

Završni ispit iz Strojnog učenja 1 (ak. god. 2023./2024.)

– NEKORIGIRANA VERZIJA –

Ispit sadrži 22 pitanja i ukupno nosi najviše 20 bodova (za 30% bodova na predmetu). Pitanja nose po 1 bod, a 1/3 boda oduzima se za pogrešan odgovor. Za maksimalan broj bodova dovoljno je točno riješiti 20 pitanja, a višak bodova iznad 20 se zanemaruje. Trajanje ispita je 180 minuta. Primjerak ispita morate predati zajedno sa svojim rješenjima.

Cjelina 4: Procjena parametara i Bayesov klasifikator (8 pitanja)

1 (P) Gaussov Bayesov klasifikator koristimo za klasifikaciju jednodimenzijskih podataka u tri klase. Procijenjene izglednosti klasa su $p(x|y=1) = \mathcal{N}(-10, 2)$, $p(x|y=2) = \mathcal{N}(2, 2)$ i $p(x|y=3) = \mathcal{N}(8, 2)$, a procijenjene apriorne vjerojatnosti klasa su $P(y=1) = P(y=2) = 1/5$ i $P(y=3) = 3/5$. Međutim, nakon što smo naučili ovaj model, zaključili smo da na ispitnom skupu postoji pomak u distribuciji podataka u odnosu na skup za učenje te da zbog toga model ne generalizira dobro. Zaključili smo da se ovo može ispraviti tako da se naučeni model malo izmijeni, i to tako da se varijanca izglednosti klase $y=1$ postavi na 5 i da se apriorne vjerojatnosti klasa ujednače, $P(y=1) = P(y=2) = P(y=3) = 1/3$. Skicirajte gustoće zajedničke vjerojatnosti naučenog i izmijenjenog modela. Neka su h_1 i h_2 MAP-hipoteze prvog i drugog modela, te neka su a i b pozitivne konstante. Razmotrite segment ulaznog prostora za koji vrijedi $-10 \leq x \leq 10$. Na kojim se dijelovima tog segmenta ulaznog prostora MAP-hipoteze prvog i drugog modela razlikuju?

- A $[-4 - a, -4 + b]$ B $[-4, -4 - a] \cup [5, 5 + b]$ C $[-4 - a, 5 + b]$ D $[-4, -4 + a] \cup [5 - b, 5]$

2 (P) Gaussovim Bayesovim klasifikatorom rješavamo problem klasifikacije u $K=10$ klasa sa $n=100$ značajki. Prisjetite se da kod Gaussovog Bayesovog klasifikatora uvođenjem odgovarajućih pretpostavki na kovarijacijsku matricu Σ možemo utjecati na broj parametara modela a time onda i na složenost modela. Razmatramo tri modela s kovarijacijskim matricama u koje smo ugradili sljedeće pretpostavke:

\mathcal{H}_1 : Značajke imaju različite varijance, ali iste za sve klase, te nisu korelirane

\mathcal{H}_2 : Značajke nisu korelirane, imaju jednaku varijancu unutar svake klase, no različitu za svaku klasu

\mathcal{H}_3 : Između značajki postoje korelacije, ali se one ne razlikuju između klasa

Neka '⊃' označava relaciju "složeniji od", a neka '>' označava relaciju "ima više parametara od". Što možemo zaključiti o složenosti i broju parametara za gornja četiri modela?

- A $\mathcal{H}_1 > \mathcal{H}_2 > \mathcal{H}_3, \mathcal{H}_1 \supset \mathcal{H}_2$ C $\mathcal{H}_3 > \mathcal{H}_1 > \mathcal{H}_2, \mathcal{H}_3 \supset \mathcal{H}_1$
 B $\mathcal{H}_3 > \mathcal{H}_2 > \mathcal{H}_1, \mathcal{H}_3 \supset \mathcal{H}_1 \supset \mathcal{H}_2$ D $\mathcal{H}_1 > \mathcal{H}_3 > \mathcal{H}_2, \mathcal{H}_1 \supset \mathcal{H}_2 \supset \mathcal{H}_3$

3 (N) Treniramo Bayesov klasifikator za odluku o dobroj destinaciji za Erasmus+ studentski boravak. Skup primjera za učenje, izgrađen na temelju iskustava prijatelja i prijatelja prijatelja, je sljedeći:

i	Država	Stipendija	Semestar	Studij	GovoriJezik	$y^{(i)}$
1	Njemačka	da	ljetni	dipl	da	1
2	Poljska	ne	zimski	preddipl	ne	1
3	Italija	da	ljetni	dipl	da	1
4	Njemačka	ne	zimski	preddipl	ne	0
5	Austrija	da	ljetni	dipl	da	1
6	Poljska	ne	zimski	dipl	ne	1
7	Austrija	da	zimski	dipl	ne	1
8	Njemačka	ne	zimski	dipl	ne	0

Očekujemo zavisnost između varijabli *Država* i *Stipendija*, pa koristimo polunaiivan Bayesov klasifikator u kojemu su te dvije varijable združene. Procjene izglednosti klasa radimo Laplaceovim MAP-procjeniteljem. Zanima nas klasifikacija za $\mathbf{x} = (\text{Italija, ne, zimski, preddipl, ne})$. Koliko iznosi aposteriorna vjerojatnost $P(y=1|\mathbf{x})$?

- A 0.588 B 0.488 C 0.322 D 0.741

4 (T) Polunaivan Bayesov klasifikator može ostvariti veću klasifikacijsku točnost od naivnog Bayesovog klasifikatora u situacijama kada između značajki postoji zavisnost. Jedan način određivanja zavisnosti između značajki temelji se na izračunu Kullback-Leiblerove divergencije (KL-divergencije) između distribucija dviju varijabli. **Koji je princip uporabe KL-divergencije u izgradnji polunaivnog Bayesovog klasifikatora?**

- A Što je manja KL-divergencija između $P(x_1)$ i $P(x_2)$, to su varijable x_1 i x_2 više zavisne, pa je to veća korist od njihovog združivanja u jedan faktor
- B Ako je KL-divergencija između $P(x_1)P(x_2)$ i $P(x_1, x_2)$ jednaka nuli, onda su varijable linearno zavisne i treba ih odvojiti u zasebne faktore
- C Ako je KL-divergencija između $P(x_1|x_2)$ i $P(x_2|x_1)$ vrlo mala, onda su varijable x_1 i x_2 vrlo zavisne i treba ih odvojiti u zasebne faktore
- D Što je veća KL-divergencija između $P(x_1)P(x_2)$ i $P(x_1, x_2)$, to su varijable x_1 i x_2 manje nezavisne, pa je to veća korist od njihovog združivanja u jedan faktor

5 (N) Na skupu označenih primjera u ulaznome prostoru dimenzije $n = 2$ treniramo Gaussov Bayesov klasifikator za klasifikaciju primjera u $K = 2$ klase, uz pretpostavku dijeljene i dijagonalne kovarijacijske matrice. Izglednost klase s oznakom $y = j$ definirana je multivarijantnom Gaussovom gustoćom vjerojatnosti:

$$p(\mathbf{x}|y = j) = \frac{1}{(2\pi)^{n/2}|\boldsymbol{\Sigma}_j|^{1/2}} \exp\left\{-\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu}_j)^T \boldsymbol{\Sigma}_j^{-1}(\mathbf{x} - \boldsymbol{\mu}_j)\right\}$$

Model treniramo na skupu podataka od $N = 7$ primjera:

$$\mathcal{D} = \{(\mathbf{x}^{(i)}, y^{(i)})\}_i = \{((-4, -2), 0), ((0, 0), 0), ((4, 2), 0), ((3, -1), 1), ((4, -1), 1), ((4, 1), 1), ((5, 1), 1)\}$$

Procijenite parametre modela na ovom skupu primjera. Budući da je skup primjera malen, za procjenu kovarijacijske matrice koristite nepristran procjenitelj. Izlaz modela za klasu $y = j$ neka je zajednička gustoća vjerojatnosti, $h_j(\mathbf{x}) = \ln p(\mathbf{x}, y = j)$. **Koliko iznosi $h_1(\mathbf{x})$ za primjer $\mathbf{x} = (4, 0)$?**

- A -2.75 B -3.84 C -4.13 D -3.03

6 (T) Bayesov klasifikator temelji se na hipotezi *maximum a posteriori* (MAP). Za treniranje Bayesovog klasifikatora možemo koristiti procjenitelj MLE. **Koja je razlika između hipoteze MAP kod Bayesovog klasifikatora i procjenitelja MLE?**

- A Procjenitelj MLE određuje apriornu vjerojatnost klase, a hipoteza MAP maksimizira aposterionu vjerojatnost parametara
- B Hipoteza MAP maksimizira aposterionu vjerojatnost parametara, a procjenitelj MLE određuje aposterionu vjerojatnost klase za zadani primjer
- C Procjenitelj MLE primjer klasificira u klasu koja je za njega navjerojatnija, a hipoteza MAP tu odluku kombinira s apriornim znanjem
- D Hipoteza MAP određuje koju klasu odabirati za primjer, a procjenitelj MLE određuje koju vrijednost odabirati za parametar

7 (N) Zadan je uzorak kontinuirane slučajne varijable, $\mathcal{D} = \{10, 5, 6, 20\}$. Pretpostavljamo razdiobu $\mathcal{N}(\mu, \sigma^2)$, čija je gustoća vjerojatnosti:

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

Za procjenu parametra μ koristimo procjenitelj $\hat{\mu}_{\text{MLE}}$, a za procjenu parametra σ^2 procjenitelj $\hat{\sigma}_{\text{UB}}^2$, koji je nepristran procjenitelj izveden odgovarajućom korekcijom iz procjenitelja $\hat{\sigma}_{\text{MLE}}^2$. Izračunajte log-izglednost procijenjenih parametara na skupu \mathcal{D} , tj. $\ln \mathcal{L}(\hat{\mu}_{\text{MLE}}, \hat{\sigma}_{\text{UB}}^2|\mathcal{D})$. **Koliko iznosi ta log-izglednost?**

- A -13.163 B -12.873 C -10.832 D -15.200

8 (P) Uz određene restrikcije na parametre Gaussovog Bayesovog klasifikatora, Gaussov Bayesov klasifikator i logistička regresija su generativno-diskriminativni par modela. U pravilu, logistička regresija imaće manje parametara od njoj odgovarajućeg modela Gaussovog Bayesovog klasifikatora. Razmotrite slučaj binarne klasifikacije u ulaznome prostoru dimenzije $n = 300$ pomoću modela logističke regresije i njoj odgovarajućeg modela Gaussovog Bayesovog klasifikatora. **Koliko će model Gaussovog Bayesovog klasifikatora imati više parametara od modela logističke regresije?**

- A 45450 B 40400 C 90600 D 20300

Cjelina 5: Probabilistički grafički modeli (5 pitanja)

- 9 (T) Probabilistički grafički modeli na sažet način prikazuju zajedničku distribuciju n slučajnih varijabli. Ta je distribucija prikazana usmjerenim grafom. Neka graf sadrži čvor označen sa x . Čemu odgovara taj čvor?
- A Distribuciji varijable x uvjetovane vrijednostima varijabli roditeljskih čvorova od x
- B Distribuciji varijable x uz opažene sve varijable koje varijabli x prethode u topološkom uređaju
- C Marginalnoj vjerojatnosti $P(x)$ ili marginalnoj gustoći vjerojatnosti $p(x)$
- D Zajedničkoj vjerojatnosti varijable x i varijabli roditeljskih čvorova od x

- 10 (P) Bayesova mreža ima pet varijabli, s topološkim uređajem v, w, x, y, z . Uz takav uređaj, u mreži vrijede sljedeće uvjetne nezavisnosti:

$$\{v, w\} \perp y | x \quad \{v, x\} \perp z | \{w, y\}$$


Primjenom algoritma d-odvajanja ispitujemo zavisnosti između parova varijabli. Koje od sljedećih tvrdnji o nezavisnosti vrijede u ovoj Bayesovoj mreži?

- A $v \perp z | x$ B $v \perp y | x$ C $v \perp y | z$ D $x \perp z | w$
- 11 (N) Razmotrite jednostavnu Bayesovu mrežu koja odgovara faktorizaciji $P(x, y, z, w) = P(z)P(w)P(y|z, w)P(x|y)$. Sve varijable su binarne. Vrijedi $P(z = 1) = 0.1$, $P(w = 1) = 0.1$, $P(x = 1|y = 0) = 0.2$ i $P(x = 1|y = 1) = 0.6$. Tablica uvjetne vjerojatnosti za čvor y je sljedeća:

z	w	$p(y = 1 z, w)$
0	0	0
0	1	0.4
1	0	0.2
1	1	0.7


Postupkom uzorkovanja s odbijanjem uzorkujemo iz aposteriorne distribucije $P(w|x = 0, z = 1)$. Uzorkovanje smo ponovili ukupno $N = 10000$ puta, od čega smo neke vektore morali odbaciti, pa je naš konačni uzorak manji od N . U uzorku neodbačenih vektora, koliko je očekivano više vektora sa $w = 0$ od vektora sa $w = 1$?

- A 472 B 596 C 944 D 348
- 12 (P) Na slici ispod prikazana je Bayesova mreža koja odgovara polunaivnom Bayesovom klasifikatoru. Pretpostavite da su značajke x_1 , x_2 i x_3 ternarne varijable te da je oznaka klase y također ternarna varijabla. Označimo ovaj model sa \mathcal{H}_2 . Model \mathcal{H}_2 može se pojednostaviti ako se ukloni brid između varijabli x_2 i x_3 . Označimo takav model sa \mathcal{H}_1 . S druge strane, od modela \mathcal{H}_2 može se napraviti još složeniji model tako da se doda brid između varijabli x_1 i x_2 . Označimo takav model sa \mathcal{H}_3 .



Razmotrite koliko parametara imaju modeli \mathcal{H}_1 , \mathcal{H}_2 i \mathcal{H}_3 . Koliko model \mathcal{H}_2 ima više parametara od modela \mathcal{H}_1 , a koliko manje parametara od modela \mathcal{H}_3 ?

- A 8 više, 8 manje B 12 više, 12 manje C 2 više, 4 manje D 12 više, 8 manje
- 13 (N) Na slici ispod prikazana je Bayesova mreža za problem prskalice za travu. Varijable su: C (oblačno/cloudy), S (prskalica/sprinkler), R (kiša/rain) i W (mokra trava/wet grass). Dane su i tablice uvjetnih vjerojatnosti.



C	$P(S = 1 C)$
0	0.5
1	0.4

C	$P(R = 1 C)$
0	0.2
1	0.8

S	R	$P(W = 1 S, R)$
0	0	0.0
0	1	0.9
1	0	0.1
1	1	0.99

Izračunajte aposteriornu vjerojatnost da radi prskalica ako trava nije mokra i oblačno je.

- A 0.069 B 0.223 C 0.309 D 0.144

Cjelina 6: Grupiranje i vrednovanje modela (9 pitanja)

14 (T) Za procjenu parametara modela GMM (središta grupa μ_k , kovarijacijske matrice Σ_k i koeficijenti mješavine π_k) tipično se koristi algoritam maksimizacije očekivanja (EM-algoritam). Prije pokretanja EM-algoritma, parametre je potrebno inicijalizirati. U praksi se za inicijalizaciju parametara μ_k koristi algoritam K-sredina. **Koji je očekivani efekt uporabe algoritma K-sredina za inicijalizaciju EM-algoritma?**

- A Veća potpuna log-izglednost konačnih parametara i veće vrijednosti gustoća komponenti
- B Veća log-izglednost početnih i konačnih parametara te manje iteracija do konvergencije
- C Manja log-izglednost početnih i konačnih parametara te optimalan broj grupa K
- D Manja log-izglednost početnih parametara, ali veća log-izglednost konačnih parametara

15 (T) Kod vrednovanja algoritma strojnog učenja važno je da vrednujemo model optimalne složenosti. Zbog toga označeni skup podataka dijelimo na tri disjunktne podskupa: skup za učenje, skup za provjeru i ispitni skup. Za odabir modela (tj. optimizaciju hiperparametara) koristimo skup za učenje i skup za provjeru, dok točnost optimalnog modela ispitujemo na ispitnome skupu. Zamislite da smo zaboravili upotrijebiti skup za provjeru: umjesto toga hiperparametre modela optimirali smo na skupu za učenje, a model smo potom ispitali na ispitnom skupu. **U odnosu na to da smo pravilno proveli vrednovanje algoritma, što možemo očekivati u ovom slučaju?**

- A Model će biti prenaučen i imat će manju točnost na ispitnome skupu
- B Model će biti prenaučen, ali imat će veću točnost na ispitnome skupu
- C Model će biti podnaučen, ali imat će veću točnost na ispitnome skupu
- D Model će biti optimalne složenosti i imat će veću točnost na ispitnome skupu

16 (P) Skup neoznačenih primjera u dvodimenzijaskome ulaznom prostoru neka je sljedeći:

$$\mathcal{D} = \{\mathbf{x}^{(i)}\}_i = \{(1, 1), (1, 3), (1, 4), (3, 4)\}$$

Primjere grupiramo u $K = 2$ grupe algoritmom K-means++. Konačna vrijednost funkcije pogreške J bit će različita za različita pokretanja algoritma. Razmotrite sve moguće konačne vrijednosti funkcije J , tj. vrijednosti funkcije J nakon što se algoritam K-means++ zaustavi. **Koliko iznosi maksimalna moguća konačna vrijednost funkcije J ?**

- A 4 B 11/2 C 10/3 D 14/3

17 (N) Algoritmom hijerarhijskog aglomerativnog grupiranja (HAC) grupiramo $N = 5$ primjera. Za grupiranje koristimo mjeru sličnosti, definiranu sljedećom matricom:

$$\begin{pmatrix} 1.0 & 0.2 & 0.8 & 0.1 & 0.4 \\ 0.2 & 1.0 & 0.3 & 0.3 & 0.7 \\ 0.8 & 0.3 & 1.0 & 0.6 & 0.5 \\ 0.1 & 0.3 & 0.6 & 1.0 & 0.4 \\ 0.4 & 0.7 & 0.5 & 0.4 & 1.0 \end{pmatrix}$$

Provedite grupiranje algoritmom HAC s potpunim povezivanjem. Pritom u svakoj iteraciji bilježite na kojoj razini sličnosti se odvija stapanje dviju grupa. **Koliko iznosi zbroj po svim razinama sličnosti na kojima se odvija stapanje grupa?**

- A 2.4 B 1.9 C 1.8 D 2.0

18 (N) Particijskim algoritmom grupiranja grupiramo $N = 1000$ primjera. Na temelju znanja o problemu zaključili smo da bi primjeri trebali formirati $K = 3$ grupe, pa smo s tim brojem grupa proveli grupiranje. Kako bismo evaluirali točnost grupiranja, slučajnim odabirom smo iz skupa primjera uzorkovali 10 primjera, ručno smo označili primjere iz tog uzorka, i zatim na tom uzorku računamo Randov indeks. Označavanje smo proveli tako da smo svakom primjeru iz uzorka dodijelili oznaku točne grupe. Oznake grupe dobivene algoritmom grupiranja y_{pred} i oznake točnih grupa y_{true} za svih deset primjera u uzorku su sljedeće:

i	1	2	3	4	5	6	7	8	9	10
$y_{pred}^{(i)}$	0	0	2	1	1	0	0	2	1	1
$y_{true}^{(i)}$	1	0	0	2	1	0	2	1	1	1

Koliko iznosi Randov indeks grupiranja izračunat na ovom uzorku?

