



I007 Osnove umjetne inteligencije

Tema: Strojno učenje: naivan Bayesov klasifikator i perceptron.

19. 5. 2021.



Strojno učenje: kako dobiti model iz podataka / iskustva

- učenje parametara
- učenje strukture
- učenje skrivenih koncepta





Klasifikacija: za dati ulaz x , treba predvidjeti klasu (oznaku) y

Primjeri

- detekcija neželjenih poruka e-pošte
- optičko prepoznavanje znakova
- medicinska dijagonistika (ulaz: simptomi, izlaz: dijagnoza)
- automatizirano ocjenjivanje eseja
- klasifikacija novinskih dokumenata u rubrike
- predviđanje kretanja dionica
- otkrivanje prevara
- predviđanje ishoda nogometnih utakmica





Klasifikacija: za dani ulaz x , treba predvidjeti klasu (oznaku) y

Primjeri

- detekcija neželjenih poruka e-pošte
- optičko prepoznavanje znakova
- medicinska dijagonistika (ulaz: simptomi, izlaz: dijagnoza)
- automatizirano ocjenjivanje eseja
- klasifikacija novinskih dokumenata u rubrike
- predviđanje kretanja dionica
- otkrivanje prevara
- predviđanje ishoda nogometnih utakmica





Klasifikacija temeljena na modelu

- izgraditi model (npr. Bayesovu mrežu) gdje su i značajke i klase slučajne varijable
- zabilježiti sve uočene značajke
- odrediti distribuciju klasa uvjetovanu značajkama

Pitanja:

- kakvu strukturu bi Bayesova mreža trebala imati?
- kako naučiti njene parametre?





Klasifikacija temeljena na modelu

- izgraditi model (npr. Bayesovu mrežu) gdje su i značajke i klase slučajne varijable
- zabilježiti sve uočene značajke
- odrediti distribuciju klasa uvjetovanu značajkama

Pitanja:

- kakvu strukturu bi Bayesova mreža trebala imati?
- kako naučiti njene parametre?





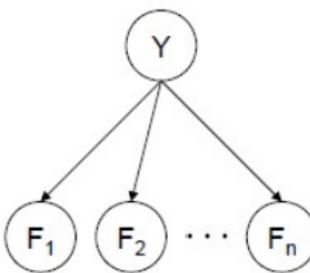
1 Naivan Bayesov klasifikator

2 Perceptron





Naivan bayesov klasifikator: prepostavlja da su sve značajke nezavisni efekti klase



$$P(Y, F_1, F_2, \dots, F_n) = P(Y) \prod_i P(F_i|Y)$$

- potrebno je samo odrediti kako svaka značajka ovisi o klasi
- ukupni broj parametara je linearan u n
- model je jako pojednostavljen, no unatoč tome često dobro radi





Zaključivanje s Naivnim Bayesovim klasifikatorom

Cilj: izračunati posterior vjerojatnost varijable klase Y ($P(Y|f_1, \dots, f_n)$)

- korak 1: odrediti zajedničku vjerojatnost klase i svih dokaza (značajki) za svaku klasu

$$P(Y, f_1, \dots, f_n) = \begin{bmatrix} P(y_1, f_1, \dots, f_n) \\ P(y_2, f_1, \dots, f_n) \\ \vdots \\ P(y_k, f_1, \dots, f_n) \end{bmatrix} = \begin{bmatrix} P(y_1) \prod_i P(f_i|y_1) \\ P(y_2) \prod_i P(f_i|y_2) \\ \vdots \\ P(y_k) \prod_i P(f_i|y_k) \end{bmatrix}$$

- korak 2: zbrojiti kako bi se dobila vjerojatnost dokaza

$$P(f_1, \dots, f_n) = \sum_j P(y_j) \prod_i P(f_i|y_j)$$

- korak 3: normalizirati tako da $P(Y, f_1, \dots, f_n)$ podijelimo s $P(f_1, \dots, f_n)$





Kako bi mogli koristiti naivan Bayesov klasifikator trebamo:

- metodu zaključivanja (upravo opisano)
- procjenu uvjetnih vjerojatnosti:
 - $P(Y)$ za klase
 - $P(F_i|Y)$ za svaku značajku
 - ove vjerojatnosti se zajedno zovu parametri modela i označavaju s θ





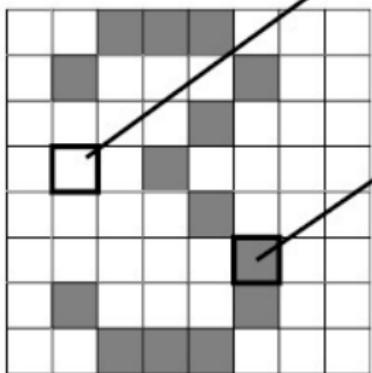
Kako bi mogli koristiti naivan Bayesov klasifikator trebamo:

