
 - **Funkcija gubitka za regresiju**

- Opet tri pristupa

$$y(\mathbf{x}) = \frac{\int tp(\mathbf{x}, t) dt}{p(\mathbf{x})} = \int tp(t|\mathbf{x}) dt = \mathbb{E}_t[t|\mathbf{x}]$$

- Naći $p(\mathbf{x}, t)$, pa $p(t|\mathbf{x})$, na kraju $y(\mathbf{x})$
- Odmah naći $p(t|\mathbf{x})$, zatim $y(\mathbf{x})$
- Direktno odrediti $y(\mathbf{x})$ iz obučavajućih podataka

Uvod u mašinsko učenje

- **Teorija informacija**

- Količina informacija koja se dobija na osnovu opažanja slučajne promenljive

$$h(x) = -\log_2 p(x)$$

- Usrednjena informacija, odnosno entropija

$$H[x] = - \sum_x p(x) \log_2 p(x)$$

Uvod u mašinsko učenje

- **Teorija informacija**


- Entropija diskretne slučajne promenljive X

$$H[p] = - \sum_i p(x_i) \ln p(x_i)$$

- Raspodele $p(x_i)$ koje imaju izražene pikove imaju manju entropiju od onih koje su “ravnomerno raspoređene”
 - Entropija nula ako se sve verovatnoće osim jedne nula.
 - Maksimalnu entropiju ima uniformna raspodela

$$p(x_i) = 1/M$$

$$H = \ln M$$



Uvod u mašinsko učenje

- **Teorija informacija**

- (Diferencijalna) entropija

- kontinualne promenljive

- kontinualnih promenljivih

$$-\int p(x) \ln p(x) dx$$

$$H[x] = -\int p(x) \ln p(x) dx$$

- Maksimalnu diferencijalnu entropiju ima Gausova distribucija

$$p(x) = \frac{1}{(2\pi\sigma^2)^{1/2}} \exp\left\{-\frac{(x-\mu)^2}{2\sigma^2}\right\}$$

$$H[x] = \frac{1}{2} \{1 + \ln(2\pi\sigma^2)\}$$

- Raste kako se distribucija širi, odnosno raste varijansa

Uvod u mašinsko učenje

- **Teorija informacija**
 - Dve slučajne promenljive sa zajedničkom raspodelom $p(x, y)$
 - Ako se zna x , dodatna informacija potrebna da se zna i y je $-\ln p(y|x)$
 - Uslovna entropija y u odnosu na x

$$H[y|x] = - \iint p(y, x) \ln p(y|x) dy dx$$

$$H[x, y] = H[y|x] + H[x]$$

Uvod u mašinsko učenje

- **Teorija informacija**
 - Relativna entropija i zajednička informacija
 - Srednja dodatna količina informacija potrebna da se izrazi x sa nepoznatom raspodelom $p(x)$, ako raspodelu aproksimiramo sa $q(x)$

$$\begin{aligned} \text{KL}(p\|q) &= - \int p(\mathbf{x}) \ln q(\mathbf{x}) d\mathbf{x} - \left(- \int p(\mathbf{x}) \ln p(\mathbf{x}) d\mathbf{x} \right) \\ &= - \int p(\mathbf{x}) \ln \left\{ \frac{q(\mathbf{x})}{p(\mathbf{x})} \right\} d\mathbf{x}. \end{aligned}$$

- Relativna entropija ili Kullback-Leibler divergencija
$$\text{KL}(p\|q) \geq 0$$

Uvod u mašinsko učenje

- **Teorija informacija**

- Relativna entropija i zajednička informacija
 - Nepoznata raspodela $p(\mathbf{x})$ koju je potrebno modelovati
 - Recimo aproksimacija parametarskom raspodelom $q(\mathbf{x}|\boldsymbol{\theta})$
 - Jedan način je minimizirati relativnu entropiju ove dve raspodele po $\boldsymbol{\theta}$, ali ne znamo $p(\mathbf{x})$
 - Ali, ako imamo skup podataka za obučavanje \mathbf{x}_n iz nepoznate raspodele
 - $$\text{KL}(p\|q) \simeq \sum_{n=1}^N \{-\ln q(\mathbf{x}_n|\boldsymbol{\theta}) + \ln p(\mathbf{x}_n)\}$$
 - » Desni član ne zavisi od parametra, a levi je negativni logaritam funkcije verovatnoće za parametar pod raspodelom $q(\mathbf{x}|\boldsymbol{\theta})$
 - » Minimizacija KL-a ekvivalentna maximizaciji fje verovatnoće

Uvod u mašinsko učenje

- **Teorija informacija**
 - Relativna entropija i zajednička informacija
 - Zajednička distribucija $p(\mathbf{x}, \mathbf{y})$
 - Ako su skupovi \mathbf{x} i \mathbf{y} nezavisni, $p(\mathbf{x}, \mathbf{y}) = p(\mathbf{x})p(\mathbf{y})$
 - Ako nisu, pomoću KL možemo zaključiti koliko imi “fali” da budu

$$\begin{aligned} I[\mathbf{x}, \mathbf{y}] &\equiv \text{KL}(p(\mathbf{x}, \mathbf{y}) \| p(\mathbf{x})p(\mathbf{y})) \\ &= - \iint p(\mathbf{x}, \mathbf{y}) \ln \left(\frac{p(\mathbf{x})p(\mathbf{y})}{p(\mathbf{x}, \mathbf{y})} \right) d\mathbf{x} d\mathbf{y} \end{aligned}$$

- Ovo je zajednička informacija \mathbf{x} i \mathbf{y} .
 - » Uvek je veća od nule, a nula ako su nezavisni

Uvod u mašinsko učenje

- **Teorija informacija**
 - Relativna entropija i zajednička informacija

$$I[x, y] = H[x] - H[x|y] = H[y] - H[y|x]$$

- Zajednička informacija: smanjenje nesigurnosti u vezi sa x ako znamo y i obrnuto