- A 0.62 B 0.58 C 0.53 D 0.49

19 (N) Vrednujemo višeklasni klasifikator koji koristimo kao referentni model za vrednovanje drugih klasifikatora. Klasifikator nasumično dodjeljuje oznake za tri klase ($K = 3$), i to prema distribuciji oznaka na skupu za učenje. Skup za učenje sadrži 100 primjera sa 35, 60 i 5 primjera u prvoj, drugoj odnosno trećoj klasi. S druge strane, ispitni skup sadrži 50 primjera, od kojih je po 20 u prvoj i drugoj klasi, a 10 u trećoj klasi. **Koliko iznosi očekivana makro-F1 vrijednost nasumičnog klasifikatora na ispitnome skupu?**

- A 0.3111 B 0.2085 C 0.2989 D 0.2156

20 (T) Algoritam K-sredina iterativno smanjuje vrijednost funkcije pogreške J . Neovisno o broju grupa K , algoritam uvijek konvergira (završava s izvođenjem). Međutim, konačna vrijednost funkcije pogreške J može se razlikovati između dva pokretanja algoritma s istim brojem grupa K . **Zašto?**

- A Zbog nelinearnosti granice između K grupa
 B Zbog razlike u početnim središtima μ_k
 C Zbog izotropnosti kovarijacijskih matrica Σ_k
 D Zbog loše odabrane vrijednosti za broj grupa K

21 (P) Podatke u dvodimenzijaskome ulaznom prostoru ($n = 2$) grupiramo u dvije grupe ($K = 2$) algoritmom Gaussove mješavine (GMM). Skup podataka je sljedeći:

$$\mathcal{D} = \{\mathbf{x}^{(i)}\}_{i=1}^8 = \{(-2, -2), (-2, -1), (-1, -2), (-1, -1), (1, 2), (3, 1), (3, 3), (5, 2)\}$$

Razmatramo dva modela: \mathcal{H}_1 i \mathcal{H}_2 . Oba modela koriste punu kovarijacijsku matricu, međutim kod modela \mathcal{H}_1 kovarijacijska matrica nije dijeljena, dok je kod modela \mathcal{H}_2 kovarijacijska matrica dijeljena. Za svaki model razmotrite ono grupiranje koje maksimizira log-izglednost na skupu \mathcal{D} . Neka je $p_j(\mathbf{x}^{(i)}|y = k)$ izglednost grupe $y = k$ za primjer $\mathbf{x}^{(i)}$ prema modelu \mathcal{H}_j . Oznake grupa su $y = 1$ i $y = 2$, te pretpostavite da je grupiranje takvo da vrijedi $\|\mu_1\| > \|\mu_2\|$. **Što od sljedećega vrijedi?**

- A $p_2(\mathbf{x}^{(8)}|y = 1) < p_1(\mathbf{x}^{(5)}|y = 1)$ C $p_2(\mathbf{x}^{(4)}|y = 2) > p_1(\mathbf{x}^{(3)}|y = 2)$
 B $p_2(\mathbf{x}^{(6)}|y = 1) < p_1(\mathbf{x}^{(7)}|y = 1)$ D $p_2(\mathbf{x}^{(1)}|y = 2) > p_1(\mathbf{x}^{(2)}|y = 2)$

22 (P) Raspoložemo sa 1250 označenih primjera. Na tom skupu treniramo i vrednujemo algoritam SVM, optimizirajući hiperparametre C i γ . Za vrednovanje koristimo ugniježdenu unakrsnu provjeru sa 5 preklopa u vanjskoj petlji i 5 preklopa u unutarnjoj petlji. To znači da za svaku kombinaciju vrijednosti hiperparametara C i γ treniramo pet modela. Ti modeli trenirani su na skupovima za učenje koji nisu disjunktni: svaki par treniranih modela dijele određeni broj primjera za učenje. Izračunajte koliko primjera za učenje dijele svaki par modela koje treniramo u unutarnjoj petlji ugniježdene unakrsne provjere. **Za koliko bi taj broj narastao kada bismo broj preklopa u unutarnjoj petlji povećali na 10?**

- A 200 B 100 C 125 D 240

Završni ispit iz Strojnog učenja 1 (ak. god. 2023./2024.)

– NEKORIGIRANA VERZIJA –

Ispit sadrži 22 pitanja i ukupno nosi najviše 20 bodova (za 30% bodova na predmetu). Pitanja nose po 1 bod, a 1/3 boda oduzima se za pogrešan odgovor. Za maksimalan broj bodova dovoljno je točno riješiti 20 pitanja, a višak bodova iznad 20 se zanemaruje. Trajanje ispita je 180 minuta. Primjerak ispita morate predati zajedno sa svojim rješenjima.

Cjelina 4: Procjena parametara i Bayesov klasifikator (8 pitanja)

- 1 (P) Gaussovim Bayesovim klasifikatorom rješavamo problem klasifikacije u $K = 10$ klasa sa $n = 100$ značajki. Prisjetite se da kod Gaussovog Bayesovog klasifikatora uvođenjem odgovarajućih pretpostavki na kovarijacijsku matricu Σ možemo utjecati na broj parametara modela a time onda i na složenost modela. Razmatramo tri modela s kovarijacijskim matricama u koje smo ugradili sljedeće pretpostavke:

\mathcal{H}_1 : Značajke imaju različite varijance, ali iste za sve klase, te nisu korelirane

\mathcal{H}_2 : Značajke nisu korelirane, imaju jednaku varijancu unutar svake klase, no različitu za svaku klasu

\mathcal{H}_3 : Između značajki postoje korelacije, ali se one ne razlikuju između klasa

Neka '⊃' označava relaciju "složeniji od", a neka '>' označava relaciju "ima više parametara od". Što možemo zaključiti o složenosti i broju parametara za gornja četiri modela?

- A $\mathcal{H}_3 > \mathcal{H}_1 > \mathcal{H}_2$, $\mathcal{H}_3 \supset \mathcal{H}_1$ C $\mathcal{H}_1 > \mathcal{H}_3 > \mathcal{H}_2$, $\mathcal{H}_1 \supset \mathcal{H}_2 \supset \mathcal{H}_3$
 B $\mathcal{H}_1 > \mathcal{H}_2 > \mathcal{H}_3$, $\mathcal{H}_1 \supset \mathcal{H}_2$ D $\mathcal{H}_3 > \mathcal{H}_2 > \mathcal{H}_1$, $\mathcal{H}_3 \supset \mathcal{H}_1 \supset \mathcal{H}_2$

- 2 (T) Polunaivan Bayesov klasifikator može ostvariti veću klasifikacijsku točnost od naivnog Bayesovog klasifikatora u situacijama kada između značajki postoji zavisnost. Jedan način određivanja zavisnosti između značajki temelji se na izračunu Kullback-Leiblerove divergencije (KL-divergencije) između distribucija dviju varijabli. Koji je princip uporabe KL-divergencije u izgradnji polunaivnog Bayesovog klasifikatora?

- A Ako je KL-divergencija između $P(x_1|x_2)$ i $P(x_2|x_1)$ vrlo mala, onda su varijable x_1 i x_2 vrlo zavisne i treba ih odvojiti u zasebne faktore
 B Što je manja KL-divergencija između $P(x_1)$ i $P(x_2)$, to su varijable x_1 i x_2 više zavisne, pa je to veća korist od njihovog združivanja u jedan faktor
 C Ako je KL-divergencija između $P(x_1)P(x_2)$ i $P(x_1, x_2)$ jednaka nuli, onda su varijable linearno zavisne i treba ih odvojiti u zasebne faktore
 D Što je veća KL-divergencija između $P(x_1)P(x_2)$ i $P(x_1, x_2)$, to su varijable x_1 i x_2 manje nezavisne, pa je to veća korist od njihovog združivanja u jedan faktor

- 3 (N) Zadan je uzorak kontinuirane slučajne varijable, $\mathcal{D} = \{10, 5, 6, 20\}$. Pretpostavljamo razdiobu $\mathcal{N}(\mu, \sigma^2)$, čija je gustoća vjerojatnosti:

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

Za procjenu parametra μ koristimo procjenitelj $\hat{\mu}_{\text{MLE}}$, a za procjenu parametra σ^2 procjenitelj $\hat{\sigma}_{\text{UB}}^2$, koji je nepristran procjenitelj izveden odgovarajućom korekcijom iz procjenitelja $\hat{\sigma}_{\text{MLE}}^2$. Izračunajte log-izglednost procijenjenih parametara na skupu \mathcal{D} , tj. $\ln \mathcal{L}(\hat{\mu}_{\text{MLE}}, \hat{\sigma}_{\text{UB}}^2 | \mathcal{D})$. Koliko iznosi ta log-izglednost?

- A -10.832 B -15.200 C -13.163 D -12.873

- 4 (N) Na skupu označenih primjera u ulaznome prostoru dimenzije $n = 2$ treniramo Gaussov Bayesov klasifikator za klasifikaciju primjera u $K = 2$ klase, uz pretpostavku dijeljene i dijagonalne kovarijacijske matrice. Izglednost klase s oznakom $y = j$ definirana je multivarijantnom Gaussovom gustoćom vjerojatnosti:

$$p(\mathbf{x}|y = j) = \frac{1}{(2\pi)^{n/2} |\Sigma_j|^{1/2}} \exp\left\{-\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu}_j)^T \Sigma_j^{-1} (\mathbf{x} - \boldsymbol{\mu}_j)\right\}$$

Model treniramo na skupu podataka od $N = 7$ primjera:

$$\mathcal{D} = \{(\mathbf{x}^{(i)}, y^{(i)})\}_i = \{((-1, -2), 0), ((0, 0), 0), ((1, 2), 0), ((3, -1), 1), ((4, -1), 1), ((4, 1), 1), ((5, 1), 1)\}$$

Procijenite parametre modela na ovom skupu primjera. Budući da je skup primjera malen, za procjenu kovarijacijske matrice koristite nepristran procjenitelj. Izlaz modela za klasu $y = j$ neka je zajednička gustoća vjerojatnosti, $h_j(\mathbf{x}) = \ln p(\mathbf{x}, y = j)$. **Koliko iznosi $h_0(\mathbf{x})$ za primjer $\mathbf{x} = (0, 0)$?**

- A -4.13 B -3.03 C -2.75 D -3.84

5 (T) Bayesov klasifikator temelji se na hipotezi *maximum a posteriori* (MAP). Za treniranje Bayesovog klasifikatora možemo koristiti procjenitelj MLE. **Koja je razlika između hipoteze MAP kod Bayesovog klasifikatora i procjenitelja MLE?**

- A Procjenitelj MLE primjer klasificira u klasu koja je za njega navjerojatnija, a hipoteza MAP tu odluku kombinira s apriornim znanjem
- B Hipoteza MAP maksimizira aposterionu vjerojatnost parametara, a procjenitelj MLE određuje aposterionu vjerojatnost klase za zadani primjer
- C Hipoteza MAP određuje koju klasu odabrati za primjer, a procjenitelj MLE određuje koju vrijednost odabrati za parametar
- D Procjenitelj MLE određuje apriornu vjerojatnost klase, a hipoteza MAP maksimizira aposterionu vjerojatnost parametara

6 (N) Treniramo Bayesov klasifikator za odluku o dobroj destinaciji za Erasmus+ studijski boravak. Skup primjera za učenje, izgrađen na temelju iskustava prijatelja i prijatelja prijatelja, je sljedeći:

i	Država	Stipendija	Semestar	Studij	GovoriJezik	$y^{(i)}$
1	Njemačka	da	ljetni	dipl	da	1
2	Poljska	ne	zimski	preddipl	ne	1
3	Italija	da	ljetni	dipl	da	1
4	Njemačka	ne	zimski	preddipl	ne	0
5	Austrija	da	ljetni	dipl	da	1
6	Poljska	ne	zimski	dipl	ne	1
7	Austrija	da	zimski	dipl	ne	1
8	Njemačka	ne	zimski	dipl	ne	0

Očekujemo zavisnost između varijabli *Država* i *Stipendija*, pa koristimo polunaivan Bayesov klasifikator u kojemu su te dvije varijable združene. Procjene izglednosti klasa radimo Laplaceovim MAP-procjeniteljem. Zanima nas klasifikacija za $\mathbf{x} = (\text{Italija}, \text{ne}, \text{zimski}, \text{preddipl}, \text{ne})$. **Koliko iznosi aposteriorna vjerojatnost $P(y = 1|\mathbf{x})$?**

- A 0.741 B 0.322 C 0.488 D 0.588

7 (P) Gaussov Bayesov klasifikator koristimo za klasifikaciju jednodimenzijskih podataka u tri klase. Procijenjene izglednosti klasa su $p(x|y = 1) = \mathcal{N}(-10, 2)$, $p(x|y = 2) = \mathcal{N}(2, 2)$ i $p(x|y = 3) = \mathcal{N}(8, 2)$, a procijenjene apriorne vjerojatnosti klasa su $P(y = 1) = P(y = 2) = 2/5$ i $P(y = 3) = 1/5$. Međutim, nakon što smo naučili ovaj model, zaključili smo da na ispitnom skupu postoji pomak u distribuciji podataka u odnosu na skup za učenje te da zbog toga model ne generalizira dobro. Zaključili smo da se ovo može ispraviti tako da se naučeni model malo izmijeni, i to tako da se varijanca izglednosti klase $y = 1$ postavi na 1 i da se apriorne vjerojatnosti klasa ujednače, $P(y = 1) = P(y = 2) = P(y = 3) = 1/3$. Skicirajte gustoće zajedničke vjerojatnosti naučenog i izmijenjenog modela. Neka su h_1 i h_2 MAP-hipoteze prvog i drugog modela, te neka su a i b pozitivne konstante. Razmotrite segment ulaznog prostora za koji vrijedi $-10 \leq x \leq 10$. **Na kojim se dijelovima tog segmenta ulaznog prostora MAP-hipoteze prvog i drugog modela razlikuju?**

- A $[-4 - a, -4] \cup [5, 5 + b]$ B $[-4, -4 + a] \cup [5 - b, 5]$ C $[-4 - a, 5 + b]$ D $[-4 - a, -4 + b]$

8 (P) Uz određene restrikcije na parametre Gaussovog Bayesovog klasifikatora, Gaussov Bayesov klasifikator i logistička regresija su generativno-diskriminativni par modela. U pravilu, logistička regresija imaće manje parametara od njoj odgovarajućeg modela Gaussovog Bayesovog klasifikatora. Razmotrite slučaj binarne klasifikacije u ulaznome prostoru dimenzije $n = 200$ pomoću modela logističke regresije i njoj odgovarajućeg modela Gaussovog Bayesovog klasifikatora. **Koliko će model Gaussovog Bayesovog klasifikatora imati više parametara od modela logističke regresije?**


- A 90600 B 45450 C 20300 D 40400

Cjelina 5: Probabilistički grafički modeli (5 pitanja)

9 (T) Probabilistički grafički modeli na sažet način prikazuju zajedničku distribuciju n slučajnih varijabli. Ta je distribucija prikazana usmjerenim grafom. Neka graf sadrži čvor označen sa x . Čemu odgovara taj čvor?

- A Distribuciji varijable x uvjetovane vrijednostima varijabli roditeljskih čvorova od x
- B Marginalnoj vjerojatnosti $P(x)$ ili marginalnoj gustoći vjerojatnosti $p(x)$
- C Distribuciji varijable x uz opažene sve varijable koje varijabli x prethode u topološkom uređaju
- D Zajedničkoj vjerojatnosti varijable x i varijabli roditeljskih čvorova od x

10 (N) Na slici ispod prikazana je Bayesova mreža za problem prskalice za travu. Varijable su: C (oblačno/*cloudy*), S (prskalica/*sprinkler*), R (kiša/*rain*) i W (mokra trava/*wet grass*). Dane su i tablice uvjetnih vjerojatnosti.



C	$P(S = 1 C)$
0	0.5
1	0.3


C	$P(R = 1 C)$
0	0.2
1	0.8

S	R	$P(W = 1 S, R)$
0	0	0.0
0	1	0.9
1	0	0.1
1	1	0.99

Izračunajte aposteriornu vjerojatnost da radi prskalica ako trava nije mokra i oblačno je.

- A 0.069 B 0.309 C 0.223 D 0.144

11 (P) Na slici ispod prikazana je Bayesova mreža koja odgovara polunaivnom Bayesovom klasifikatoru. Pretpostavite da su značajke x_1 , x_2 i x_3 ternarne varijable te da je oznaka klase y također ternarna varijabla. Označimo ovaj model sa \mathcal{H}_2 . Model \mathcal{H}_2 može se pojednostaviti ako se ukloni brid između varijabli x_2 i x_3 . Označimo takav model sa \mathcal{H}_1 . S druge strane, od modela \mathcal{H}_2 može se napraviti još složeniji model tako da se doda brid između varijabli x_1 i x_2 . Označimo takav model sa \mathcal{H}_3 .



Razmotrite koliko parametara imaju modeli \mathcal{H}_1 , \mathcal{H}_2 i \mathcal{H}_3 . Koliko model \mathcal{H}_2 ima više parametara od modela \mathcal{H}_1 , a koliko manje parametara od modela \mathcal{H}_3 ?

- A 12 više, 12 manje B 12 više, 8 manje C 4 više, 4 manje D 8 više, 8 manje

12 (P) Bayesova mreža ima pet varijabli, s topološkim uređajem v, w, x, y, z . Uz takav uređaj, u mreži vrijede sljedeće uvjetne nezavisnosti:

$$\{v, w\} \perp y | x \quad \{v, x\} \perp z | \{w, y\}$$

Primjenom algoritma d-odvajanja ispitujemo zavisnosti između parova varijabli. Koje od sljedećih tvrdnji o nezavisnosti vrijede u ovoj Bayesovoj mreži?

- A $v \perp z | w$ B $v \perp z | x$ C $w \perp y | x$ D $v \perp y | z$

13 (N) Razmotrite jednostavnu Bayesovu mrežu koja odgovara faktorizaciji $P(x, y, z, w) = P(z)P(w)P(y|z, w)P(x|y)$. Sve varijable su binarne. Vrijedi $P(z = 1) = 0.1$, $P(w = 1) = 0.3$, $P(x = 1|y = 0) = 0.2$ i $P(x = 1|y = 1) = 0.6$. Tablica uvjetne vjerojatnosti za čvor y je sljedeća:

z	w	$p(y = 1 z, w)$
0	0	0
0	1	0.4
1	0	0.2
1	1	0.7

Postupkom uzorkovanja s odbijanjem uzorkujemo iz aposteriorne distribucije $P(w|x = 0, z = 1)$. Uzorkovanje smo ponovili ukupno $N = 10000$ puta, od čega smo neke vektore morali odbaciti, pa je naš konačni uzorak manji od N . U uzorku neodbačenih vektora, koliko je očekivano više vektora sa $w = 0$ od vektora sa $w = 1$?

- A 472 B 348 C 944 D 596

Cjelina 6: Grupiranje i vrednovanje modela (9 pitanja)

14 (T) Za procjenu parametara modela GMM (središta grupa μ_k , kovarijacijske matrice Σ_k i koeficijenti mješavine π_k) tipično se koristi algoritam maksimizacije očekivanja (EM-algoritam). Prije pokretanja EM-algoritma, parametre je potrebno inicijalizirati. U praksi se za inicijalizaciju parametara μ_k koristi algoritam K-sredina. **Koji je očekivani efekt uporabe algoritma K-sredina za inicijalizaciju EM-algoritma?**

- A Manja log-izglednost početnih i konačnih parametara te optimalan broj grupa K
- B Veća potpuna log-izglednost konačnih parametara i veće vrijednosti gustoća komponenti
- C Veća log-izglednost početnih i konačnih parametara te manje iteracija do konvergencije
- D Manja log-izglednost početnih parametara, ali veća log-izglednost konačnih parametara

15 (T) Kod vrednovanja algoritma strojnog učenja važno je da vrednujemo model optimalne složenosti. Zbog toga označeni skup podataka dijelimo na tri disjunktne podskupa: skup za učenje, skup za provjeru i ispitni skup. Za odabir modela (tj. optimizaciju hiperparametara) koristimo skup za učenje i skup za provjeru, dok točnost optimalnog modela ispitujemo na ispitnome skupu. Zamislite da smo zaboravili upotrijebiti skup za provjeru: umjesto toga hiperparametre modela optimirali smo na skupu za učenje, a model smo potom ispitivali na ispitnom skupu. **U odnosu na to da smo pravilno proveli vrednovanje algoritma, što možemo očekivati u ovom slučaju?**

- A Model će biti podnaučen, ali imat će veću točnost na ispitnome skupu
- B Model će biti optimalne složenosti i imat će veću točnost na ispitnome skupu
- C Model će biti prenaučeni i imat će manju točnost na ispitnome skupu
- D Model će biti prenaučeni, ali imat će veću točnost na ispitnome skupu

16 (N) Particijskim algoritmom grupiranja grupiramo $N = 1000$ primjera. Na temelju znanja o problemu zaključili smo da bi primjeri trebali formirati $K = 3$ grupe, pa smo s tim brojem grupa proveli grupiranje. Kako bismo evaluirali točnost grupiranja, slučajnim odabirom smo iz skupa primjera uzorkovali 10 primjera, ručno smo označili primjere iz tog uzorka, i zatim na tom uzorku računamo Randov indeks. Označavanje smo proveli tako da smo svakom primjeru iz uzorka dodijelili oznaku točne grupe. Oznake grupe dobivene algoritmom grupiranja y_{pred} i oznake točnih grupa y_{true} za svih deset primjera u uzorku su sljedeće:

i	1	2	3	4	5	6	7	8	9	10
$y_{pred}^{(i)}$	0	1	2	1	1	0	0	2	1	1
$y_{true}^{(i)}$	1	0	0	2	1	0	2	1	0	1

Koliko iznosi Randov indeks grupiranja izračunat na ovom uzorku?