- metodu zaključivanja (upravo opisano)
- procjenu uvjetnih vjerojatnosti:
 - $P(Y)$ za klase
 - $P(F_i|Y)$ za svaku značajku
 - ove vjerojatnosti se zajedno zovu parametri modela i označavaju s θ



 $P(Y)$

1	0.1
2	0.1
3	0.1
4	0.1
5	0.1
6	0.1
7	0.1
8	0.1
9	0.1
0	0.1

 $P(F_{3,1} = on|Y) \quad P(F_{5,5} = on|Y)$

1	0.01
2	0.05
3	0.05
4	0.30
5	0.80
6	0.90
7	0.05
8	0.60
9	0.50
0	0.80

1	0.05
2	0.01
3	0.90
4	0.80
5	0.90
6	0.90
7	0.25
8	0.85
9	0.60
0	0.80





Učenje i testiranje

- podaci: označeni primjeri
 - skup za učenje
 - skup za provjeru
 - skup za testiranje
- značajke: parovi atribut-vrijednost koji opisuje svaki primjer
- ciklus eksperimentiranja
 - naučiti parametre na skupu za učenje
 - podešiti hiperparametre na skupu za provjeru
 - izračunati točnost na skupu za testiranje
 - važno: nikada ne "viriti" u skup za testiranje
- evaluacija
 - točnost: postotak dobro označenih primjera
- prenaučenost i generalizacija
 - želimo klasifikator koji dobro radi na skupu za testiranje
 - prenaučenost: opisuje skup za učenje jako dobro, ali ne radi dobro na novim primjerima
 - kako bi bolje generalizirali trebamo koristiti zaglađivanje ili neku drugu vrstu poboljšanja procjenitelja



Učenje i testiranje

- podaci: označeni primjeri
 - skup za učenje
 - skup za provjeru
 - skup za testiranje
- značajke: parovi atribut-vrijednost koji opisuje svaki primjer
- ciklus eksperimentiranja
 - naučiti parametre na skupu za učenje
 - podešiti hiperparametre na skupu za provjeru
 - izračunati točnost na skupu za testiranje
 - važno: nikada ne "viriti" u skup za testiranje
- evaluacija
 - točnost: postotak dobro označenih primjera
- prenaučenost i generalizacija
 - želimo klasifikator koji dobro radi na skupu za testiranje
 - prenaučenost: opisuje skup za učenje jako dobro, ali ne radi dobro na novim primjerima
 - kako bi bolje generalizirali trebamo koristiti zaglađivanje ili neku drugu vrstu poboljšanja procjenitelja



Učenje i testiranje

- podaci: označeni primjeri
 - skup za učenje
 - skup za provjeru
 - skup za testiranje
- značajke: parovi atribut-vrijednost koji opisuje svaki primjer
- ciklus eksperimentiranja
 - naučiti parametre na skupu za učenje
 - podešiti hiperparametre na skupu za provjeru
 - izračunati točnost na skupu za testiranje
 - važno: nikada ne "viriti" u skup za testiranje
- evaluacija
 - točnost: postotak dobro označenih primjera
- prenaučenost i generalizacija
 - želimo klasifikator koji dobro radi na skupu za testiranje
 - prenaučenost: opisuje skup za učenje jako dobro, ali ne radi dobro na novim primjerima
 - kako bi bolje generalizirali trebamo koristiti zaglađivanje ili neku drugu vrstu poboljšanja procjenitelja



Učenje i testiranje

- podaci: označeni primjeri
 - skup za učenje
 - skup za provjeru
 - skup za testiranje
- značajke: parovi atribut-vrijednost koji opisuje svaki primjer
- ciklus eksperimentiranja
 - naučiti parametre na skupu za učenje
 - podešiti hiperparametre na skupu za provjeru
 - izračunati točnost na skupu za testiranje
 - važno: nikada ne "viriti" u skup za testiranje
- evaluacija
 - točnost: postotak dobro označenih primjera
- prenaučenost i generalizacija
 - želimo klasifikator koji dobro radi na skupu za testiranje
 - prenaučenost: opisuje skup za učenje jako dobro, ali ne radi dobro na novim primjerima
 - kako bi bolje generalizirali trebamo koristiti zaglađivanje ili neku drugu vrstu poboljšanja procjenitelja