- A 0.49 B 0.62 C 0.53 D 0.58

17 (P) Raspoložemo sa 1500 označenih primjera. Na tom skupu treniramo i vrednujemo algoritam SVM, optimizirajući hiperparametre C i γ . Za vrednovanje koristimo ugniježđenu unakrsnu provjeru sa 5 preklopa u vanjskoj petlji i 5 preklopa u unutarnjoj petlji. To znači da za svaku kombinaciju vrijednosti hiperparametara C i γ treniramo pet modela. Ti modeli trenirani su na skupovima za učenje koji nisu disjunktne: svaki par treniranih modela dijele određeni broj primjera za učenje. Izračunajte koliko primjera za učenje dijele svaki par modela koje treniramo u unutarnjoj petlji ugniježđene unakrsne provjere. **Za koliko bi taj broj narastao kada bismo broj preklopa u unutarnjoj petlji povećali na 10?**

- A 150 B 240 C 120 D 288

18 (P) Podatke u dvodimenzijaskome ulaznom prostoru ($n = 2$) grupiramo u dvije grupe ($K = 2$) algoritmom Gaussove mješavine (GMM). Skup podataka je sljedeći:

$$\mathcal{D} = \{\mathbf{x}^{(i)}\}_{i=1}^8 = \{(-2, -2), (-2, -1), (-1, -2), (-1, -1), (1, 2), (3, 1), (3, 3), (5, 2)\}$$

Razmatramo dva modela: \mathcal{H}_1 i \mathcal{H}_2 . Oba modela koriste punu kovarijacijsku matricu, međutim kod modela \mathcal{H}_1 kovarijacijska matrica nije dijeljena, dok je kod modela \mathcal{H}_2 kovarijacijska matrica dijeljena. Za svaki model razmotrite ono grupiranje koje maksimizira log-izglednost na skupu \mathcal{D} . Neka je $p_j(\mathbf{x}^{(i)}|y = k)$ izglednost grupe

$y = k$ za primjer $\mathbf{x}^{(i)}$ prema modelu \mathcal{H}_j . Oznake grupa su $y = 1$ i $y = 2$, te pretpostavite da je grupiranje takvo da vrijedi $\|\boldsymbol{\mu}_1\| > \|\boldsymbol{\mu}_2\|$. Što od sljedećega vrijedi?

- A $p_2(\mathbf{x}^{(1)}|y=2) > p_1(\mathbf{x}^{(2)}|y=2)$ C $p_2(\mathbf{x}^{(4)}|y=2) > p_1(\mathbf{x}^{(3)}|y=2)$
 B $p_2(\mathbf{x}^{(6)}|y=1) < p_1(\mathbf{x}^{(7)}|y=1)$ D $p_2(\mathbf{x}^{(8)}|y=1) < p_1(\mathbf{x}^{(5)}|y=1)$

19 (P) Skup neoznačenih primjera u dvodimenzijaskome ulaznom prostoru neka je sljedeći:

$$\mathcal{D} = \{\mathbf{x}^{(i)}\}_i = \{(1, 1), (1, 3), (1, 4), (3, 4)\}$$

Primjere grupiramo u $K = 2$ grupe algoritmom K-means++. Konačna vrijednost funkcije pogreške J bit će različita za različita pokretanja algoritma. Razmotrite sve moguće konačne vrijednosti funkcije J , tj. vrijednosti funkcije J nakon što se algoritam K-means++ zaustavi. **Koliko iznosi maksimalna moguća konačna vrijednost funkcije J ?**

- A 4 B 14/3 C 11/2 D 10/3

20 (N) Algoritmom hijerarhijskog aglomerativnog grupiranja (HAC) grupiramo $N = 5$ primjera. Za grupiranje koristimo mjeru sličnosti, definiranu sljedećom matricom:

$$\begin{pmatrix} 1.0 & 0.2 & 0.6 & 0.7 & 0.4 \\ 0.2 & 1.0 & 0.3 & 0.3 & 0.7 \\ 0.6 & 0.3 & 1.0 & 0.9 & 0.5 \\ 0.7 & 0.3 & 0.9 & 1.0 & 0.4 \\ 0.4 & 0.7 & 0.5 & 0.4 & 1.0 \end{pmatrix}$$

Provedite grupiranje algoritmom HAC s potpunim povezivanjem. Pritom u svakoj iteraciji bilježite na kojoj razini sličnosti se odvija stapanje dviju grupa. **Koliko iznosi zbroj po svim razinama sličnosti na kojima se odvija stapanje grupa?**

- A 2.4 B 1.8 C 1.9 D 2.0

21 (N) Vrednujemo višeklasni klasifikator koji koristimo kao referentni model za vrednovanje drugih klasifikatora. Klasifikator nasumično dodjeljuje oznake za tri klase ($K = 3$), i to prema distribuciji oznaka na skupu za učenje. Skup za učenje sadrži 100 primjera sa 25, 70 i 5 primjera u prvoj, drugoj odnosno trećoj klasi. S druge strane, ispitni skup sadrži 50 primjera, od kojih je po 10 u prvoj i drugoj klasi, a 30 u trećoj klasi. **Koliko iznosi očekivana makro-F1 vrijednost nasumičnog klasifikatora na ispitnome skupu?**

- A 0.3111 B 0.2989 C 0.2156 D 0.2085

22 (T) Algoritam K-sredina iterativno smanjuje vrijednost funkcije pogreške J . Neovisno o broju grupa K , algoritam uvijek konvergira (završava s izvođenjem). Međutim, konačna vrijednost funkcije pogreške J može se razlikovati između dva pokretanja algoritma s istim brojem grupa K . **Zašto?**

- A Zbog razlike u početnim središtima $\boldsymbol{\mu}_k$
 B Zbog loše odabrane vrijednosti za broj grupa K
 C Zbog izotropnosti kovarijacijskih matrica Σ_k
 D Zbog nelinearnosti granice između K grupa

Završni ispit iz Strojnog učenja 1 (ak. god. 2023./2024.)

– NEKORIGIRANA VERZIJA –

Ispit sadrži 22 pitanja i ukupno nosi najviše 20 bodova (za 30% bodova na predmetu). Pitanja nose po 1 bod, a 1/3 boda oduzima se za pogrešan odgovor. Za maksimalan broj bodova dovoljno je točno riješiti 20 pitanja, a višak bodova iznad 20 se zanemaruje. Trajanje ispita je 180 minuta. Primjerak ispita morate predati zajedno sa svojim rješenjima.

Cjelina 4: Procjena parametara i Bayesov klasifikator (8 pitanja)

- 1 (N) Zadan je uzorak kontinuirane slučajne varijable, $\mathcal{D} = \{10, 5, 6, 20\}$. Pretpostavljamo razdiobu $\mathcal{N}(\mu, \sigma^2)$, čija je gustoća vjerojatnosti:

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

Za procjenu parametra μ koristimo procjenitelj $\hat{\mu}_{\text{MLE}}$, a za procjenu parametra σ^2 procjenitelj $\hat{\sigma}_{\text{UB}}^2$, koji je nepristran procjenitelj izveden odgovarajućom korekcijom iz procjenitelja $\hat{\sigma}_{\text{MLE}}^2$. Izračunajte log-izglednost procijenjenih parametara na skupu \mathcal{D} , tj. $\ln \mathcal{L}(\hat{\mu}_{\text{MLE}}, \hat{\sigma}_{\text{UB}}^2|\mathcal{D})$. **Koliko iznosi ta log-izglednost?**

- A -15.200 B -12.873 C -13.163 D -10.832

- 2 (N) Na skupu označenih primjera u ulaznome prostoru dimenzije $n = 2$ treniramo Gaussov Bayesov klasifikator za klasifikaciju primjera u $K = 2$ klase, uz pretpostavku dijeljene i dijagonalne kovarijacijske matrice. Izglednost klase s oznakom $y = j$ definirana je multivarijantnom Gaussovom gustoćom vjerojatnosti:

$$p(\mathbf{x}|y = j) = \frac{1}{(2\pi)^{n/2}|\Sigma_j|^{1/2}} \exp\left\{-\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu}_j)^T \Sigma_j^{-1}(\mathbf{x} - \boldsymbol{\mu}_j)\right\}$$

Model treniramo na skupu podataka od $N = 7$ primjera:

$$\mathcal{D} = \{(\mathbf{x}^{(i)}, y^{(i)})\}_i = \{((-4, -2), 0), ((0, 0), 0), ((4, 2), 0), ((3, -1), 1), ((4, -1), 1), ((4, 1), 1), ((5, 1), 1)\}$$

Procijenite parametre modela na ovom skupu primjera. Budući da je skup primjera malen, za procjenu kovarijacijske matrice koristite nepristran procjenitelj. Izlaz modela za klasu $y = j$ neka je zajednička gustoća vjerojatnosti, $h_j(\mathbf{x}) = \ln p(\mathbf{x}, y = j)$. **Koliko iznosi $h_0(\mathbf{x})$ za primjer $\mathbf{x} = (0, 0)$?**

- A -3.84 B -2.75 C -3.03 D -4.13

- 3 (P) Uz određene restrikcije na parametre Gaussovog Bayesovog klasifikatora, Gaussov Bayesov klasifikator i logistička regresija su generativno-diskriminativni par modela. U pravilu, logistička regresija imat će manje parametara od njoj odgovarajućeg modela Gaussovog Bayesovog klasifikatora. Razmotrite slučaj binarne klasifikacije u ulaznome prostoru dimenzije $n = 200$ pomoću modela logističke regresije i njoj odgovarajućeg modela Gaussovog Bayesovog klasifikatora. **Koliko će model Gaussovog Bayesovog klasifikatora imati više parametara od modela logističke regresije?**

- A 45450 B 40400 C 90600 D 20300

- 4 (N) Treniramo Bayesov klasifikator za odluku o dobroj destinaciji za Erasmus+ studentski boravak. Skup primjera za učenje, izgrađen na temelju iskustava prijatelja i prijatelja prijatelja, je sljedeći:

i	Država	Stipendija	Semestar	Studij	GovoriJezik	$y^{(i)}$
1	Njemačka	da	ljetni	dipl	da	1
2	Poljska	ne	zimski	preddipl	ne	1
3	Italija	da	ljetni	dipl	da	1
4	Njemačka	ne	zimski	preddipl	ne	0
5	Austrija	da	ljetni	dipl	da	1
6	Poljska	ne	zimski	dipl	ne	1
7	Austrija	da	zimski	dipl	ne	1
8	Njemačka	ne	zimski	dipl	ne	0

Očekujemo zavisnost između varijabli *Država* i *Stipendija*, pa koristimo polunaivan Bayesov klasifikator u kojemu su te dvije varijable združene. Procjene izglednosti klasa radimo Laplaceovim MAP-procjeniteljem. Zanima nas klasifikacija za $\mathbf{x} = (\text{Italija, da, zimski, preddipl, ne})$. **Koliko iznosi aposteriorna vjerojatnost $P(y = 1|\mathbf{x})$?**

- A 0.588 B 0.488 C 0.741 D 0.322

- 5** (P) Gaussovima Bayesovim klasifikatorom rješavamo problem klasifikacije u $K = 10$ klasa sa $n = 100$ značajki. Prisjetite se da kod Gaussovog Bayesovog klasifikatora uvođenjem odgovarajućih pretpostavki na kovarijacijsku matricu Σ možemo utjecati na broj parametara modela a time onda i na složenost modela. Razmatramo tri modela s kovarijacijskim matricama u koje smo ugradili sljedeće pretpostavke:

\mathcal{H}_1 : Značajke imaju različite varijance, ali iste za sve klase, te nisu korelirane

\mathcal{H}_2 : Značajke nisu korelirane, imaju jednaku varijancu unutar svake klase, no različitu za svaku klasu

\mathcal{H}_3 : Između značajki postoje korelacije, ali se one ne razlikuju između klasa

Neka ‘ \supset ’ označava relaciju “složeniji od”, a neka ‘ $>$ ’ označava relaciju “ima više parametara od”. **Što možemo zaključiti o složenosti i broju parametara za gornja četiri modela?**

A $\mathcal{H}_1 > \mathcal{H}_2 > \mathcal{H}_3, \mathcal{H}_1 \supset \mathcal{H}_2$ C $\mathcal{H}_3 > \mathcal{H}_2 > \mathcal{H}_1, \mathcal{H}_3 \supset \mathcal{H}_1 \supset \mathcal{H}_2$

B $\mathcal{H}_3 > \mathcal{H}_1 > \mathcal{H}_2, \mathcal{H}_3 \supset \mathcal{H}_1$ D $\mathcal{H}_1 > \mathcal{H}_3 > \mathcal{H}_2, \mathcal{H}_1 \supset \mathcal{H}_2 \supset \mathcal{H}_3$

- 6** (T) Bayesov klasifikator temelji se na hipotezi *maximum a posteriori* (MAP). Za treniranje Bayesovog klasifikatora možemo koristiti procjenitelj MLE. **Koja je razlika između hipoteze MAP kod Bayesovog klasifikatora i procjenitelja MLE?**

A Hipoteza MAP maksimizira aposterionu vjerojatnost parametara, a procjenitelj MLE određuje aposterionu vjerojatnost klase za zadani primjer

B Procjenitelj MLE određuje apriornu vjerojatnost klase, a hipoteza MAP maksimizira aposterionu vjerojatnost parametara

C Hipoteza MAP određuje koju klasu odabrati za primjer, a procjenitelj MLE određuje koju vrijednost odabrati za parametar

D Procjenitelj MLE primjer klasificira u klasu koja je za njega navjerojatnija, a hipoteza MAP tu odluku kombinira s apriornim znanjem

- 7** (P) Gaussov Bayesov klasifikator koristimo za klasifikaciju jednodimenzijskih podataka u tri klase. Procijenjene izglednosti klasa su $p(x|y = 1) = \mathcal{N}(-10, 2)$, $p(x|y = 2) = \mathcal{N}(2, 2)$ i $p(x|y = 3) = \mathcal{N}(8, 2)$, a procijenjene apriorne vjerojatnosti klasa su $P(y = 1) = P(y = 2) = 1/5$ i $P(y = 3) = 3/5$. Međutim, nakon što smo naučili ovaj model, zaključili smo da na ispitnom skupu postoji pomak u distribuciji podataka u odnosu na skup za učenje te da zbog toga model ne generalizira dobro. Zaključili smo da se ovo može ispraviti tako da se naučeni model malo izmijeni, i to tako da se varijanca izglednosti klase $y = 1$ postavi na 5 i da se apriorne vjerojatnosti klasa ujednače, $P(y = 1) = P(y = 2) = P(y = 3) = 1/3$. Skicirajte gustoće zajedničke vjerojatnosti naučenog i izmijenjenog modela. Neka su h_1 i h_2 MAP-hipoteze prvog i drugog modela, te neka su a i b pozitivne konstante. Razmotrite segment ulaznog prostora za koji vrijedi $-10 \leq x \leq 10$. **Na kojim se dijelovima tog segmenta ulaznog prostora MAP-hipoteze prvog i drugog modela razlikuju?**

A $[-4 - a, 5 + b]$ B $[-4, -4 + a] \cup [5 - b, 5]$ C $[-4, -4 - a] \cup [5, 5 + b]$ D $[-4 - a, -4 + b]$

- 8** (T) Polunaivan Bayesov klasifikator može ostvariti veću klasifikacijsku točnost od naivnog Bayesovog klasifikatora u situacijama kada između značajki postoji zavisnost. Jedan način određivanja zavisnosti između značajki temelji se na izračunu Kullback-Leiblerove divergencije (KL-divergencije) između distribucija dviju varijabli. **Koji je princip uporabe KL-divergencije u izgradnji polunaivnog Bayesovog klasifikatora?**

A Što je manja KL-divergencija između $P(x_1)$ i $P(x_2)$, to su varijable x_1 i x_2 više zavisne, pa je to veća korist od njihovog združivanja u jedan faktor

B Ako je KL-divergencija između $P(x_1|x_2)$ i $P(x_2|x_1)$ vrlo mala, onda su varijable x_1 i x_2 vrlo zavisne i treba ih odvojiti u zasebne faktore

C Ako je KL-divergencija između $P(x_1|x_2)$ i $P(x_2|x_1)$ vrlo velika, onda su varijable x_1 i x_2 vrlo zavisne i treba ih združiti u jedan faktor

D Što je veća KL-divergencija između $P(x_1)P(x_2)$ i $P(x_1, x_2)$, to su varijable x_1 i x_2 manje nezavisne, pa je to veća korist od njihovog združivanja u jedan faktor

Cjelina 5: Probabilistički grafički modeli (5 pitanja)

- 9 (P) Bayesova mreža ima pet varijabli, s topološkim uređajem v, w, x, y, z . Uz takav uređaj, u mreži vrijede sljedeće uvjetne nezavisnosti:

$$\{v, w\} \perp y | x \quad \{v, x\} \perp z | \{w, y\}$$

Primjenom algoritma d-odvajanja ispitujemo zavisnosti između parova varijabli. **Koje od sljedećih tvrdnji o nezavisnosti vrijede u ovoj Bayesovoj mreži?**

- A $v \perp z | x$ B $v \perp y | x$ C $x \perp z | w$ D $v \perp z | y$


- 10 (N) Razmotrite jednostavnu Bayesovu mrežu koja odgovara faktorizaciji $P(x, y, z, w) = P(z)P(w)P(y|z, w)P(x|y)$. Sve varijable su binarne. Vrijedi $P(z = 1) = 0.1$, $P(w = 1) = 0.3$, $P(x = 1|y = 0) = 0.2$ i $P(x = 1|y = 1) = 0.6$. Tablica uvjetne vjerojatnosti za čvor y je sljedeća:

z	w	$p(y = 1 z, w)$
0	0	0
0	1	0.4
1	0	0.2
1	1	0.7

Postupkom uzorkovanja s odbijanjem uzorkujemo iz aposteriorne distribucije $P(w|x = 0, z = 1)$. Uzorkovanje smo ponovili ukupno $N = 10000$ puta, od čega smo neke vektore morali odbaciti, pa je naš konačni uzorak manji od N . **U uzorku neodbačenih vektora, koliko je očekivano više vektora sa $w = 0$ od vektora sa $w = 1$?**

- A 348 B 596 C 472 D 944


- 11 (P) Na slici ispod prikazana je Bayesova mreža koja odgovara polunaivnom Bayesovom klasifikatoru. Pretpostavite da su značajke x_1, x_2 i x_3 ternarne varijable te da je oznaka klase y također ternarna varijabla. Označimo ovaj model sa \mathcal{H}_2 . Model \mathcal{H}_2 može se pojednostaviti ako se ukloni brid između varijabli x_2 i x_3 . Označimo takav model sa \mathcal{H}_1 . S druge strane, od modela \mathcal{H}_2 može se napraviti još složeniji model tako da se doda brid između varijabli x_1 i x_2 . Označimo takav model sa \mathcal{H}_3 .



Razmotrite koliko parametara imaju modeli $\mathcal{H}_1, \mathcal{H}_2$ i \mathcal{H}_3 . **Koliko model \mathcal{H}_2 ima više parametara od modela \mathcal{H}_1 , a koliko manje parametara od modela \mathcal{H}_3 ?**

- A 2 više, 4 manje B 12 više, 8 manje C 8 više, 8 manje D 12 više, 12 manje

- 12 (N) Na slici ispod prikazana je Bayesova mreža za problem prskalice za travu. Varijable su: C (oblačno/*cloudy*), S (prskalica/*sprinkler*), R (kiša/*rain*) i W (mokra trava/*wet grass*). Dane su i tablice uvjetnih vjerojatnosti.



C	$P(S = 1 C)$
0	0.5
1	0.3

C	$P(R = 1 C)$
0	0.2
1	0.8

S	R	$P(W = 1 S, R)$
0	0	0.0
0	1	0.9
1	0	0.1
1	1	0.99

Izračunajte aposteriornu vjerojatnost da radi prskalica ako trava nije mokra i oblačno je.

- A 0.223 B 0.069 C 0.309 D 0.144

- 13 (T) Probabilistički grafički modeli na sažet način prikazuju zajedničku distribuciju n slučajnih varijabli. Ta je distribucija prikazana usmjerenim grafom. Neka graf sadrži čvor označen sa x . **Čemu odgovara taj čvor?**

- A Distribuciji varijable x uvjetovane vrijednostima varijabli roditeljskih čvorova od x
 B Zajedničkoj vjerojatnosti varijable x i varijabli roditeljskih čvorova od x
 C Distribuciji varijable x uz opažene sve varijable koje varijabli x prethode u topološkom uređaju
 D Marginalnoj vjerojatnosti $P(x)$ ili marginalnoj gustoći vjerojatnosti $p(x)$

Cjelina 6: Grupiranje i vrednovanje modela (9 pitanja)

- 14** (P) Podatke u dvodimenzijaskome ulaznom prostoru ($n = 2$) grupiramo u dvije grupe ($K = 2$) algoritmom Gaussove mješavine (GMM). Skup podataka je sljedeći:

$$\mathcal{D} = \{\mathbf{x}^{(i)}\}_{i=1}^8 = \{(-2, -2), (-2, -1), (-1, -2), (-1, -1), (1, 2), (3, 1), (3, 3), (5, 2)\}$$

Razmatramo dva modela: \mathcal{H}_1 i \mathcal{H}_2 . Oba modela koriste punu kovarijacijsku matricu, međutim kod modela \mathcal{H}_1 kovarijacijska matrica nije dijeljena, dok je kod modela \mathcal{H}_2 kovarijacijska matrica dijeljena. Za svaki model razmotrite ono grupiranje koje maksimizira log-izglednost na skupu \mathcal{D} . Neka je $p_j(\mathbf{x}^{(i)}|y = k)$ izglednost grupe $y = k$ za primjer $\mathbf{x}^{(i)}$ prema modelu \mathcal{H}_j . Oznake grupa su $y = 1$ i $y = 2$, te pretpostavite da je grupiranje takvo da vrijedi $\|\boldsymbol{\mu}_1\| > \|\boldsymbol{\mu}_2\|$. Što od sljedećega vrijedi?

- A $p_2(\mathbf{x}^{(1)}|y = 2) > p_1(\mathbf{x}^{(2)}|y = 2)$ C $p_2(\mathbf{x}^{(6)}|y = 1) < p_1(\mathbf{x}^{(7)}|y = 1)$
 B $p_2(\mathbf{x}^{(8)}|y = 1) < p_1(\mathbf{x}^{(5)}|y = 1)$ D $p_2(\mathbf{x}^{(4)}|y = 2) > p_1(\mathbf{x}^{(3)}|y = 2)$
- 15** (T) Za procjenu parametara modela GMM (središta grupa $\boldsymbol{\mu}_k$, kovarijacijske matrice Σ_k i koeficijenti mješavine π_k) tipično se koristi algoritam maksimizacije očekivanja (EM-algoritam). Prije pokretanja EM-algoritma, parametre je potrebno inicijalizirati. U praksi se za inicijalizaciju parametara $\boldsymbol{\mu}_k$ koristi algoritam K-sredina. **Koji je očekivani efekt uporabe algoritma K-sredina za inicijalizaciju EM-algoritma?**

- A Manja log-izglednost početnih i konačnih parametara te optimalan broj grupa K
 B Veća log-izglednost početnih i konačnih parametara te manje iteracija do konvergencije
 C Manja log-izglednost početnih parametara, ali veća log-izglednost konačnih parametara
 D Veća potpuna log-izglednost konačnih parametara i veće vrijednosti gustoća komponenti

- 16** (P) Skup neoznačenih primjera u dvodimenzijaskome ulaznom prostoru neka je sljedeći:

$$\mathcal{D} = \{\mathbf{x}^{(i)}\}_i = \{(1, 1), (1, 3), (1, 4), (3, 4)\}$$

Primjere grupiramo u $K = 2$ grupe algoritmom K-means++. Konačna vrijednost funkcije pogreške J bit će različita za različita pokretanja algoritma. Razmotrite sve moguće konačne vrijednosti funkcije J , tj. vrijednosti funkcije J nakon što se algoritam K-means++ zaustavi. **Koliko iznosi maksimalna moguća konačna vrijednost funkcije J ?**

- A 14/3 B 10/3 C 4 D 11/2
- 17** (T) Kod vrednovanja algoritma strojnog učenja važno je da vrednujemo model optimalne složenosti. Zbog toga označeni skup podataka dijelimo na tri disjunktne podskupa: skup za učenje, skup za provjeru i ispitni skup. Za odabir modela (tj. optimizaciju hiperparametara) koristimo skup za učenje i skup za provjeru, dok točnost optimalnog modela ispitujemo na ispitnome skupu. Zamislite da smo zaboravili upotrijebiti skup za provjeru: umjesto toga hiperparametre modela optimirali smo na skupu za učenje, a model smo potom ispitali na ispitnom skupu. **U odnosu na to da smo pravilno proveli vrednovanje algoritma, što možemo očekivati u ovom slučaju?**

- A Model će biti prenaučeni, ali imat će veću točnost na ispitnome skupu
 B Model će biti optimalne složenosti i imat će veću točnost na ispitnome skupu
 C Model će biti prenaučeni i imat će manju točnost na ispitnome skupu
 D Model će biti podnaučeni, ali imat će veću točnost na ispitnome skupu

- 18** (N) Algoritmom hijerarhijskog aglomerativnog grupiranja (HAC) grupiramo $N = 5$ primjera. Za grupiranje koristimo mjeru sličnosti, definiranu sljedećom matricom:

$$\begin{pmatrix} 1.0 & 0.2 & 0.8 & 0.2 & 0.4 \\ 0.2 & 1.0 & 0.3 & 0.3 & 0.7 \\ 0.8 & 0.3 & 1.0 & 0.6 & 0.5 \\ 0.2 & 0.3 & 0.6 & 1.0 & 0.4 \\ 0.4 & 0.7 & 0.5 & 0.4 & 1.0 \end{pmatrix}$$

Provedite grupiranje algoritmom HAC s potpunim povezivanjem. Pritom u svakoj iteraciji bilježite na kojoj razini sličnosti se odvija stapanje dviju grupa. **Koliko iznosi zbroj po svim razinama sličnosti na kojima se odvija stapanje grupa?**

- A 1.8 B 1.9 C 2.4 D 2.0

19 (T) Algoritam K-sredina iterativno smanjuje vrijednost funkcije pogreške J . Neovisno o broju grupa K , algoritam uvijek konvergira (završava s izvođenjem). Međutim, konačna vrijednost funkcije pogreške J može se razlikovati između dva pokretanja algoritma s istim brojem grupa K . **Zašto?**

- A Zbog razlike u početnim središtima μ_k
 B Zbog loše odabrane vrijednosti za broj grupa K
 C Zbog nelinearnosti granice između K grupa
 D Zbog izotropnosti kovarijacijskih matrica Σ_k

20 (N) Particijskim algoritmom grupiranja grupiramo $N = 1000$ primjera. Na temelju znanja o problemu zaključili smo da bi primjeri trebali formirati $K = 3$ grupe, pa smo s tim brojem grupa proveli grupiranje. Kako bismo evaluirali točnost grupiranja, slučajnim odabirom smo iz skupa primjera uzorkovali 10 primjera, ručno smo označili primjere iz tog uzorka, i zatim na tom uzorku računamo Randov indeks. Označavanje smo proveli tako da smo svakom primjeru iz uzorka dodijelili oznaku točne grupe. Oznake grupe dobivene algoritmom grupiranja y_{pred} i oznake točnih grupa y_{true} za svih deset primjera u uzorku su sljedeće:

i	1	2	3	4	5	6	7	8	9	10
$y_{pred}^{(i)}$	0	0	2	1	1	0	0	2	1	1
$y_{true}^{(i)}$	1	0	0	2	1	0	2	1	1	1

Koliko iznosi Randov indeks grupiranja izračunat na ovom uzorku?

- A 0.49 B 0.58 C 0.53 D 0.62

21 (N) Vrednujemo višeklasni klasifikator koji koristimo kao referentni model za vrednovanje drugih klasifikatora. Klasifikator nasumično dodjeljuje oznake za tri klase ($K = 3$), i to prema distribuciji oznaka na skupu za učenje. Skup za učenje sadrži 100 primjera sa 35, 60 i 5 primjera u prvoj, drugoj odnosno trećoj klasi. S druge strane, ispitni skup sadrži 50 primjera, od kojih je po 20 u prvoj i drugoj klasi, a 10 u trećoj klasi. **Koliko iznosi očekivana makro-F1 vrijednost nasumičnog klasifikatora na ispitnome skupu?**

- A 0.2085 B 0.2156 C 0.2989 D 0.3111

22 (P) Raspoložemo sa 750 označenih primjera. Na tom skupu treniramo i vrednujemo algoritam SVM, optimizirajući hiperparametre C i γ . Za vrednovanje koristimo ugniježđenu unakrsnu provjeru sa 5 preklopa u vanjskoj petlji i 5 preklopa u unutarnjoj petlji. To znači da za svaku kombinaciju vrijednosti hiperparametara C i γ treniramo pet modela. Ti modeli trenirani su na skupovima za učenje koji nisu disjunktni: svaki par treniranih modela dijele određeni broj primjera za učenje. Izračunajte koliko primjera za učenje dijele svaki par modela koje treniramo u unutarnjoj petlji ugniježđene unakrsne provjere. **Za koliko bi taj broj narastao kada bismo broj preklopa u unutarnjoj petlji povećali na 10?**

- A 60 B 144 C 75 D 120

Završni ispit iz Strojnog učenja 1 (ak. god. 2023./2024.)

– NEKORIGIRANA VERZIJA –

Ispit sadrži **22 pitanja** i ukupno nosi najviše 20 bodova (za 30% bodova na predmetu). Pitanja nose po 1 bod, a 1/3 boda oduzima se za pogrešan odgovor. Za maksimalan broj bodova dovoljno je točno riješiti **20 pitanja**, a višak bodova iznad 20 se zanemaruje. Trajanje ispita je **180 minuta**. Primjerak ispita morate predati zajedno sa svojim rješenjima.

Cjelina 4: Procjena parametara i Bayesov klasifikator (8 pitanja)

- 1** (N) Treniramo Bayesov klasifikator za odluku o dobroj destinaciji za Erasmus+ studijski boravak. Skup primjera za učenje, izgrađen na temelju iskustava prijatelja i prijatelja prijatelja, je sljedeći:

i	Država	Stipendija	Semestar	Studij	GovoriJezik	$y^{(i)}$
1	Njemačka	da	ljetni	dipl	da	1
2	Poljska	ne	zimski	preddipl	ne	1
3	Italija	da	ljetni	dipl	da	1
4	Njemačka	ne	zimski	preddipl	ne	0
5	Austrija	da	ljetni	dipl	da	1
6	Poljska	ne	zimski	dipl	ne	1
7	Austrija	da	zimski	dipl	ne	1
8	Njemačka	ne	zimski	dipl	ne	0

Očekujemo zavisnost između varijabli *Država* i *Stipendija*, pa koristimo polunaivan Bayesov klasifikator u kojemu su te dvije varijable združene. Procjene izglednosti klasa radimo Laplaceovim MAP-procjeniteljem. Zanima nas klasifikacija za $\mathbf{x} = (\text{Italija, da, zimski, preddipl, ne})$. **Koliko iznosi aposteriorna vjerojatnost $P(y = 1|\mathbf{x})$?**

- A 0.741 B 0.488 C 0.588 D 0.322

- 2** (T) Polunaivan Bayesov klasifikator može ostvariti veću klasifikacijsku točnost od naivnog Bayesovog klasifikatora u situacijama kada između značajki postoji zavisnost. Jedan način određivanja zavisnosti između značajki temelji se na izračunu Kullback-Leiblerove divergencije (KL-divergencije) između distribucija dviju varijabli. **Koji je princip uporabe KL-divergencije u izgradnji polunaivnog Bayesovog klasifikatora?**

- A Što je manja KL-divergencija između $P(x_1)$ i $P(x_2)$, to su varijable x_1 i x_2 više zavisne, pa je to veća korist od njihovog združivanja u jedan faktor
- B Što je veća KL-divergencija između $P(x_1)P(x_2)$ i $P(x_1, x_2)$, to su varijable x_1 i x_2 manje nezavisne, pa je to veća korist od njihovog združivanja u jedan faktor
- C Ako je KL-divergencija između $P(x_1)P(x_2)$ i $P(x_1, x_2)$ jednaka nuli, onda su varijable linearno zavisne i treba ih odvojiti u zasebne faktore
- D Ako je KL-divergencija između $P(x_1|x_2)$ i $P(x_2|x_1)$ vrlo mala, onda su varijable x_1 i x_2 vrlo zavisne i treba ih odvojiti u zasebne faktore

- 3** (T) Bayesov klasifikator temelji se na hipotezi *maximum a posteriori* (MAP). Za treniranje Bayesovog klasifikatora možemo koristiti procjenitelj MLE. **Koja je razlika između hipoteze MAP kod Bayesovog klasifikatora i procjenitelja MLE?**

- A Procjenitelj MLE primjer klasificira u klasu koja je za njega navjerojatnija, a hipoteza MAP tu odluku kombinira s apriornim znanjem
- B Procjenitelj MLE određuje apriornu vjerojatnost klase, a hipoteza MAP maksimizira aposterionu vjerojatnost parametara
- C Hipoteza MAP maksimizira aposterionu vjerojatnost parametara, a procjenitelj MLE određuje aposterionu vjerojatnost klase za zadani primjer
- D Hipoteza MAP određuje koju klasu odabrati za primjer, a procjenitelj MLE određuje koju vrijednost odabrati za parametar

- 4 (N) Na skupu označenih primjera u ulaznome prostoru dimenzije $n = 2$ treniramo Gaussov Bayesov klasifikator za klasifikaciju primjera u $K = 2$ klase, uz pretpostavku dijeljene i dijagonalne kovarijacijske matrice. Izglednost klase s oznakom $y = j$ definirana je multivarijantnom Gaussovom gustoćom vjerojatnosti:

$$p(\mathbf{x}|y = j) = \frac{1}{(2\pi)^{n/2} |\Sigma_j|^{1/2}} \exp \left\{ -\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu}_j)^T \Sigma_j^{-1} (\mathbf{x} - \boldsymbol{\mu}_j) \right\}$$

Model treniramo na skupu podataka od $N = 7$ primjera:

$$\mathcal{D} = \{(\mathbf{x}^{(i)}, y^{(i)})\}_i = \{((-4, -2), 0), ((0, 0), 0), ((4, 2), 0), ((3, -1), 1), ((4, -1), 1), ((4, 1), 1), ((5, 1), 1)\}$$

Procijenite parametre modela na ovom skupu primjera. Budući da je skup primjera malen, za procjenu kovarijacijske matrice koristite nepristran procjenitelj. Izlaz modela za klasu $y = j$ neka je zajednička gustoća vjerojatnosti, $h_j(\mathbf{x}) = \ln p(\mathbf{x}, y = j)$. **Koliko iznosi $h_0(\mathbf{x})$ za primjer $\mathbf{x} = (0, 0)$?**

- A -3.84 B -2.75 C -3.03 D -4.13

- 5 (P) Gaussov Bayesov klasifikator koristimo za klasifikaciju jednodimenzijskih podataka u tri klase. Procijenjene izglednosti klase su $p(x|y = 1) = \mathcal{N}(-10, 2)$, $p(x|y = 2) = \mathcal{N}(2, 2)$ i $p(x|y = 3) = \mathcal{N}(8, 2)$, a procijenjene apriorne vjerojatnosti klase su $P(y = 1) = P(y = 2) = 2/5$ i $P(y = 3) = 1/5$. Međutim, nakon što smo naučili ovaj model, zaključili smo da na ispitnom skupu postoji pomak u distribuciji podataka u odnosu na skup za učenje te da zbog toga model ne generalizira dobro. Zaključili smo da se ovo može ispraviti tako da se naučeni model malo izmijeni, i to tako da se varijanca izglednosti klase $y = 1$ postavi na 1 i da se apriorne vjerojatnosti klase ujednače, $P(y = 1) = P(y = 2) = P(y = 3) = 1/3$. Skicirajte gustoće zajedničke vjerojatnosti naučenog i izmijenjenog modela. Neka su h_1 i h_2 MAP-hipoteze prvog i drugog modela, te neka su a i b pozitivne konstante. Razmotrite segment ulaznog prostora za koji vrijedi $-10 \leq x \leq 10$. **Na kojim se dijelovima tog segmenta ulaznog prostora MAP-hipoteze prvog i drugog modela razlikuju?**

- A $[-4 - a, -4] \cup [5, 5 + b]$ B $[-4 - a, -4 + b]$ C $[-4 - a, 5 + b]$ D $[-4, -4 + a] \cup [5 - b, 5]$

- 6 (P) Gaussovim Bayesovim klasifikatorom rješavamo problem klasifikacije u $K = 10$ klasa sa $n = 100$ značajki. Prisjetite se da kod Gaussovog Bayesovog klasifikatora uvođenjem odgovarajućih pretpostavki na kovarijacijsku matricu Σ možemo utjecati na broj parametara modela a time onda i na složenost modela. Razmatramo tri modela s kovarijacijskim matricama u koje smo ugradili sljedeće pretpostavke:

\mathcal{H}_1 : Značajke imaju različite varijance, ali iste za sve klase, te nisu korelirane

\mathcal{H}_2 : Značajke nisu korelirane, imaju jednaku varijancu unutar svake klase, no različitu za svaku klasu

\mathcal{H}_3 : Između značajki postoje korelacije, ali se one ne razlikuju između klasa

Neka ‘ \supset ’ označava relaciju “složeniji od”, a neka ‘ $>$ ’ označava relaciju “ima više parametara od”. **Što možemo zaključiti o složenosti i broju parametara za gornja četiri modela?**

- A $\mathcal{H}_1 > \mathcal{H}_2 > \mathcal{H}_3$, $\mathcal{H}_1 \supset \mathcal{H}_2$ C $\mathcal{H}_3 > \mathcal{H}_2 > \mathcal{H}_1$, $\mathcal{H}_3 \supset \mathcal{H}_1 \supset \mathcal{H}_2$
 B $\mathcal{H}_3 > \mathcal{H}_1 > \mathcal{H}_2$, $\mathcal{H}_3 \supset \mathcal{H}_1$ D $\mathcal{H}_1 > \mathcal{H}_3 > \mathcal{H}_2$, $\mathcal{H}_1 \supset \mathcal{H}_2 \supset \mathcal{H}_3$

- 7 (P) Uz određene restrikcije na parametre Gaussovog Bayesovog klasifikatora, Gaussov Bayesov klasifikator i logistička regresija su generativno-diskriminativni par modela. U pravilu, logistička regresija imat će manje parametara od njoj odgovarajućeg modela Gaussovog Bayesovog klasifikatora. Razmotrite slučaj binarne klasifikacije u ulaznome prostoru dimenzije $n = 300$ pomoću modela logističke regresije i njoj odgovarajućeg modela Gaussovog Bayesovog klasifikatora. **Koliko će model Gaussovog Bayesovog klasifikatora imati više parametara od modela logističke regresije?**

- A 20300 B 40400 C 45450 D 90600

- 8 (N) Zadan je uzorak kontinuirane slučajne varijable, $\mathcal{D} = \{-10, 5, 6, 20\}$. Pretpostavljamo razdiobu $\mathcal{N}(\mu, \sigma^2)$, čija je gustoća vjerojatnosti:


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

Za procjenu parametra μ koristimo procjenitelj $\hat{\mu}_{\text{MLE}}$, a za procjenu parametra σ^2 procjenitelj $\hat{\sigma}_{\text{UB}}^2$, koji je nepristran procjenitelj izveden odgovarajućom korekcijom iz procjenitelja $\hat{\sigma}_{\text{MLE}}^2$. Izračunajte log-izglednost procijenjenih parametara na skupu \mathcal{D} , tj. $\ln \mathcal{L}(\hat{\mu}_{\text{MLE}}, \hat{\sigma}_{\text{UB}}^2 | \mathcal{D})$. **Koliko iznosi ta log-izglednost?**

- A -15.200 B -10.832 C -13.163 D -12.873

Cjelina 5: Probabilistički grafički modeli (5 pitanja)

- 9 (N) Na slici ispod prikazana je Bayesova mreža za problem prskalice za travu. Varijable su: C (oblačno/*cloudy*), S (prskalica/*sprinkler*), R (kiša/*rain*) i W (mokra trava/*wet grass*). Dane su i tablice uvjetnih vjerojatnosti.



C	$P(S = 1 C)$
0	0.5
1	0.4


C	$P(R = 1 C)$
0	0.2
1	0.8

S	R	$P(W = 1 S, R)$
0	0	0.0
0	1	0.9
1	0	0.1
1	1	0.99

Izračunajte aposteriornu vjerojatnost da radi prskalica ako trava nije mokra i oblačno je.

- A 0.069 B 0.223 C 0.309 D 0.144

- 10 (P) Na slici ispod prikazana je Bayesova mreža koja odgovara polunaivnom Bayesovom klasifikatoru. Pretpostavite da su značajke x_1 , x_2 i x_3 ternarne varijable te da je oznaka klase y također ternarna varijabla. Označimo ovaj model sa \mathcal{H}_2 . Model \mathcal{H}_2 može se pojednostaviti ako se ukloni brid između varijabli x_2 i x_3 . Označimo takav model sa \mathcal{H}_1 . S druge strane, od modela \mathcal{H}_2 može se napraviti još složeniji model tako da se doda brid između varijabli x_1 i x_2 . Označimo takav model sa \mathcal{H}_3 .