Učenje i testiranje

- podaci: označeni primjeri
 - skup za učenje
 - skup za provjeru
 - skup za testiranje
- značajke: parovi atribut-vrijednost koji opisuje svaki primjer
- ciklus eksperimentiranja
 - naučiti parametre na skupu za učenje
 - podešiti hiperparametre na skupu za provjeru
 - izračunati točnost na skupu za testiranje
 - važno: nikada ne "viriti" u skup za testiranje
- evaluacija
 - točnost: postotak dobro označenih primjera
- prenaučenost i generalizacija
 - želimo klasifikator koji dobro radi na skupu za testiranje
 - prenaučenost: opisuje skup za učenje jako dobro, ali ne radi dobro na novim primjerima
 - kako bi bolje generalizirali trebamo koristiti zaglađivanje ili neku drugu vrstu poboljšanja procjenitelja



Procjena parametara

- procjena distribucije slučajne varijable
- empirijsko: koristi se skup za učenje
 - npr. relativne frekvencije su procjenitelji maksimalne vjerodostojnosti

$$P_{ML}(x) = \frac{\text{broj}(x)}{\text{ukupni broj primjera}}$$

- na ovaj način može doći do prenaučenosti
- Laplaceovo zaglađivanje: pretpostavimo da se svaki ishod pojavio jedan puta više nego što zaista je

$$P_{LAP}(x) = \frac{\text{broj}(x) + 1}{\text{ukupni broj primjera} + |X|}$$





Procjena parametara

- procjena distribucije slučajne varijable
- empirijsko: koristi se skup za učenje
 - npr. relativne frekvencije su procjenitelji maksimalne vjerodostojnosti

$$P_{ML}(x) = \frac{\text{broj}(x)}{\text{ukupni broj primjera}}$$

- na ovaj način može doći do prenaučenosti
- Laplaceovo zaglađivanje: pretpostavimo da se svaki ishod pojavio jedan puta više nego što zaista je

$$P_{LAP}(x) = \frac{\text{broj}(x) + 1}{\text{ukupni broj primjera} + |X|}$$





Procjena parametara

- poopćeno Laplaceovo zaglađivanje: pretpostavimo da se svaki ishod pojavio k puta više nego što zaista je

$$P_{LAP,k}(x) = \frac{\text{broj}(x) + k}{\text{ukupni broj primjera} + k|X|}$$

- poopćeno Laplaceovo zaglađivanje za uvjetovanu vjerojatnost

$$P_{LAP,k}(x|y) = \frac{\text{broj}(x, y) + k}{\text{broj}(y) + k|X|}$$

- u praksi Laplaceovo zaglađivanje ne radi najbolje za $P(X|Y)$
- druga mogućnost je linearna interpolacija
 - iz primjera se empirijski procjeni $\hat{P}(X)$ i $\hat{P}(X|Y)$, a novi procjenitelj se definira kao

$$P_{LIN}(x|y) = \alpha \hat{P}(x|y) + (1 - \alpha) \hat{P}(x)$$



Procjena parametara

- poopćeno Laplaceovo zaglađivanje: pretpostavimo da se svaki ishod pojavio k puta više nego što zaista je

$$P_{LAP,k}(x) = \frac{\text{broj}(x) + k}{\text{ukupni broj primjera} + k|X|}$$

- poopćeno Laplaceovo zaglađivanje za uvjetovanu vjerojatnost

$$P_{LAP,k}(x|y) = \frac{\text{broj}(x, y) + k}{\text{broj}(y) + k|X|}$$

- u praksi Laplaceovo zaglađivanje ne radi najbolje za $P(X|Y)$
- druga mogućnost je linearna interpolacija
 - iz primjera se empirijski procjeni $\hat{P}(X)$ i $\hat{P}(X|Y)$, a novi procjenitelj se definira kao

$$P_{LIN}(x|y) = \alpha \hat{P}(x|y) + (1 - \alpha) \hat{P}(x)$$



Podešavanje na skupu za provjeru

- imamo dvije vrste nepoznanica
 - parametre: vjerojatnosti $P(X|Y)$ i $P(Y)$
 - hiperparametre: količina/tip zaglađivanja, k , α
- odakle što naučiti?
 - parametre učimo iz skupa za učenje
 - hiperparametre podešavamo na skupu za provjeru
 - za svaku vrijednost hiperparametara naučimo i testiramo
 - odaberemo najbolju vrijednost i napravimo završni test na skupu za testiranje