Razmotrite koliko parametara imaju modeli \mathcal{H}_1 , \mathcal{H}_2 i \mathcal{H}_3 . **Koliko model \mathcal{H}_2 ima više parametara od modela \mathcal{H}_1 , a koliko manje parametara od modela \mathcal{H}_3 ?**

- A 2 više, 4 manje B 12 više, 12 manje C 12 više, 8 manje D 8 više, 8 manje

- 11 (T) Probabilistički grafički modeli na sažet način prikazuju zajedničku distribuciju n slučajnih varijabli. Ta je distribucija prikazana usmjerenim grafom. Neka graf sadrži čvor označen sa x . **Čemu odgovara taj čvor?**
- A Distribuciji varijable x uvjetovane vrijednostima varijabli roditeljskih čvorova od x
- B Distribuciji varijable x uz opažene sve varijable koje varijabli x prethode u topološkom uređaju
- C Marginalnoj vjerojatnosti $P(x)$ ili marginalnoj gustoći vjerojatnosti $p(x)$
- D Zajedničkoj vjerojatnosti varijable x i varijabli roditeljskih čvorova od x

- 12 (P) Bayesova mreža ima pet varijabli, s topološkim uređajem v, w, x, y, z . Uz takav uređaj, u mreži vrijede sljedeće uvjetne nezavisnosti:

$$\{v, w\} \perp y | x \quad \{v, x\} \perp z | \{w, y\}$$

Primjenom algoritma d-odvajanja ispitujemo zavisnosti između parova varijabli. **Koje od sljedećih tvrdnji o nezavisnosti vrijede u ovoj Bayesovoj mreži?**

- A $v \perp z | w$ B $x \perp z | w$ C $w \perp y | z$ D $w \perp y | x$

- 13 (N) Razmotrite jednostavnu Bayesovu mrežu koja odgovara faktorizaciji $P(x, y, z, w) = P(z)P(w)P(y|z, w)P(x|y)$. Sve varijable su binarne. Vrijedi $P(z = 1) = 0.1$, $P(w = 1) = 0.2$, $P(x = 1|y = 0) = 0.2$ i $P(x = 1|y = 1) = 0.6$. Tablica uvjetne vjerojatnosti za čvor y je sljedeća:

z	w	$p(y = 1 z, w)$
0	0	0
0	1	0.4
1	0	0.2
1	1	0.7

Postupkom uzorkovanja s odbijanjem uzorkujemo iz aposteriorne distribucije $P(w|x = 0, z = 1)$. Uzorkovanje smo ponovili ukupno $N = 10000$ puta, od čega smo neke vektore morali odbaciti, pa je naš konačni uzorak manji od N . **U uzorku neodbačenih vektora, koliko je očekivano više vektora sa $w = 0$ od vektora sa $w = 1$?**

- A 472 B 944 C 596 D 348

Cjelina 6: Grupiranje i vrednovanje modela (9 pitanja)

- 14** (N) Particijskim algoritmom grupiranja grupiramo $N = 1000$ primjera. Na temelju znanja o problemu zaključili smo da bi primjeri trebali formirati $K = 3$ grupe, pa smo s tim brojem grupa proveli grupiranje. Kako bismo evaluirali točnost grupiranja, slučajnim odabirom smo iz skupa primjera uzorkovali 10 primjera, ručno smo označili primjere iz tog uzorka, i zatim na tom uzorku računamo Randov indeks. Označavanje smo proveli tako da smo svakom primjeru iz uzorka dodijelili oznaku točne grupe. Oznake grupe dobivene algoritmom grupiranja y_{pred} i oznake točnih grupa y_{true} za svih deset primjera u uzorku su sljedeće:

i	1	2	3	4	5	6	7	8	9	10
$y_{pred}^{(i)}$	0	0	2	1	1	0	0	2	1	1
$y_{true}^{(i)}$	1	0	0	2	1	0	2	1	1	1

Koliko iznosi Randov indeks grupiranja izračunat na ovom uzorku?

- A 0.58 B 0.62 C 0.53 D 0.49
- 15** (P) Podatke u dvodimenzijaskome ulaznom prostoru ($n = 2$) grupiramo u dvije grupe ($K = 2$) algoritmom Gaussove mješavine (GMM). Skup podataka je sljedeći:

$$\mathcal{D} = \{\mathbf{x}^{(i)}\}_{i=1}^8 = \{(-2, -2), (-2, -1), (-1, -2), (-1, -1), (1, 2), (3, 1), (3, 3), (5, 2)\}$$

Razmatramo dva modela: \mathcal{H}_1 i \mathcal{H}_2 . Oba modela koriste punu kovarijacijsku matricu, međutim kod modela \mathcal{H}_1 kovarijacijska matrica nije dijeljena, dok je kod modela \mathcal{H}_2 kovarijacijska matrica dijeljena. Za svaki model razmotrite ono grupiranje koje maksimizira log-izglednost na skupu \mathcal{D} . Neka je $p_j(\mathbf{x}^{(i)}|y = k)$ izglednost grupe $y = k$ za primjer $\mathbf{x}^{(i)}$ prema modelu \mathcal{H}_j . Oznake grupa su $y = 1$ i $y = 2$, te pretpostavite da je grupiranje takvo da vrijedi $\|\boldsymbol{\mu}_1\| > \|\boldsymbol{\mu}_2\|$. **Što od sljedećega vrijedi?**

- A $p_2(\mathbf{x}^{(4)}|y = 2) > p_1(\mathbf{x}^{(3)}|y = 2)$ C $p_2(\mathbf{x}^{(8)}|y = 1) < p_1(\mathbf{x}^{(5)}|y = 1)$
 B $p_2(\mathbf{x}^{(6)}|y = 1) < p_1(\mathbf{x}^{(7)}|y = 1)$ D $p_2(\mathbf{x}^{(1)}|y = 2) > p_1(\mathbf{x}^{(2)}|y = 2)$
- 16** (T) Za procjenu parametara modela GMM (središta grupa $\boldsymbol{\mu}_k$, kovarijacijske matrice Σ_k i koeficijenti mješavine π_k) tipično se koristi algoritam maksimizacije očekivanja (EM-algoritam). Prije pokretanja EM-algoritma, parametre je potrebno inicijalizirati. U praksi se za inicijalizaciju parametara $\boldsymbol{\mu}_k$ koristi algoritam K-sredina. **Koji je očekivani efekt uporabe algoritma K-sredina za inicijalizaciju EM-algoritma?**

- A Manja log-izglednost početnih parametara, ali veća log-izglednost konačnih parametara
 B Veća potpuna log-izglednost konačnih parametara i veće vrijednosti gustoća komponenti
 C Veća log-izglednost početnih i konačnih parametara te manje iteracija do konvergencije
 D Manja log-izglednost početnih i konačnih parametara te optimalan broj grupa K
- 17** (N) Algoritmom hijerarhijskog aglomerativnog grupiranja (HAC) grupiramo $N = 5$ primjera. Za grupiranje koristimo mjeru sličnosti, definiranu sljedećom matricom:

$$\begin{pmatrix} 1.0 & 0.2 & 0.8 & 0.2 & 0.4 \\ 0.2 & 1.0 & 0.3 & 0.3 & 0.7 \\ 0.8 & 0.3 & 1.0 & 0.6 & 0.5 \\ 0.2 & 0.3 & 0.6 & 1.0 & 0.4 \\ 0.4 & 0.7 & 0.5 & 0.4 & 1.0 \end{pmatrix}$$

Provedite grupiranje algoritmom HAC s potpunim povezivanjem. Pritom u svakoj iteraciji bilježite na kojoj razini sličnosti se odvija stapanje dviju grupa. **Koliko iznosi zbroj po svim razinama sličnosti na kojima se odvija stapanje grupa?**

- A 1.9 B 1.8 C 2.4 D 2.0
- 18** (P) Skup neoznačenih primjera u dvodimenzijaskome ulaznom prostoru neka je sljedeći:

$$\mathcal{D} = \{\mathbf{x}^{(i)}\}_i = \{(1, 1), (1, 3), (1, 4), (3, 4)\}$$

Primjere grupiramo u $K = 2$ grupe algoritmom K-means++. Konačna vrijednost funkcije pogreške J bit će različita za različita pokretanja algoritma. Razmotrite sve moguće konačne vrijednosti funkcije J , tj. vrijednosti funkcije J nakon što se algoritam K-means++ zaustavi. **Koliko iznosi maksimalna moguća konačna vrijednost funkcije J ?**

- A 4 B 10/3 C 14/3 D 11/2

19 (T) Algoritam K-sredina iterativno smanjuje vrijednost funkcije pogreške J . Neovisno o broju grupa K , algoritam uvijek konvergira (završava s izvođenjem). Međutim, konačna vrijednost funkcije pogreške J može se razlikovati između dva pokretanja algoritma s istim brojem grupa K . **Zašto?**

- A Zbog nelinearnosti granice između K grupa
 B Zbog razlike u početnim središtima μ_k
 C Zbog loše odabrane vrijednosti za broj grupa K
 D Zbog izotropnosti kovarijacijskih matrica Σ_k

20 (P) Raspoložemo sa 750 označenih primjera. Na tom skupu treniramo i vrednujemo algoritam SVM, optimizirajući hiperparametre C i γ . Za vrednovanje koristimo ugniježđenu unakrsnu provjeru sa 5 preklopa u vanjskoj petlji i 5 preklopa u unutarnjoj petlji. To znači da za svaku kombinaciju vrijednosti hiperparametara C i γ treniramo pet modela. Ti modeli trenirani su na skupovima za učenje koji nisu disjunktni: svaki par treniranih modela dijele određeni broj primjera za učenje. Izračunajte koliko primjera za učenje dijele svaki par modela koje treniramo u unutarnjoj petlji ugniježđene unakrsne provjere. **Za koliko bi taj broj narastao kada bismo broj preklopa u unutarnjoj petlji povećali na 10?**

- A 75 B 120 C 60 D 144

21 (N) Vrednujemo višeklasni klasifikator koji koristimo kao referentni model za vrednovanje drugih klasifikatora. Klasifikator nasumično dodjeljuje oznake za tri klase ($K = 3$), i to prema distribuciji oznaka na skupu za učenje. Skup za učenje sadrži 100 primjera sa 35, 60 i 5 primjera u prvoj, drugoj odnosno trećoj klasi. S druge strane, ispitni skup sadrži 50 primjera, od kojih je po 20 u prvoj i drugoj klasi, a 10 u trećoj klasi. **Koliko iznosi očekivana makro-F1 vrijednost nasumičnog klasifikatora na ispitnome skupu?**

- A 0.3111 B 0.2085 C 0.2989 D 0.2156

22 (T) Kod vrednovanja algoritma strojnog učenja važno je da vrednujemo model optimalne složenosti. Zbog toga označeni skup podataka dijelimo na tri disjunktna podskupa: skup za učenje, skup za provjeru i ispitni skup. Za odabir modela (tj. optimizaciju hiperparametara) koristimo skup za učenje i skup za provjeru, dok točnost optimalnog modela ispitujemo na ispitnome skupu. Zamislite da smo zaboravili upotrijebiti skup za provjeru: umjesto toga hiperparametre modela optimirali smo na skupu za učenje, a model smo potom ispitali na ispitnom skupu. **U odnosu na to da smo pravilno proveli vrednovanje algoritma, što možemo očekivati u ovom slučaju?**

- A Model će biti podnaučen, ali imat će veću točnost na ispitnome skupu
 B Model će biti prenaučeni, ali imat će veću točnost na ispitnome skupu
 C Model će biti prenaučeni i imat će manju točnost na ispitnome skupu
 D Model će biti optimalne složenosti i imat će veću točnost na ispitnome skupu

Završni ispit iz Strojnog učenja 1 (ak. god. 2023./2024.)

– NEKORIGIRANA VERZIJA –

Ispit sadrži 22 pitanja i ukupno nosi najviše 20 bodova (za 30% bodova na predmetu). Pitanja nose po 1 bod, a 1/3 boda oduzima se za pogrešan odgovor. Za maksimalan broj bodova dovoljno je točno riješiti 20 pitanja, a višak bodova iznad 20 se zanemaruje. Trajanje ispita je 180 minuta. Primjerak ispita morate predati zajedno sa svojim rješenjima.

Cjelina 4: Procjena parametara i Bayesov klasifikator (8 pitanja)

- 1 (N) Zadan je uzorak kontinuirane slučajne varijable, $\mathcal{D} = \{10, 5, 6, 20\}$. Pretpostavljamo razdiobu $\mathcal{N}(\mu, \sigma^2)$, čija je gustoća vjerojatnosti:

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

Za procjenu parametra μ koristimo procjenitelj $\hat{\mu}_{\text{MLE}}$, a za procjenu parametra σ^2 procjenitelj $\hat{\sigma}_{\text{UB}}^2$, koji je nepristran procjenitelj izveden odgovarajućom korekcijom iz procjenitelja $\hat{\sigma}_{\text{MLE}}^2$. Izračunajte log-izglednost procijenjenih parametara na skupu \mathcal{D} , tj. $\ln \mathcal{L}(\hat{\mu}_{\text{MLE}}, \hat{\sigma}_{\text{UB}}^2 | \mathcal{D})$. **Koliko iznosi ta log-izglednost?**

- A -13.163 B -12.873 C -10.832 D -15.200

- 2 (T) Polunaivan Bayesov klasifikator može ostvariti veću klasifikacijsku točnost od naivnog Bayesovog klasifikatora u situacijama kada između značajki postoji zavisnost. Jedan način određivanja zavisnosti između značajki temelji se na izračunu Kullback-Leiblerove divergencije (KL-divergencije) između distribucija dviju varijabli. **Koji je princip uporabe KL-divergencije u izgradnji polunaivnog Bayesovog klasifikatora?**

- A Ako je KL-divergencija između $P(x_1)P(x_2)$ i $P(x_1, x_2)$ jednaka nuli, onda su varijable linearno zavisne i treba ih odvojiti u zasebne faktore
- B Što je veća KL-divergencija između $P(x_1)P(x_2)$ i $P(x_1, x_2)$, to su varijable x_1 i x_2 manje nezavisne, pa je to veća korist od njihovog združivanja u jedan faktor
- C Ako je KL-divergencija između $P(x_1|x_2)$ i $P(x_2|x_1)$ vrlo velika, onda su varijable x_1 i x_2 vrlo zavisne i treba ih združiti u jedan faktor
- D Što je manja KL-divergencija između $P(x_1)$ i $P(x_2)$, to su varijable x_1 i x_2 više zavisne, pa je to veća korist od njihovog združivanja u jedan faktor

- 3 (P) Gaussovim Bayesovim klasifikatorom rješavamo problem klasifikacije u $K = 10$ klasa sa $n = 100$ značajki. Prisjetite se da kod Gaussovog Bayesovog klasifikatora uvođenjem odgovarajućih pretpostavki na kovarijacijsku matricu Σ možemo utjecati na broj parametara modela a time onda i na složenost modela. Razmatramo tri modela s kovarijacijskim matricama u koje smo ugradili sljedeće pretpostavke:

\mathcal{H}_1 : Značajke imaju različite varijance, ali iste za sve klase, te nisu korelirane

\mathcal{H}_2 : Značajke nisu korelirane, imaju jednaku varijancu unutar svake klase, no različitu za svaku klasu

\mathcal{H}_3 : Između značajki postoje korelacije, ali se one ne razlikuju između klasa

Neka ‘ \supset ’ označava relaciju “složeniji od”, a neka ‘ $>$ ’ označava relaciju “ima više parametara od”. **Što možemo zaključiti o složenosti i broju parametara za gornja četiri modela?**

- A $\mathcal{H}_1 > \mathcal{H}_2 > \mathcal{H}_3$, $\mathcal{H}_1 \supset \mathcal{H}_2$ C $\mathcal{H}_1 > \mathcal{H}_3 > \mathcal{H}_2$, $\mathcal{H}_1 \supset \mathcal{H}_2 \supset \mathcal{H}_3$
- B $\mathcal{H}_3 > \mathcal{H}_1 > \mathcal{H}_2$, $\mathcal{H}_3 \supset \mathcal{H}_1$ D $\mathcal{H}_3 > \mathcal{H}_2 > \mathcal{H}_1$, $\mathcal{H}_3 \supset \mathcal{H}_1 \supset \mathcal{H}_2$

- 4 (P) Gaussov Bayesov klasifikator koristimo za klasifikaciju jednodimenzijskih podataka u tri klase. Procijenjene izglednosti klasa su $p(x|y=1) = \mathcal{N}(-10, 2)$, $p(x|y=2) = \mathcal{N}(2, 2)$ i $p(x|y=3) = \mathcal{N}(8, 2)$, a procijenjene apriorne vjerojatnosti klasa su $P(y=1) = P(y=2) = 2/5$ i $P(y=3) = 1/5$. Međutim, nakon što smo naučili ovaj model, zaključili smo da na ispitnom skupu postoji pomak u distribuciji podataka u odnosu na skup za učenje te da zbog toga model ne generalizira dobro. Zaključili smo da se ovo može ispraviti tako da se naučeni model malo

izmijeni, i to tako da se varijanca izglednosti klase $y = 1$ postavi na 1 i da se apriorne vjerojatnosti klasa ujednače, $P(y = 1) = P(y = 2) = P(y = 3) = 1/3$. Skicirajte gustoće zajedničke vjerojatnosti naučenog i izmijenjenog modela. Neka su h_1 i h_2 MAP-hipoteze prvog i drugog modela, te neka su a i b pozitivne konstante. Razmotrite segment ulaznog prostora za koji vrijedi $-10 \leq x \leq 10$. **Na kojim se dijelovima tog segmenta ulaznog prostora MAP-hipoteze prvog i drugog modela razlikuju?**

- A $[-4 - a, 5 + b]$ B $[-4 - a, -4] \cup [5, 5 + b]$ C $[-4, -4 + a] \cup [5 - b, 5]$ D $[-4 - a, -4 + b]$

5 (T) Bayesov klasifikator temelji se na hipotezi *maximum a posteriori* (MAP). Za treniranje Bayesovog klasifikatora možemo koristiti procjenitelj MLE. **Koja je razlika između hipoteze MAP kod Bayesovog klasifikatora i procjenitelja MLE?**

- A Hipoteza MAP maksimizira aposterionu vjerojatnost parametara, a procjenitelj MLE određuje aposterionu vjerojatnost klase za zadani primjer
- B Procjenitelj MLE određuje apriornu vjerojatnost klase, a hipoteza MAP maksimizira aposterionu vjerojatnost parametara
- C Procjenitelj MLE primjer klasificira u klasu koja je za njega navjerojatnija, a hipoteza MAP tu odluku kombinira s apriornim znanjem
- D Hipoteza MAP određuje koju klasu odabrati za primjer, a procjenitelj MLE određuje koju vrijednost odabrati za parametar

6 (N) Treniramo Bayesov klasifikator za odluku o dobroj destinaciji za Erasmus+ studijski boravak. Skup primjera za učenje, izgrađen na temelju iskustava prijatelja i prijatelja prijatelja, je sljedeći:

i	Država	Stipendija	Semestar	Studij	GovoriJezik	$y^{(i)}$
1	Njemačka	da	ljetni	dipl	da	1
2	Poljska	ne	zimski	preddipl	ne	1
3	Italija	da	ljetni	dipl	da	1
4	Njemačka	ne	zimski	preddipl	ne	0
5	Austrija	da	ljetni	dipl	da	1
6	Poljska	ne	zimski	dipl	ne	1
7	Austrija	da	zimski	dipl	ne	1
8	Njemačka	ne	zimski	dipl	ne	0

Očekujemo zavisnost između varijabli *Država* i *Stipendija*, pa koristimo polunaivan Bayesov klasifikator u kojemu su te dvije varijable združene. Procjene izglednosti klasa radimo Laplaceovim MAP-procjeniteljem. Zanima nas klasifikacija za $\mathbf{x} = (\text{Italija}, \text{da}, \text{zimski}, \text{dipl}, \text{ne})$. **Koliko iznosi aposteriorna vjerojatnost $P(y = 1|\mathbf{x})$?**

- A 0.488 B 0.322 C 0.741 D 0.588

7 (P) Uz određene restrikcije na parametre Gaussovog Bayesovog klasifikatora, Gaussov Bayesov klasifikator i logistička regresija su generativno-diskriminativni par modela. U pravilu, logistička regresija imaće manje parametara od njoj odgovarajućeg modela Gaussovog Bayesovog klasifikatora. Razmotrite slučaj binarne klasifikacije u ulaznome prostoru dimenzije $n = 200$ pomoću modela logističke regresije i njoj odgovarajućeg modela Gaussovog Bayesovog klasifikatora. **Koliko će model Gaussovog Bayesovog klasifikatora imati više parametara od modela logističke regresije?**

- A 90600 B 40400 C 20300 D 45450

8 (N) Na skupu označenih primjera u ulaznome prostoru dimenzije $n = 2$ treniramo Gaussov Bayesov klasifikator za klasifikaciju primjera u $K = 2$ klase, uz pretpostavku dijeljene i dijagonalne kovarijacijske matrice. Izglednost klase s oznakom $y = j$ definirana je multivarijantnom Gaussovom gustoćom vjerojatnosti:

$$p(\mathbf{x}|y = j) = \frac{1}{(2\pi)^{n/2} |\Sigma_j|^{1/2}} \exp \left\{ -\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu}_j)^T \Sigma_j^{-1} (\mathbf{x} - \boldsymbol{\mu}_j) \right\}$$

Model treniramo na skupu podataka od $N = 7$ primjera:


$$\mathcal{D} = \{(\mathbf{x}^{(i)}, y^{(i)})\}_i = \{((-4, -2), 0), ((0, 0), 0), ((4, 2), 0), ((3, -1), 1), ((4, -1), 1), ((4, 1), 1), ((5, 1), 1)\}$$

Procijenite parametre modela na ovom skupu primjera. Budući da je skup primjera malen, za procjenu kovarijacijske matrice koristite nepristran procjenitelj. Izlaz modela za klasu $y = j$ neka je zajednička gustoća vjerojatnosti, $h_j(\mathbf{x}) = \ln p(\mathbf{x}, y = j)$. **Koliko iznosi $h_1(\mathbf{x})$ za primjer $\mathbf{x} = (4, 0)$?**

- A -2.75 B -3.03 C -4.13 D -3.84

Cjelina 5: Probabilistički grafički modeli (5 pitanja)

- 9 (N) Na slici ispod prikazana je Bayesova mreža za problem prskalice za travu. Varijable su: C (oblačno/*cloudy*), S (prskalica/*sprinkler*), R (kiša/*rain*) i W (mokra trava/*wet grass*). Dane su i tablice uvjetnih vjerojatnosti.



C	$P(S = 1 C)$
0	0.5
1	0.4

C	$P(R = 1 C)$
0	0.2
1	0.8

S	R	$P(W = 1 S, R)$
0	0	0.0
0	1	0.9
1	0	0.1
1	1	0.99

Izračunajte aposteriornu vjerojatnost da radi prskalica ako trava nije mokra i oblačno je.

- A 0.144 B 0.223 C 0.069 D 0.309

- 10 (P) Bayesova mreža ima pet varijabli, s topološkim uređajem v, w, x, y, z . Uz takav uređaj, u mreži vrijede sljedeće uvjetne nezavisnosti:

$$\{v, w\} \perp y | x \quad \{v, x\} \perp z | \{w, y\}$$


Primjenom algoritma d-odvajanja ispitujemo zavisnosti između parova varijabli. **Koje od sljedećih tvrdnji o nezavisnosti vrijede u ovoj Bayesovoj mreži?**

- A $v \perp z | y$ B $w \perp y | z$ C $w \perp y | x$ D $v \perp y | z$

- 11 (T) Probabilistički grafički modeli na sažet način prikazuju zajedničku distribuciju n slučajnih varijabli. Ta je distribucija prikazana usmjerenim grafom. Neka graf sadrži čvor označen sa x . **Čemu odgovara taj čvor?**

- A Distribuciji varijable x uz opažene sve varijable koje varijabli x prethode u topološkom uređaju
 B Distribuciji varijable x uvjetovane vrijednostima varijabli roditeljskih čvorova od x
 C Marginalnoj vjerojatnosti $P(x)$ ili marginalnoj gustoći vjerojatnosti $p(x)$
 D Zajedničkoj vjerojatnosti varijable x i varijabli roditeljskih čvorova od x

- 12 (P) Na slici ispod prikazana je Bayesova mreža koja odgovara polunaivnom Bayesovom klasifikatoru. Pretpostavite da su značajke x_1, x_2 i x_3 ternarne varijable te da je oznaka klase y također ternarna varijabla. Označimo ovaj model sa \mathcal{H}_2 . Model \mathcal{H}_2 može se pojednostaviti ako se ukloni brid između varijabli x_2 i x_3 . Označimo takav model sa \mathcal{H}_1 . S druge strane, od modela \mathcal{H}_2 može se napraviti još složeniji model tako da se doda brid između varijabli x_1 i x_2 . Označimo takav model sa \mathcal{H}_3 .



Razmotrite koliko parametara imaju modeli $\mathcal{H}_1, \mathcal{H}_2$ i \mathcal{H}_3 . **Koliko model \mathcal{H}_2 ima više parametara od modela \mathcal{H}_1 , a koliko manje parametara od modela \mathcal{H}_3 ?**

- A 12 više, 8 manje B 8 više, 8 manje C 2 više, 4 manje D 12 više, 12 manje

- 13 (N) Razmotrite jednostavnu Bayesovu mrežu koja odgovara faktorizaciji $P(x, y, z, w) = P(z)P(w)P(y|z, w)P(x|y)$. Sve varijable su binarne. Vrijedi $P(z = 1) = 0.1$, $P(w = 1) = 0.2$, $P(x = 1|y = 0) = 0.2$ i $P(x = 1|y = 1) = 0.6$. Tablica uvjetne vjerojatnosti za čvor y je sljedeća:

z	w	$p(y = 1 z, w)$
0	0	0
0	1	0.4
1	0	0.2
1	1	0.7

Postupkom uzorkovanja s odbijanjem uzorkujemo iz aposteriorne distribucije $P(w|x = 0, z = 1)$. Uzorkovanje smo ponovili ukupno $N = 10000$ puta, od čega smo neke vektore morali odbaciti, pa je naš konačni uzorak manji od N . **U uzorku neodbačenih vektora, koliko je očekivano više vektora sa $w = 0$ od vektora sa $w = 1$?**

- A 596 B 944 C 472 D 348

Cjelina 6: Grupiranje i vrednovanje modela (9 pitanja)

- 14 (N) Particijskim algoritmom grupiranja grupiramo $N = 1000$ primjera. Na temelju znanja o problemu zaključili smo da bi primjeri trebali formirati $K = 3$ grupe, pa smo s tim brojem grupa proveli grupiranje. Kako bismo evaluirali točnost grupiranja, slučajnim odabirom smo iz skupa primjera uzorkovali 10 primjera, ručno smo označili primjere iz tog uzorka, i zatim na tom uzorku računamo Randov indeks. Označavanje smo proveli tako da smo svakom primjeru iz uzorka dodijelili oznaku točne grupe. Oznake grupe dobivene algoritmom grupiranja y_{pred} i oznake točnih grupa y_{true} za svih deset primjera u uzorku su sljedeće:

i	1	2	3	4	5	6	7	8	9	10
$y_{pred}^{(i)}$	0	1	2	1	1	0	0	2	1	1
$y_{true}^{(i)}$	1	0	0	2	1	0	2	1	0	1

Koliko iznosi Randov indeks grupiranja izračunat na ovom uzorku?

- A 0.49 B 0.58 C 0.62 D 0.53
- 15 (P) Skup neoznačenih primjera u dvodimenzijaskome ulaznom prostoru neka je sljedeći:

$$\mathcal{D} = \{\mathbf{x}^{(i)}\}_i = \{(1, 1), (1, 3), (1, 4), (3, 4)\}$$

Primjere grupiramo u $K = 2$ grupe algoritmom K-means++. Konačna vrijednost funkcije pogreške J bit će različita za različita pokretanja algoritma. Razmotrite sve moguće konačne vrijednosti funkcije J , tj. vrijednosti funkcije J nakon što se algoritam K-means++ zaustavi. **Koliko iznosi maksimalna moguća konačna vrijednost funkcije J ?**

- A 14/3 B 4 C 11/2 D 10/3
- 16 (T) Kod vrednovanja algoritma strojnog učenja važno je da vrednujemo model optimalne složenosti. Zbog toga označeni skup podataka dijelimo na tri disjunktne podskupa: skup za učenje, skup za provjeru i ispitni skup. Za odabir modela (tj. optimizaciju hiperparametara) koristimo skup za učenje i skup za provjeru, dok točnost optimalnog modela ispitujemo na ispitnome skupu. Zamislite da smo zaboravili upotrijebiti skup za provjeru: umjesto toga hiperparametre modela optimirali smo na skupu za učenje, a model smo potom ispitali na ispitnom skupu. **U odnosu na to da smo pravilno proveli vrednovanje algoritma, što možemo očekivati u ovom slučaju?**

- A Model će biti prenaučen, ali imat će veću točnost na ispitnome skupu
- B Model će biti prenaučen i imat će manju točnost na ispitnome skupu
- C Model će biti podnaučen, ali imat će veću točnost na ispitnome skupu
- D Model će biti optimalne složenosti i imat će veću točnost na ispitnome skupu

- 17 (T) Za procjenu parametara modela GMM (središta grupa μ_k , kovarijacijske matrice Σ_k i koeficijenti mješavine π_k) tipično se koristi algoritam maksimizacije očekivanja (EM-algoritam). Prije pokretanja EM-algoritma, parametre je potrebno inicijalizirati. U praksi se za inicijalizaciju parametara μ_k koristi algoritam K-sredina. **Koji je očekivani efekt uporabe algoritma K-sredina za inicijalizaciju EM-algoritma?**

- A Veća potpuna log-izglednost konačnih parametara i veće vrijednosti gustoća komponenti
- B Manja log-izglednost početnih parametara, ali veća log-izglednost konačnih parametara
- C Veća log-izglednost početnih i konačnih parametara te manje iteracija do konvergencije
- D Manja log-izglednost početnih i konačnih parametara te optimalan broj grupa K

- 18 (P) Raspoložemo sa 750 označenih primjera. Na tom skupu treniramo i vrednujemo algoritam SVM, optimizirajući hiperparametre C i γ . Za vrednovanje koristimo ugniježdenu unakrsnu provjeru sa 5 preklopa u vanjskoj petlji i 5 preklopa u unutarnjoj petlji. To znači da za svaku kombinaciju vrijednosti hiperparametara C i γ treniramo pet modela. Ti modeli trenirani su na skupovima za učenje koji nisu disjunktne: svaki par treniranih modela dijele određeni broj primjera za učenje. Izračunajte koliko primjera za učenje dijele svaki par modela koje treniramo u unutarnjoj petlji ugniježdene unakrsne provjere. **Za koliko bi taj broj narastao kada bismo broj preklopa u unutarnjoj petlji povećali na 10?**

- A 60 B 120 C 75 D 144

- 19 (N) Algoritmom hijerarhijskog aglomerativnog grupiranja (HAC) grupiramo $N = 5$ primjera. Za grupiranje koristimo mjeru sličnosti, definiranu sljedećom matricom:

$$\begin{pmatrix} 1.0 & 0.2 & 0.8 & 0.2 & 0.4 \\ 0.2 & 1.0 & 0.3 & 0.3 & 0.7 \\ 0.8 & 0.3 & 1.0 & 0.6 & 0.5 \\ 0.2 & 0.3 & 0.6 & 1.0 & 0.4 \\ 0.4 & 0.7 & 0.5 & 0.4 & 1.0 \end{pmatrix}$$

Provedite grupiranje algoritmom HAC s potpunim povezivanjem. Pritom u svakoj iteraciji bilježite na kojoj razini sličnosti se odvija stapanje dviju grupa. **Koliko iznosi zbroj po svim razinama sličnosti na kojima se odvija stapanje grupa?**

- A 2.0 B 1.8 C 2.4 D 1.9

- 20 (T) Algoritam K-sredina iterativno smanjuje vrijednost funkcije pogreške J . Neovisno o broju grupa K , algoritam uvijek konvergira (završava s izvođenjem). Međutim, konačna vrijednost funkcije pogreške J može se razlikovati između dva pokretanja algoritma s istim brojem grupa K . **Zašto?**

- A Zbog nelinearnosti granice između K grupa
 B Zbog izotropnosti kovarijacijskih matrica Σ_k
 C Zbog razlike u početnim središtima μ_k
 D Zbog loše odabrane vrijednosti za broj grupa K

- 21 (P) Podatke u dvodimenzijaskome ulaznom prostoru ($n = 2$) grupiramo u dvije grupe ($K = 2$) algoritmom Gaussove mješavine (GMM). Skup podataka je sljedeći:

$$\mathcal{D} = \{\mathbf{x}^{(i)}\}_{i=1}^8 = \{(-2, -2), (-2, -1), (-1, -2), (-1, -1), (1, 2), (3, 1), (3, 3), (5, 2)\}$$

Razmatramo dva modela: \mathcal{H}_1 i \mathcal{H}_2 . Oba modela koriste punu kovarijacijsku matricu, međutim kod modela \mathcal{H}_1 kovarijacijska matrica nije dijeljena, dok je kod modela \mathcal{H}_2 kovarijacijska matrica dijeljena. Za svaki model razmotrite ono grupiranje koje maksimizira log-izglednost na skupu \mathcal{D} . Neka je $p_j(\mathbf{x}^{(i)}|y = k)$ izglednost grupe $y = k$ za primjer $\mathbf{x}^{(i)}$ prema modelu \mathcal{H}_j . Oznake grupa su $y = 1$ i $y = 2$, te pretpostavite da je grupiranje takvo da vrijedi $\|\mu_1\| > \|\mu_2\|$. **Što od sljedećega vrijedi?**

- A $p_2(\mathbf{x}^{(1)}|y = 2) > p_1(\mathbf{x}^{(2)}|y = 2)$ C $p_2(\mathbf{x}^{(8)}|y = 1) < p_1(\mathbf{x}^{(5)}|y = 1)$
 B $p_2(\mathbf{x}^{(4)}|y = 2) > p_1(\mathbf{x}^{(3)}|y = 2)$ D $p_2(\mathbf{x}^{(6)}|y = 1) < p_1(\mathbf{x}^{(7)}|y = 1)$

- 22 (N) Vrednujemo višeklasni klasifikator koji koristimo kao referentni model za vrednovanje drugih klasifikatora. Klasifikator nasumično dodjeljuje oznake za tri klase ($K = 3$), i to prema distribuciji oznaka na skupu za učenje. Skup za učenje sadrži 100 primjera sa 60, 35 i 5 primjera u prvoj, drugoj odnosno trećoj klasi. S druge strane, ispitni skup sadrži 50 primjera, od kojih je po 10 u prvoj i drugoj klasi, a 30 u trećoj klasi. **Koliko iznosi očekivana makro-F1 vrijednost nasumičnog klasifikatora na ispitnome skupu?**

- A 0.3111 B 0.2989 C 0.2085 D 0.2156

Završni ispit iz Strojnog učenja 1 (ak. god. 2023./2024.)

– NEKORIGIRANA VERZIJA –

Ispit sadrži 22 pitanja i ukupno nosi najviše 20 bodova (za 30% bodova na predmetu). Pitanja nose po 1 bod, a 1/3 boda oduzima se za pogrešan odgovor. Za maksimalan broj bodova dovoljno je točno riješiti 20 pitanja, a višak bodova iznad 20 se zanemaruje. Trajanje ispita je 180 minuta. Primjerak ispita morate predati zajedno sa svojim rješenjima.

Cjelina 4: Procjena parametara i Bayesov klasifikator (8 pitanja)

- 1 (N) Zadan je uzorak kontinuirane slučajne varijable, $\mathcal{D} = \{10, 5, 6, 20\}$. Pretpostavljamo razdiobu $\mathcal{N}(\mu, \sigma^2)$, čija je gustoća vjerojatnosti:

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

Za procjenu parametra μ koristimo procjenitelj $\hat{\mu}_{\text{MLE}}$, a za procjenu parametra σ^2 procjenitelj $\hat{\sigma}_{\text{UB}}^2$, koji je nepristran procjenitelj izveden odgovarajućom korekcijom iz procjenitelja $\hat{\sigma}_{\text{MLE}}^2$. Izračunajte log-izglednost procijenjenih parametara na skupu \mathcal{D} , tj. $\ln \mathcal{L}(\hat{\mu}_{\text{MLE}}, \hat{\sigma}_{\text{UB}}^2 | \mathcal{D})$. **Koliko iznosi ta log-izglednost?**

- A -15.200 B -13.163 C -12.873 D -10.832

- 2 (N) Treniramo Bayesov klasifikator za odluku o dobroj destinaciji za Erasmus+ studijski boravak. Skup primjera za učenje, izgrađen na temelju iskustava prijatelja i prijatelja prijatelja, je sljedeći:

i	Država	Stipendija	Semestar	Studij	GovoriJezik	$y^{(i)}$
1	Njemačka	da	ljetni	dipl	da	1
2	Poljska	ne	zimski	preddipl	ne	1
3	Italija	da	ljetni	dipl	da	1
4	Njemačka	ne	zimski	preddipl	ne	0
5	Austrija	da	ljetni	dipl	da	1
6	Poljska	ne	zimski	dipl	ne	1
7	Austrija	da	zimski	dipl	ne	1
8	Njemačka	ne	zimski	dipl	ne	0

Očekujemo zavisnost između varijabli *Država* i *Stipendija*, pa koristimo polunaivan Bayesov klasifikator u kojemu su te dvije varijable združene. Procjene izglednosti klasa radimo Laplaceovim MAP-procjeniteljem. Zanima nas klasifikacija za $\mathbf{x} = (\text{Italija, da, zimski, preddipl, ne})$. **Koliko iznosi aposteriorna vjerojatnost $P(y = 1 | \mathbf{x})$?**

- A 0.322 B 0.741 C 0.588 D 0.488

- 3 (T) Bayesov klasifikator temelji se na hipotezi *maximum a posteriori* (MAP). Za treniranje Bayesovog klasifikatora možemo koristiti procjenitelj MLE. **Koja je razlika između hipoteze MAP kod Bayesovog klasifikatora i procjenitelja MLE?**

- A Hipoteza MAP maksimizira aposterionu vjerojatnost parametara, a procjenitelj MLE određuje aposterionu vjerojatnost klase za zadani primjer
- B Procjenitelj MLE primjer klasificira u klasu koja je za njega navjerojatnija, a hipoteza MAP tu odluku kombinira s apriornim znanjem
- C Hipoteza MAP određuje koju klasu odabrati za primjer, a procjenitelj MLE određuje koju vrijednost odabrati za parametar
- D Procjenitelj MLE određuje apriornu vjerojatnost klase, a hipoteza MAP maksimizira aposterionu vjerojatnost parametara

- 4 (N) Na skupu označenih primjera u ulaznome prostoru dimenzije $n = 2$ treniramo Gaussov Bayesov klasifikator za klasifikaciju primjera u $K = 2$ klase, uz pretpostavku dijeljene i dijagonalne kovarijacijske matrice. Izglednost klase s oznakom $y = j$ definirana je multivarijantnom Gaussovom gustoćom vjerojatnosti:

$$p(\mathbf{x}|y = j) = \frac{1}{(2\pi)^{n/2} |\Sigma_j|^{1/2}} \exp \left\{ -\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu}_j)^T \Sigma_j^{-1} (\mathbf{x} - \boldsymbol{\mu}_j) \right\}$$

Model treniramo na skupu podataka od $N = 7$ primjera:

$$\mathcal{D} = \{(\mathbf{x}^{(i)}, y^{(i)})\}_i = \{((-4, -2), 0), ((0, 0), 0), ((4, 2), 0), ((3, -1), 1), ((4, -1), 1), ((4, 1), 1), ((5, 1), 1)\}$$

Procijenite parametre modela na ovom skupu primjera. Budući da je skup primjera malen, za procjenu kovarijacijske matrice koristite nepristran procjenitelj. Izlaz modela za klasu $y = j$ neka je zajednička gustoća vjerojatnosti, $h_j(\mathbf{x}) = \ln p(\mathbf{x}, y = j)$. **Koliko iznosi $h_1(\mathbf{x})$ za primjer $\mathbf{x} = (4, 0)$?**

- A -3.03 B -3.84 C -2.75 D -4.13

- 5 (P) Uz određene restrikcije na parametre Gaussovog Bayesovog klasifikatora, Gaussov Bayesov klasifikator i logistička regresija su generativno-diskriminativni par modela. U pravilu, logistička regresija imaće manje parametara od njoj odgovarajućeg modela Gaussovog Bayesovog klasifikatora. Razmotrite slučaj binarne klasifikacije u ulaznome prostoru dimenzije $n = 200$ pomoću modela logističke regresije i njoj odgovarajućeg modela Gaussovog Bayesovog klasifikatora. **Koliko će model Gaussovog Bayesovog klasifikatora imati više parametara od modela logističke regresije?**