Podešavanje na skupu za provjeru

- imamo dvije vrste nepoznanica
 - parametre: vjerojatnosti $P(X|Y)$ i $P(Y)$
 - hiperparametre: količina/tip zaglađivanja, k , α
- odakle što naučiti?
 - parametre učimo iz skupa za učenje
 - hiperparametre podešavamo na skupu za provjeru
 - za svaku vrijednost hiperparametara naučimo i testiramo
 - odaberemo najbolju vrijednost i napravimo završni test na skupu za testiranje





Podešavanje na skupu za provjeru

- imamo dvije vrste nepoznanica
 - parametre: vjerojatnosti $P(X|Y)$ i $P(Y)$
 - hiperparametre: količina/tip zaglađivanja, k , α
- odakle što naučiti?
 - parametre učimo iz skupa za učenje
 - hiperparametre podešavamo na skupu za provjeru
 - za svaku vrijednost hiperparametara naučimo i testiramo
 - odaberemo najbolju vrijednost i napravimo završni test na skupu za testiranje





1 Naivan Bayesov klasifikator

2 Perceptron





Linearni klasifikatori

- zadani su nam vektori značajki: svakom primjeru x pridružujemo vektor $f(x)$, na osnovu kojeg trebamo odrediti klasu kojoj primjer pripada
- svaka značajka ima odredenu težinu (ne nužno pozitivnu)
- računamo aktivaciju kao težinsku sumu značajki:

$$\text{aktivacija}_w(x) = \sum_i w_i \cdot f_i(x) = w \cdot f(x)$$

- ako je aktivacija:
 - nenegativna, izlaz je +1
 - negativna, izlaz je -1





Linearni klasifikatori

- zadani su nam vektori značajki: svakom primjeru x pridružujemo vektor $f(x)$, na osnovu kojeg trebamo odrediti klasu kojoj primjer pripada
- svaka značajka ima određenu težinu (ne nužno pozitivnu)
- računamo aktivaciju kao težinsku sumu značajki:

$$\text{aktivacija}_w(x) = \sum_i w_i \cdot f_i(x) = w \cdot f(x)$$

- ako je aktivacija:
 - nenegativna, izlaz je +1
 - negativna, izlaz je -1





Linearni klasifikatori

- zadani su nam vektori značajki: svakom primjeru x pridružujemo vektor $f(x)$, na osnovu kojeg trebamo odrediti klasu kojoj primjer pripada
- svaka značajka ima određenu težinu (ne nužno pozitivnu)
- računamo aktivaciju kao težinsku sumu značajki:

$$\text{aktivacija}_w(x) = \sum_i w_i \cdot f_i(x) = w \cdot f(x)$$

- ako je aktivacija:
 - nenegativna, izlaz je +1
 - negativna, izlaz je -1





Linearni klasifikatori

- zadani su nam vektori značajki: svakom primjeru x pridružujemo vektor $f(x)$, na osnovu kojeg trebamo odrediti klasu kojoj primjer pripada
- svaka značajka ima određenu težinu (ne nužno pozitivnu)
- računamo aktivaciju kao težinsku sumu značajki:

$$\text{aktivacija}_w(x) = \sum_i w_i \cdot f_i(x) = w \cdot f(x)$$

- ako je aktivacija:
 - nenegativna, izlaz je +1
 - negativna, izlaz je -1





- u binarnom slučaju: uspoređuju se značajke s vektorom težina
- učenje: odrediti vektor težina s obzirom na primjere

Pravilo odluke

- u prostoru vektora značajki:
 - primjeri su točke
 - svaki vektor težina je hiperravnina
 - jedna strana odgovara vrijednosti $Y = +1$
 - druga strana odgovara vrijednosti $Y = -1$





- u binarnom slučaju: uspoređuju se značajke s vektorom težina
- učenje: odrediti vektor težina s obzirom na primjere

Pravilo odluke

- u prostoru vektora značajki:
 - primjeri su točke
 - svaki vektor težina je hiperravnina
 - jedna strana odgovara vrijednosti $Y = +1$
 - druga strana odgovara vrijednosti $Y = -1$





Korigiranje težina: binarni perceptron

- inicijaliziraj sve težine na 0
- za svaki primjer iz skupa za učenje:
 - klasificiraj s obzirom na trenutne težine

$$y = \begin{cases} +1, & \text{ako je } w \cdot f(x) \geq 0 \\ -1, & \text{ako je } w \cdot f(x) < 0 \end{cases}$$