- A 20300 B 40400 C 90600 D 45450

- 6 (P) Gaussov Bayesov klasifikator koristimo za klasifikaciju jednodimenzijskih podataka u tri klase. Procijenjene izglednosti klase su $p(x|y = 1) = \mathcal{N}(-10, 2)$, $p(x|y = 2) = \mathcal{N}(2, 2)$ i $p(x|y = 3) = \mathcal{N}(8, 2)$, a procijenjene apriorne vjerojatnosti klase su $P(y = 1) = P(y = 2) = 2/5$ i $P(y = 3) = 1/5$. Međutim, nakon što smo naučili ovaj model, zaključili smo da na ispitnom skupu postoji pomak u distribuciji podataka u odnosu na skup za učenje te da zbog toga model ne generalizira dobro. Zaključili smo da se ovo može ispraviti tako da se naučeni model malo izmijeni, i to tako da se varijanca izglednosti klase $y = 1$ postavi na 1 i da se apriorne vjerojatnosti klase ujednače, $P(y = 1) = P(y = 2) = P(y = 3) = 1/3$. Skicirajte gustoće zajedničke vjerojatnosti naučenog i izmijenjenog modela. Neka su h_1 i h_2 MAP-hipoteze prvog i drugog modela, te neka su a i b pozitivne konstante. Razmotrite segment ulaznog prostora za koji vrijedi $-10 \leq x \leq 10$. **Na kojim se dijelovima tog segmenta ulaznog prostora MAP-hipoteze prvog i drugog modela razlikuju?**

- A $[-4 - a, 5 + b]$ B $[-4, -4 + a] \cup [5 - b, 5]$ C $[-4 - a, -4 + b]$ D $[-4 - a, -4] \cup [5, 5 + b]$

- 7 (T) Polunaivan Bayesov klasifikator može ostvariti veću klasifikacijsku točnost od naivnog Bayesovog klasifikatora u situacijama kada između značajki postoji zavisnost. Jedan način određivanja zavisnosti između značajki temelji se na izračunu Kullback-Leiblerove divergencije (KL-divergencije) između distribucija dviju varijabli. **Koji je princip uporabe KL-divergencije u izgradnji polunaivnog Bayesovog klasifikatora?**

- A Što je veća KL-divergencija između $P(x_1)P(x_2)$ i $P(x_1, x_2)$, to su varijable x_1 i x_2 manje nezavisne, pa je to veća korist od njihovog združivanja u jedan faktor
- B Ako je KL-divergencija između $P(x_1|x_2)$ i $P(x_2|x_1)$ vrlo mala, onda su varijable x_1 i x_2 vrlo zavisne i treba ih odvojiti u zasebne faktore
- C Što je manja KL-divergencija između $P(x_1)$ i $P(x_2)$, to su varijable x_1 i x_2 više zavisne, pa je to veća korist od njihovog združivanja u jedan faktor
- D Ako je KL-divergencija između $P(x_1|x_2)$ i $P(x_2|x_1)$ vrlo velika, onda su varijable x_1 i x_2 vrlo zavisne i treba ih združiti u jedan faktor

- 8 (P) Gausovim Bayesovim klasifikatorom rješavamo problem klasifikacije u $K = 10$ klase sa $n = 100$ značajki. Prisjetite se da kod Gaussovog Bayesovog klasifikatora uvođenjem odgovarajućih pretpostavki na kovarijacijsku matricu Σ možemo utjecati na broj parametara modela a time onda i na složenost modela. Razmatramo tri modela s kovarijacijskim matricama u koje smo ugradili sljedeće pretpostavke:

\mathcal{H}_1 : Značajke imaju različite varijance, ali iste za sve klase, te nisu korelirane

\mathcal{H}_2 : Značajke nisu korelirane, imaju jednaku varijancu unutar svake klase, no različitu za svaku klasu

\mathcal{H}_3 : Između značajki postoje korelacije, ali se one ne razlikuju između klase

Neka ‘ \supset ’ označava relaciju “složeniji od”, a neka ‘ $>$ ’ označava relaciju “ima više parametara od”. Što možemo zaključiti o složenosti i broju parametara za gornja četiri modela?


- A $\mathcal{H}_1 > \mathcal{H}_3 > \mathcal{H}_2, \mathcal{H}_1 \supset \mathcal{H}_2 \supset \mathcal{H}_3$ C $\mathcal{H}_1 > \mathcal{H}_2 > \mathcal{H}_3, \mathcal{H}_1 \supset \mathcal{H}_2$
 B $\mathcal{H}_3 > \mathcal{H}_1 > \mathcal{H}_2, \mathcal{H}_3 \supset \mathcal{H}_1$ D $\mathcal{H}_3 > \mathcal{H}_2 > \mathcal{H}_1, \mathcal{H}_3 \supset \mathcal{H}_1 \supset \mathcal{H}_2$

Cjelina 5: Probabilistički grafički modeli (5 pitanja)

9 (T) Probabilistički grafički modeli na sažet način prikazuju zajedničku distribuciju n slučajnih varijabli. Ta je distribucija prikazana usmjerenim grafom. Neka graf sadrži čvor označen sa x . Čemu odgovara taj čvor?

- A Marginalnoj vjerojatnosti $P(x)$ ili marginalnoj gustoći vjerojatnosti $p(x)$
 B Distribuciji varijable x uvjetovane vrijednostima varijabli roditeljskih čvorova od x
 C Distribuciji varijable x uz opažene sve varijable koje varijabli x prethode u topološkom uređaju
 D Zajedničkoj vjerojatnosti varijable x i varijabli roditeljskih čvorova od x

10 (P) Na slici ispod prikazana je Bayesova mreža koja odgovara polunaivnom Bayesovom klasifikatoru. Pretpostavite da su značajke x_1, x_2 i x_3 ternarne varijable te da je oznaka klase y također ternarna varijabla. Označimo ovaj model sa \mathcal{H}_2 . Model \mathcal{H}_2 može se pojednostaviti ako se ukloni brid između varijabli x_2 i x_3 . Označimo takav model sa \mathcal{H}_1 . S druge strane, od modela \mathcal{H}_2 može se napraviti još složeniji model tako da se doda brid između varijabli x_1 i x_2 . Označimo takav model sa \mathcal{H}_3 .



Razmotrite koliko parametara imaju modeli $\mathcal{H}_1, \mathcal{H}_2$ i \mathcal{H}_3 . Koliko model \mathcal{H}_2 ima više parametara od modela \mathcal{H}_1 , a koliko manje parametara od modela \mathcal{H}_3 ?

- A 12 više, 12 manje B 8 više, 8 manje C 2 više, 4 manje D 12 više, 8 manje

11 (N) Razmotrite jednostavnu Bayesovu mrežu koja odgovara faktorizaciji $P(x, y, z, w) = P(z)P(w)P(y|z, w)P(x|y)$. Sve varijable su binarne. Vrijedi $P(z = 1) = 0.1, P(w = 1) = 0.1, P(x = 1|y = 0) = 0.2$ i $P(x = 1|y = 1) = 0.6$. Tablica uvjetne vjerojatnosti za čvor y je sljedeća:

z	w	$p(y = 1 z, w)$
0	0	0
0	1	0.4
1	0	0.2
1	1	0.7

Postupkom uzorkovanja s odbijanjem uzorkujemo iz aposteriorne distribucije $P(w|x = 0, z = 1)$. Uzorkovanje smo ponovili ukupno $N = 10000$ puta, od čega smo neke vektore morali odbaciti, pa je naš konačni uzorak manji od N . U uzorku neodbačenih vektora, koliko je očekivano više vektora sa $w = 0$ od vektora sa $w = 1$?

- A 472 B 944 C 596 D 348


12 (P) Bayesova mreža ima pet varijabli, s topološkim uređajem v, w, x, y, z . Uz takav uređaj, u mreži vrijede sljedeće uvjetne nezavisnosti:

$$\{v, w\} \perp y | x \quad \{v, x\} \perp z | \{w, y\}$$

Primjenom algoritma d-odvajanja ispitujemo zavisnosti između parova varijabli. Koje od sljedećih tvrdnji o nezavisnosti vrijede u ovoj Bayesovoj mreži?

- A $w \perp y | z$ B $v \perp z | y$ C $v \perp y | z$ D $v \perp y | x$

13 (N) Na slici ispod prikazana je Bayesova mreža za problem prskalice za travu. Varijable su: C (oblačno/cloudy), S (prskalica/sprinkler), R (kiša/rain) i W (mokra trava/wet grass). Dane su i tablice uvjetnih vjerojatnosti.



C	$P(S = 1 C)$
0	0.5
1	0.2

C	$P(R = 1 C)$
0	0.2
1	0.8

S	R	$P(W = 1 S, R)$
0	0	0.0
0	1	0.9
1	0	0.1
1	1	0.99

Izračunajte aposteriornu vjerojatnost da radi prskalica ako trava nije mokra i oblačno je.

- A 0.144 B 0.309 C 0.223 D 0.069

Cjelina 6: Grupiranje i vrednovanje modela (9 pitanja)

- 14** (N) Vrednujemo višeklasni klasifikator koji koristimo kao referentni model za vrednovanje drugih klasifikatora. Klasifikator nasumično dodjeljuje oznake za tri klase ($K = 3$), i to prema distribuciji oznaka na skupu za učenje. Skup za učenje sadrži 100 primjera sa 35, 60 i 5 primjera u prvoj, drugoj odnosno trećoj klasi. S druge strane, ispitni skup sadrži 50 primjera, od kojih je po 20 u prvoj i drugoj klasi, a 10 u trećoj klasi. **Koliko iznosi očekivana makro-F1 vrijednost nasumičnog klasifikatora na ispitnome skupu?**

- A 0.2989 B 0.3111 C 0.2085 D 0.2156

- 15** (T) Kod vrednovanja algoritma strojnog učenja važno je da vrednujemo model optimalne složenosti. Zbog toga označeni skup podataka dijelimo na tri disjunktne podskupa: skup za učenje, skup za provjeru i ispitni skup. Za odabir modela (tj. optimizaciju hiperparametara) koristimo skup za učenje i skup za provjeru, dok točnost optimalnog modela ispitujemo na ispitnome skupu. Zamislite da smo zaboravili upotrijebiti skup za provjeru: umjesto toga hiperparametre modela optimirali smo na skupu za učenje, a model smo potom ispitali na ispitnom skupu. **U odnosu na to da smo pravilno proveli vrednovanje algoritma, što možemo očekivati u ovom slučaju?**

- A Model će biti prenaučeni i imat će manju točnost na ispitnome skupu
 B Model će biti podnaučeni, ali imat će veću točnost na ispitnome skupu
 C Model će biti prenaučeni, ali imat će veću točnost na ispitnome skupu
 D Model će biti optimalne složenosti i imat će veću točnost na ispitnome skupu

- 16** (P) Podatke u dvodimenzijском ulaznom prostoru ($n = 2$) grupiramo u dvije grupe ($K = 2$) algoritmom Gaussove mješavine (GMM). Skup podataka je sljedeći:

$$\mathcal{D} = \{\mathbf{x}^{(i)}\}_{i=1}^8 = \{(-2, -2), (-2, -1), (-1, -2), (-1, -1), (1, 2), (3, 1), (3, 3), (5, 2)\}$$

Razmatramo dva modela: \mathcal{H}_1 i \mathcal{H}_2 . Oba modela koriste punu kovarijacijsku matricu, međutim kod modela \mathcal{H}_1 kovarijacijska matrica nije dijeljena, dok je kod modela \mathcal{H}_2 kovarijacijska matrica dijeljena. Za svaki model razmotrite ono grupiranje koje maksimizira log-izglednost na skupu \mathcal{D} . Neka je $p_j(\mathbf{x}^{(i)}|y = k)$ izglednost grupe $y = k$ za primjer $\mathbf{x}^{(i)}$ prema modelu \mathcal{H}_j . Oznake grupa su $y = 1$ i $y = 2$, te pretpostavite da je grupiranje takvo da vrijedi $\|\boldsymbol{\mu}_1\| > \|\boldsymbol{\mu}_2\|$. **Što od sljedećega vrijedi?**

- A $p_2(\mathbf{x}^{(8)}|y = 1) < p_1(\mathbf{x}^{(5)}|y = 1)$ C $p_2(\mathbf{x}^{(1)}|y = 2) > p_1(\mathbf{x}^{(2)}|y = 2)$
 B $p_2(\mathbf{x}^{(6)}|y = 1) < p_1(\mathbf{x}^{(7)}|y = 1)$ D $p_2(\mathbf{x}^{(4)}|y = 2) > p_1(\mathbf{x}^{(3)}|y = 2)$

- 17** (T) Algoritam K-sredina iterativno smanjuje vrijednost funkcije pogreške J . Neovisno o broju grupa K , algoritam uvijek konvergira (završava s izvođenjem). Međutim, konačna vrijednost funkcije pogreške J može se razlikovati između dva pokretanja algoritma s istim brojem grupa K . **Zašto?**

- A Zbog izotropnosti kovarijacijskih matrica Σ_k
 B Zbog loše odabrane vrijednosti za broj grupa K
 C Zbog nelinearnosti granice između K grupa
 D Zbog razlike u početnim središtima $\boldsymbol{\mu}_k$

18 (T) Za procjenu parametara modela GMM (središta grupa μ_k , kovarijacijske matrice Σ_k i koeficijenti mješavine π_k) tipično se koristi algoritam maksimizacije očekivanja (EM-algoritam). Prije pokretanja EM-algoritma, parametre je potrebno inicijalizirati. U praksi se za inicijalizaciju parametara μ_k koristi algoritam K-sredina. **Koji je očekivani efekt uporabe algoritma K-sredina za inicijalizaciju EM-algoritma?**

- A Manja log-izglednost početnih i konačnih parametara te optimalan broj grupa K
- B Veća potpuna log-izglednost konačnih parametara i veće vrijednosti gustoća komponenti
- C Manja log-izglednost početnih parametara, ali veća log-izglednost konačnih parametara
- D Veća log-izglednost početnih i konačnih parametara te manje iteracija do konvergencije

19 (P) Skup neoznačenih primjera u dvodimenzijaskome ulaznom prostoru neka je sljedeći:

$$\mathcal{D} = \{\mathbf{x}^{(i)}\}_i = \{(1, 1), (1, 3), (1, 4), (3, 4)\}$$

Primjere grupiramo u $K = 2$ grupe algoritmom K-means++. Konačna vrijednost funkcije pogreške J bit će različita za različita pokretanja algoritma. Razmotrite sve moguće konačne vrijednosti funkcije J , tj. vrijednosti funkcije J nakon što se algoritam K-means++ zaustavi. **Koliko iznosi maksimalna moguća konačna vrijednost funkcije J ?**

- A 4 B 14/3 C 10/3 D 11/2

20 (N) Particijskim algoritmom grupiranja grupiramo $N = 1000$ primjera. Na temelju znanja o problemu zaključili smo da bi primjeri trebali formirati $K = 3$ grupe, pa smo s tim brojem grupa proveli grupiranje. Kako bismo evaluirali točnost grupiranja, slučajnim odabirom smo iz skupa primjera uzorkovali 10 primjera, ručno smo označili primjere iz tog uzorka, i zatim na tom uzorku računamo Randov indeks. Označavanje smo proveli tako da smo svakom primjeru iz uzorka dodijelili oznaku točne grupe. Oznake grupe dobivene algoritmom grupiranja y_{pred} i oznake točnih grupa y_{true} za svih deset primjera u uzorku su sljedeće:

i	1	2	3	4	5	6	7	8	9	10
$y_{pred}^{(i)}$	0	1	2	1	1	0	0	2	1	1
$y_{true}^{(i)}$	1	0	0	2	1	0	2	1	0	1

Koliko iznosi Randov indeks grupiranja izračunat na ovom uzorku?

- A 0.58 B 0.49 C 0.62 D 0.53

21 (N) Algoritmom hijerarhijskog aglomerativnog grupiranja (HAC) grupiramo $N = 5$ primjera. Za grupiranje koristimo mjeru sličnosti, definiranu sljedećom matricom:

$$\begin{pmatrix} 1.0 & 0.2 & 0.6 & 0.7 & 0.4 \\ 0.2 & 1.0 & 0.3 & 0.3 & 0.7 \\ 0.6 & 0.3 & 1.0 & 0.9 & 0.5 \\ 0.7 & 0.3 & 0.9 & 1.0 & 0.4 \\ 0.4 & 0.7 & 0.5 & 0.4 & 1.0 \end{pmatrix}$$

Provedite grupiranje algoritmom HAC s potpunim povezivanjem. Pritom u svakoj iteraciji bilježite na kojoj razini sličnosti se odvija stapanje dviju grupa. **Koliko iznosi zbroj po svim razinama sličnosti na kojima se odvija stapanje grupa?**

- A 1.9 B 2.4 C 1.8 D 2.0

22 (P) Raspoložemo sa 1000 označenih primjera. Na tom skupu treniramo i vrednujemo algoritam SVM, optimizirajući hiperparametre C i γ . Za vrednovanje koristimo ugniježdenu unakrsnu provjeru sa 5 preklopa u vanjskoj petlji i 5 preklopa u unutarnjoj petlji. To znači da za svaku kombinaciju vrijednosti hiperparametara C i γ treniramo pet modela. Ti modeli trenirani su na skupovima za učenje koji nisu disjunktni: svaki par treniranih modela dijele određeni broj primjera za učenje. Izračunajte koliko primjera za učenje dijele svaki par modela koje treniramo u unutarnjoj petlji ugniježdene unakrsne provjere. **Za koliko bi taj broj narastao kada bismo broj preklopa u unutarnjoj petlji povećali na 10?**

- A 192 B 160 C 100 D 80

Završni ispit iz Strojnog učenja 1 (ak. god. 2023./2024.)

– NEKORIGIRANA VERZIJA –

Ispit sadrži 22 pitanja i ukupno nosi najviše 20 bodova (za 30% bodova na predmetu). Pitanja nose po 1 bod, a 1/3 boda oduzima se za pogrešan odgovor. Za maksimalan broj bodova dovoljno je točno riješiti 20 pitanja, a višak bodova iznad 20 se zanemaruje. Trajanje ispita je 180 minuta. Primjerak ispita morate predati zajedno sa svojim rješenjima.

Cjelina 4: Procjena parametara i Bayesov klasifikator (8 pitanja)

- 1 (P) Uz određene restrikcije na parametre Gaussovog Bayesovog klasifikatora, Gaussov Bayesov klasifikator i logistička regresija su generativno-diskriminativni par modela. U pravilu, logistička regresija imaće manje parametara od njoj odgovarajućeg modela Gaussovog Bayesovog klasifikatora. Razmotrite slučaj binarne klasifikacije u ulaznome prostoru dimenzije $n = 300$ pomoću modela logističke regresije i njoj odgovarajućeg modela Gaussovog Bayesovog klasifikatora. **Koliko će model Gaussovog Bayesovog klasifikatora imati više parametara od modela logističke regresije?**

A 40400 B 45450 C 20300 D 90600

- 2 (N) Zadan je uzorak kontinuirane slučajne varijable, $\mathcal{D} = \{10, 5, 6, 0\}$. Pretpostavljamo razdiobu $\mathcal{N}(\mu, \sigma^2)$, čija je gustoća vjerojatnosti:

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

Za procjenu parametra μ koristimo procjenitelj $\hat{\mu}_{MLE}$, a za procjenu parametra σ^2 procjenitelj $\hat{\sigma}_{UB}^2$, koji je nepristran procjenitelj izveden odgovarajućom korekcijom iz procjenitelja $\hat{\sigma}_{MLE}^2$. Izračunajte log-izglednost procijenjenih parametara na skupu \mathcal{D} , tj. $\ln \mathcal{L}(\hat{\mu}_{MLE}, \hat{\sigma}_{UB}^2|\mathcal{D})$. **Koliko iznosi ta log-izglednost?**

A -13.163 B -10.832 C -12.873 D -15.200

- 3 (N) Treniramo Bayesov klasifikator za odluku o dobroj destinaciji za Erasmus+ studijski boravak. Skup primjera za učenje, izgrađen na temelju iskustava prijatelja i prijatelja prijatelja, je sljedeći:

i	Država	Stipendija	Semestar	Studij	GovoriJezik	$y^{(i)}$
1	Njemačka	da	ljetni	dipl	da	1
2	Poljska	ne	zimski	preddipl	ne	1
3	Italija	da	ljetni	dipl	da	1
4	Njemačka	ne	zimski	preddipl	ne	0
5	Austrija	da	ljetni	dipl	da	1
6	Poljska	ne	zimski	dipl	ne	1
7	Austrija	da	zimski	dipl	ne	1
8	Njemačka	ne	zimski	dipl	ne	0

Očekujemo zavisnost između varijabli *Država* i *Stipendija*, pa koristimo polunaivan Bayesov klasifikator u kojemu su te dvije varijable združene. Procjene izglednosti klasa radimo Laplaceovim MAP-procjeniteljem. Zanima nas klasifikacija za $\mathbf{x} = (\text{Italija}, \text{ne}, \text{zimski}, \text{dipl}, \text{ne})$. **Koliko iznosi aposteriorna vjerojatnost $P(y = 1|\mathbf{x})$?**

A 0.588 B 0.488 C 0.741 D 0.322

- 4 (P) Gausovim Bayesovim klasifikatorom rješavamo problem klasifikacije u $K = 10$ klasa sa $n = 100$ značajki. Prisjetite se da kod Gaussovog Bayesovog klasifikatora uvođenjem odgovarajućih pretpostavki na kovarijacijsku matricu Σ možemo utjecati na broj parametara modela a time onda i na složenost modela. Razmatramo tri modela s kovarijacijskim matricama u koje smo ugradili sljedeće pretpostavke:

\mathcal{H}_1 : Značajke imaju različite varijance, ali iste za sve klase, te nisu korelirane

\mathcal{H}_2 : Značajke nisu korelirane, imaju jednaku varijancu unutar svake klase, no različitu za svaku klasu

\mathcal{H}_3 : Između značajki postoje korelacije, ali se one ne razlikuju između klasa

Neka ‘ \supset ’ označava relaciju “složeniji od”, a neka ‘ $>$ ’ označava relaciju “ima više parametara od”. Što možemo zaključiti o složenosti i broju parametara za gornja četiri modela?