- ako je primjer dobro svrstan (tj. $y = y^*$), nema promjene
- ako je primjer krivo svrstan, popravi vektor težina

$$w = w + y^* \cdot f(x)$$





Višeklasno pravilo odluke

- ako imamo više klasa tada:
 - svakoj klasi y pridružujemo vektor težina w_y
 - izračunamo aktivaciju klase y : $w_y \cdot f(x)$
 - klasificiramo u klasu s najvećom aktivacijom

$$y = \arg \max_y w_y \cdot f(x)$$





Učenje: višeklasni perceptron

- inicijaliziraj sve težine na 0
- za svaki primjer iz skupa za učenje:
 - klasificiraj s obzirom na trenutne težine

$$y = \arg \max_y w_y \cdot f(x)$$

- ako je primjer dobro svrstan (tj. $y = y^*$), nema promjene
- ako je primjer krivo svrstan, popravi vektore težina

$$w_y = w_y - f(x)$$

$$w_{y^*} = w_{y^*} + f(x)$$





- odvojivost / separabilnost: ukoliko postoje parametri koji cijeli skup za učenje pravilno klasificiraju
- konvergencija: ukoliko je skup za učenje separabilan, perceptron konvergira u binarnom slučaju
- u slučaju neodvojivih primjera, moguće je uzeti srednju vrijednost kao separator





Poboljšavanje perceptrona

- minimalno ispravljujuće ažuriranje:

$$w_y = w'_y - \tau f(x)$$

$$w_{y^*} = w'_{y^*} + \tau f(x)$$

$$\min_w \frac{1}{2} \sum_y \|w_y - w'_y\|^2$$

uz uvjet $w_{y^*} \cdot f \geq w_y \cdot f + 1$

$$\tau = \frac{(w'_y - w'_{y^*}) \cdot f + 1}{2f \cdot f}$$





Poboljšavanje perceptrona

- minimalno ispravljujuće ažuriranje:

$$w_y = w'_y - \tau f(x)$$

$$w_{y^*} = w'_{y^*} + \tau f(x)$$

$$\min_w \frac{1}{2} \sum_y \|w_y - w'_y\|^2$$

uz uvjet $w_{y^*} \cdot f \geq w_y \cdot f + 1$

$$\tau = \frac{(w'_y - w'_{y^*}) \cdot f + 1}{2f \cdot f}$$





Poboljšavanje perceptrona

- ponekad je ova vrijednost prevelika, pa se može uvesti maksimalna veličina koraka C i τ tada definiramo kao

$$\tau = \min \left\{ \frac{(w'_y - w'_{y^*}) \cdot f + 1}{2f \cdot f}, C \right\}$$

- metoda potpornih vektor: maksimizirati margine (ima smisla intuitivno, teoretski i praktično)
- u obzir se uzimaju samo potpuni vektori (primjeri najbliži hiperravnini), dok se ostali primjeri ignoriraju
- kao rezultat se dobije separator s maksimalnim marginama

$$\min_w \frac{1}{2} \sum_y \|w\|^2$$

uz uvjet $\forall i, y \quad w_{y^*} \cdot f(x_i) \geq w_y \cdot f(x_i) + 1$





Poboljšavanje perceptrona

- ponekad je ova vrijednost prevelika, pa se može uvesti maksimalna veličina koraka C i τ tada definiramo kao

$$\tau = \min \left\{ \frac{(w'_y - w'_{y^*}) \cdot f + 1}{2f \cdot f}, C \right\}$$

- metoda potpornih vektor: maksimizirati margine (ima smisla intuitivno, teoretski i praktično)
- u obzir se uzimaju samo potpuni vektori (primjeri najbliži hiperravnini), dok se ostali primjeri ignoriraju
- kao rezultat se dobije separator s maksimalnim marginama

$$\min_w \frac{1}{2} \sum_y \|w\|^2$$

uz uvjet $\forall i, y \quad w_{y^*} \cdot f(x_i) \geq w_y \cdot f(x_i) + 1$





Poboljšavanje perceptrona

- ponekad je ova vrijednost prevelika, pa se može uvesti maksimalna veličina koraka C i τ tada definiramo kao

$$\tau = \min \left\{ \frac{(w'_y - w'_{y^*}) \cdot f + 1}{2f \cdot f}, C \right\}$$

- metoda potpornih vektor: maksimizirati margine (ima smisla intuitivno, teoretski i praktično)
- u obzir se uzimaju samo potpuni vektori (primjeri najbliži hiperravnini), dok se ostali primjeri ignoriraju
- kao rezultat se dobije separator s maksimalnim marginama

$$\min_w \frac{1}{2} \sum_y \|w\|^2$$

uz uvjet $\forall i, y \quad w_{y^*} \cdot f(x_i) \geq w_y \cdot f(x_i) + 1$