- A $\mathcal{H}_1 > \mathcal{H}_2 > \mathcal{H}_3$, $\mathcal{H}_1 \supset \mathcal{H}_2$ C $\mathcal{H}_3 > \mathcal{H}_1 > \mathcal{H}_2$, $\mathcal{H}_3 \supset \mathcal{H}_1$
 B $\mathcal{H}_3 > \mathcal{H}_2 > \mathcal{H}_1$, $\mathcal{H}_3 \supset \mathcal{H}_1 \supset \mathcal{H}_2$ D $\mathcal{H}_1 > \mathcal{H}_3 > \mathcal{H}_2$, $\mathcal{H}_1 \supset \mathcal{H}_2 \supset \mathcal{H}_3$

- 5 (P) Gaussov Bayesov klasifikator koristimo za klasifikaciju jednodimenzijskih podataka u tri klase. Procijenjene izglednosti klase su $p(x|y = 1) = \mathcal{N}(-10, 2)$, $p(x|y = 2) = \mathcal{N}(2, 2)$ i $p(x|y = 3) = \mathcal{N}(8, 2)$, a procijenjene apriorne vjerojatnosti klase su $P(y = 1) = P(y = 2) = 1/5$ i $P(y = 3) = 3/5$. Međutim, nakon što smo naučili ovaj model, zaključili smo da na ispitnom skupu postoji pomak u distribuciji podataka u odnosu na skup za učenje te da zbog toga model ne generalizira dobro. Zaključili smo da se ovo može ispraviti tako da se naučeni model malo izmijeni, i to tako da se varijanca izglednosti klase $y = 1$ postavi na 1 i da se apriorne vjerojatnosti klase ujednače, $P(y = 1) = P(y = 2) = P(y = 3) = 1/3$. Skicirajte gustoće zajedničke vjerojatnosti naučenog i izmijenjenog modela. Neka su h_1 i h_2 MAP-hipoteze prvog i drugog modela, te neka su a i b pozitivne konstante. Razmotrite segment ulaznog prostora za koji vrijedi $-10 \leq x \leq 10$. Na kojim se dijelovima tog segmenta ulaznog prostora MAP-hipoteze prvog i drugog modela razlikuju?

- A $[-4, -4 + a] \cup [5, 5 + b]$ B $[-4 - a, 5 + b]$ C $[-4 - a, -4 + b]$ D $[-4 - a, -4] \cup [5 - b, 5]$

- 6 (N) Na skupu označenih primjera u ulaznome prostoru dimenzije $n = 2$ treniramo Gaussov Bayesov klasifikator za klasifikaciju primjera u $K = 2$ klase, uz pretpostavku dijeljene i dijagonalne kovarijacijske matrice. Izglednost klase s oznakom $y = j$ definirana je multivarijantnom Gaussovom gustoćom vjerojatnosti:

$$p(\mathbf{x}|y = j) = \frac{1}{(2\pi)^{n/2} |\Sigma_j|^{1/2}} \exp \left\{ -\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu}_j)^T \Sigma_j^{-1} (\mathbf{x} - \boldsymbol{\mu}_j) \right\}$$

Model treniramo na skupu podataka od $N = 7$ primjera:

$$\mathcal{D} = \{(\mathbf{x}^{(i)}, y^{(i)})\}_i = \{((-1, -2), 0), ((0, 0), 0), ((1, 2), 0), ((3, -1), 1), ((4, -1), 1), ((4, 1), 1), ((5, 1), 1)\}$$

Procijenite parametre modela na ovom skupu primjera. Budući da je skup primjera malen, za procjenu kovarijacijske matrice koristite nepristran procjenitelj. Izlaz modela za klasu $y = j$ neka je zajednička gustoća vjerojatnosti, $h_j(\mathbf{x}) = \ln p(\mathbf{x}, y = j)$. Koliko iznosi $h_0(\mathbf{x})$ za primjer $\mathbf{x} = (0, 0)$?

- A -4.13 B -2.75 C -3.03 D -3.84

- 7 (T) Bayesov klasifikator temelji se na hipotezi *maximum a posteriori* (MAP). Za treniranje Bayesovog klasifikatora možemo koristiti procjenitelj MLE. Koja je razlika između hipoteze MAP kod Bayesovog klasifikatora i procjenitelja MLE?

- A Hipoteza MAP maksimizira aposterionu vjerojatnost parametara, a procjenitelj MLE određuje aposterionu vjerojatnost klase za zadani primjer
 B Procjenitelj MLE primjer klasificira u klasu koja je za njega navjerojatnija, a hipoteza MAP tu odluku kombinira s apriornim znanjem
 C Procjenitelj MLE određuje apriornu vjerojatnost klase, a hipoteza MAP maksimizira aposterionu vjerojatnost parametara
 D Hipoteza MAP određuje koju klasu odabirati za primjer, a procjenitelj MLE određuje koju vrijednost odabirati za parametar

- 8 (T) Polunaivan Bayesov klasifikator može ostvariti veću klasifikacijsku točnost od naivnog Bayesovog klasifikatora u situacijama kada između značajki postoji zavisnost. Jedan način određivanja zavisnosti između značajki temelji se na izračunu Kullback-Leiblerove divergencije (KL-divergencije) između distribucija dviju varijabli. Koji je princip uporabe KL-divergencije u izgradnji polunaivnog Bayesovog klasifikatora?

- A Što je veća KL-divergencija između $P(x_1)P(x_2)$ i $P(x_1, x_2)$, to su varijable x_1 i x_2 manje nezavisne, pa je to veća korist od njihovog združivanja u jedan faktor
 B Ako je KL-divergencija između $P(x_1|x_2)$ i $P(x_2|x_1)$ vrlo velika, onda su varijable x_1 i x_2 vrlo zavisne i treba ih združiti u jedan faktor
 C Ako je KL-divergencija između $P(x_1|x_2)$ i $P(x_2|x_1)$ vrlo mala, onda su varijable x_1 i x_2 vrlo zavisne i treba ih odvojiti u zasebne faktore
 D Što je manja KL-divergencija između $P(x_1)$ i $P(x_2)$, to su varijable x_1 i x_2 više zavisne, pa je to veća korist od njihovog združivanja u jedan faktor

Cjelina 5: Probabilistički grafički modeli (5 pitanja)

- 9 (N) Razmotrite jednostavnu Bayesovu mrežu koja odgovara faktorizaciji $P(x, y, z, w) = P(z)P(w)P(y|z, w)P(x|y)$. Sve varijable su binarne. Vrijedi $P(z = 1) = 0.1$, $P(w = 1) = 0.2$, $P(x = 1|y = 0) = 0.2$ i $P(x = 1|y = 1) = 0.6$. Tablica uvjetne vjerojatnosti za čvor y je sljedeća:

z	w	$p(y = 1 z, w)$
0	0	0
0	1	0.4
1	0	0.2
1	1	0.7

Postupkom uzorkovanja s odbijanjem uzorkujemo iz aposteriorne distribucije $P(w|x = 0, z = 1)$. Uzorkovanje smo ponovili ukupno $N = 10000$ puta, od čega smo neke vektore morali odbaciti, pa je naš konačni uzorak manji od N . U uzorku neodbačenih vektora, koliko je očekivano više vektora sa $w = 0$ od vektora sa $w = 1$?

- A 348 B 944 C 596 D 472

- 10 (T) Probabilistički grafički modeli na sažet način prikazuju zajedničku distribuciju n slučajnih varijabli. Ta je distribucija prikazana usmjerenim grafom. Neka graf sadrži čvor označen sa x . Čemu odgovara taj čvor?

- A Marginalnoj vjerojatnosti $P(x)$ ili marginalnoj gustoći vjerojatnosti $p(x)$
 B Distribuciji varijable x uvjetovane vrijednostima varijabli roditeljskih čvorova od x
 C Distribuciji varijable x uz opažene sve varijable koje varijabli x prethode u topološkom uređaju
 D Zajedničkoj vjerojatnosti varijable x i varijabli roditeljskih čvorova od x


- 11 (P) Bayesova mreža ima pet varijabli, s topološkim uređajem v, w, x, y, z . Uz takav uređaj, u mreži vrijede sljedeće uvjetne nezavisnosti:

$$\{v, w\} \perp y | x \quad \{v, x\} \perp z | \{w, y\}$$

Primjenom algoritma d-odvajanja ispitujemo zavisnosti između parova varijabli. Koje od sljedećih tvrdnji o nezavisnosti vrijede u ovoj Bayesovoj mreži?

- A $v \perp z | y$ B $v \perp y | w$ C $w \perp y | x$ D $v \perp z | w$

- 12 (N) Na slici ispod prikazana je Bayesova mreža za problem prskalice za travu. Varijable su: C (oblačno/cloudy), S (prskalica/sprinkler), R (kiša/rain) i W (mokra trava/wet grass). Dane su i tablice uvjetnih vjerojatnosti.



C	$P(S = 1 C)$
0	0.5
1	0.4


C	$P(R = 1 C)$
0	0.2
1	0.8

S	R	$P(W = 1 S, R)$
0	0	0.0
0	1	0.9
1	0	0.1
1	1	0.99

Izračunajte aposteriornu vjerojatnost da radi prskalica ako trava nije mokra i oblačno je.

- A 0.144 B 0.069 C 0.309 D 0.223

- 13 (P) Na slici ispod prikazana je Bayesova mreža koja odgovara polunaivnom Bayesovom klasifikatoru. Pretpostavite da su značajke x_1, x_2 i x_3 ternarne varijable te da je oznaka klase y također ternarna varijabla. Označimo ovaj model sa \mathcal{H}_2 . Model \mathcal{H}_2 može se pojednostaviti ako se ukloni brid između varijabli x_2 i x_3 . Označimo takav model sa \mathcal{H}_1 . S druge strane, od modela \mathcal{H}_2 može se napraviti još složeniji model tako da se doda brid između varijabli x_1 i x_2 . Označimo takav model sa \mathcal{H}_3 .



Razmotrite koliko parametara imaju modeli $\mathcal{H}_1, \mathcal{H}_2$ i \mathcal{H}_3 . Koliko model \mathcal{H}_2 ima više parametara od modela \mathcal{H}_1 , a koliko manje parametara od modela \mathcal{H}_3 ?

- A 8 više, 8 manje B 12 više, 8 manje C 2 više, 4 manje D 12 više, 12 manje

Cjelina 6: Grupiranje i vrednovanje modela (9 pitanja)

- 14 (N) Algoritmom hijerarhijskog aglomerativnog grupiranja (HAC) grupiramo $N = 5$ primjera. Za grupiranje koristimo mjeru sličnosti, definiranu sljedećom matricom:

$$\begin{pmatrix} 1.0 & 0.2 & 0.6 & 0.7 & 0.4 \\ 0.2 & 1.0 & 0.3 & 0.3 & 0.7 \\ 0.6 & 0.3 & 1.0 & 0.9 & 0.5 \\ 0.7 & 0.3 & 0.9 & 1.0 & 0.4 \\ 0.4 & 0.7 & 0.5 & 0.4 & 1.0 \end{pmatrix}$$

Provedite grupiranje algoritmom HAC s potpunim povezivanjem. Pritom u svakoj iteraciji bilježite na kojoj razini sličnosti se odvija stapanje dviju grupa. **Koliko iznosi zbroj po svim razinama sličnosti na kojima se odvija stapanje grupa?**

- A 1.9 B 2.0 C 2.4 D 1.8
- 15 (N) Particijskim algoritmom grupiranja grupiramo $N = 1000$ primjera. Na temelju znanja o problemu zaključili smo da bi primjeri trebali formirati $K = 3$ grupe, pa smo s tim brojem grupa proveli grupiranje. Kako bismo evaluirali točnost grupiranja, slučajnim odabirom smo iz skupa primjera uzorkovali 10 primjera, ručno smo označili primjere iz tog uzorka, i zatim na tom uzorku računamo Randov indeks. Označavanje smo proveli tako da smo svakom primjeru iz uzorka dodijelili oznaku točne grupe. Oznake grupe dobivene algoritmom grupiranja y_{pred} i oznake točnih grupa y_{true} za svih deset primjera u uzorku su sljedeće:

i	1	2	3	4	5	6	7	8	9	10
$y_{pred}^{(i)}$	0	0	2	1	1	0	0	2	1	1
$y_{true}^{(i)}$	1	0	0	2	1	0	2	1	1	1

Koliko iznosi Randov indeks grupiranja izračunat na ovom uzorku?

- A 0.49 B 0.62 C 0.53 D 0.58
- 16 (N) Vrednujemo višeklasni klasifikator koji koristimo kao referentni model za vrednovanje drugih klasifikatora. Klasifikator nasumično dodjeljuje oznake za tri klase ($K = 3$), i to prema distribuciji oznaka na skupu za učenje. Skup za učenje sadrži 100 primjera sa 35, 60 i 5 primjera u prvoj, drugoj odnosno trećoj klasi. S druge strane, ispitni skup sadrži 50 primjera, od kojih je po 20 u prvoj i drugoj klasi, a 10 u trećoj klasi. **Koliko iznosi očekivana makro-F1 vrijednost nasumičnog klasifikatora na ispitnome skupu?**

- A 0.2156 B 0.2085 C 0.2989 D 0.3111
- 17 (P) Skup neoznačenih primjera u dvodimenzijaskome ulaznom prostoru neka je sljedeći:

$$\mathcal{D} = \{\mathbf{x}^{(i)}\}_i = \{(1, 1), (1, 3), (1, 4), (3, 4)\}$$

Primjere grupiramo u $K = 2$ grupe algoritmom K-means++. Konačna vrijednost funkcije pogreške J bit će različita za različita pokretanja algoritma. Razmotrite sve moguće konačne vrijednosti funkcije J , tj. vrijednosti funkcije J nakon što se algoritam K-means++ zaustavi. **Koliko iznosi maksimalna moguća konačna vrijednost funkcije J ?**

- A $14/3$ B $10/3$ C $11/2$ D 4
- 18 (T) Algoritam K-sredina iterativno smanjuje vrijednost funkcije pogreške J . Neovisno o broju grupa K , algoritam uvijek konvergira (završava s izvođenjem). Međutim, konačna vrijednost funkcije pogreške J može se razlikovati između dva pokretanja algoritma s istim brojem grupa K . **Zašto?**
- A Zbog loše odabrane vrijednosti za broj grupa K
- B Zbog razlike u početnim središtima μ_k
- C Zbog izotropnosti kovarijacijskih matrica Σ_k
- D Zbog nelinearnosti granice između K grupa

- 19 (P) Raspoložemo sa 750 označenih primjera. Na tom skupu treniramo i vrednujemo algoritam SVM, optimizirajući hiperparametre C i γ . Za vrednovanje koristimo ugniježdenu unakrsnu provjeru sa 5 preklopa u vanjskoj petlji i 5 preklopa u unutarnjoj petlji. To znači da za svaku kombinaciju vrijednosti hiperparametara C i γ treniramo pet modela. Ti modeli trenirani su na skupovima za učenje koji nisu disjunktni: svaki par treniranih modela dijele određeni broj primjera za učenje. Izračunajte koliko primjera za učenje dijele svaki par modela koje treniramo u unutarnjoj petlji ugniježdene unakrsne provjere. **Za koliko bi taj broj narastao kada bismo broj preklopa u unutarnjoj petlji povećali na 10?**

A 120 B 60 C 75 D 144

- 20 (P) Podatke u dvodimenzijaskome ulaznom prostoru ($n = 2$) grupiramo u dvije grupe ($K = 2$) algoritmom Gaussove mješavine (GMM). Skup podataka je sljedeći:

$$\mathcal{D} = \{\mathbf{x}^{(i)}\}_{i=1}^8 = \{(-2, -2), (-2, -1), (-1, -2), (-1, -1), (1, 2), (3, 1), (3, 3), (5, 2)\}$$

Razmatramo dva modela: \mathcal{H}_1 i \mathcal{H}_2 . Oba modela koriste punu kovarijacijsku matricu, međutim kod modela \mathcal{H}_1 kovarijacijska matrica nije dijeljena, dok je kod modela \mathcal{H}_2 kovarijacijska matrica dijeljena. Za svaki model razmotrite ono grupiranje koje maksimizira log-izglednost na skupu \mathcal{D} . Neka je $p_j(\mathbf{x}^{(i)}|y = k)$ izglednost grupe $y = k$ za primjer $\mathbf{x}^{(i)}$ prema modelu \mathcal{H}_j . Oznake grupa su $y = 1$ i $y = 2$, te pretpostavite da je grupiranje takvo da vrijedi $\|\boldsymbol{\mu}_1\| > \|\boldsymbol{\mu}_2\|$. **Što od sljedećega vrijedi?**

A $p_2(\mathbf{x}^{(1)}|y = 2) > p_1(\mathbf{x}^{(2)}|y = 2)$ C $p_2(\mathbf{x}^{(8)}|y = 1) < p_1(\mathbf{x}^{(5)}|y = 1)$
 B $p_2(\mathbf{x}^{(4)}|y = 2) > p_1(\mathbf{x}^{(3)}|y = 2)$ D $p_2(\mathbf{x}^{(6)}|y = 1) < p_1(\mathbf{x}^{(7)}|y = 1)$

- 21 (T) Kod vrednovanja algoritma strojnog učenja važno je da vrednujemo model optimalne složenosti. Zbog toga označeni skup podataka dijelimo na tri disjunktna podskupa: skup za učenje, skup za provjeru i ispitni skup. Za odabir modela (tj. optimizaciju hiperparametara) koristimo skup za učenje i skup za provjeru, dok točnost optimalnog modela ispitujemo na ispitnome skupu. Zamislite da smo zaboravili upotrijebiti skup za provjeru: umjesto toga hiperparametre modela optimirali smo na skupu za učenje, a model smo potom ispitali na ispitnom skupu. **U odnosu na to da smo pravilno proveli vrednovanje algoritma, što možemo očekivati u ovom slučaju?**

A Model će biti prenaučeni, ali imat će veću točnost na ispitnome skupu
 B Model će biti optimalne složenosti i imat će veću točnost na ispitnome skupu
 C Model će biti prenaučeni i imat će manju točnost na ispitnome skupu
 D Model će biti podnaučeni, ali imat će veću točnost na ispitnome skupu

- 22 (T) Za procjenu parametara modela GMM (središta grupa $\boldsymbol{\mu}_k$, kovarijacijske matrice Σ_k i koeficijenti mješavine π_k) tipično se koristi algoritam maksimizacije očekivanja (EM-algoritam). Prije pokretanja EM-algoritma, parametre je potrebno inicijalizirati. U praksi se za inicijalizaciju parametara $\boldsymbol{\mu}_k$ koristi algoritam K-sredina. **Koji je očekivani efekt uporabe algoritma K-sredina za inicijalizaciju EM-algoritma?**

A Manja log-izglednost početnih i konačnih parametara te optimalan broj grupa K
 B Veća log-izglednost početnih i konačnih parametara te manje iteracija do konvergencije
 C Manja log-izglednost početnih parametara, ali veća log-izglednost konačnih parametara
 D Veća potpuna log-izglednost konačnih parametara i veće vrijednosti gustoća komponenti

Završni ispit iz Strojnog učenja 1 (ak. god. 2023./2024.)

– NEKORIGIRANA VERZIJA –

Ispit sadrži 22 pitanja i ukupno nosi najviše 20 bodova (za 30% bodova na predmetu). Pitanja nose po 1 bod, a 1/3 boda oduzima se za pogrešan odgovor. Za maksimalan broj bodova dovoljno je točno riješiti 20 pitanja, a višak bodova iznad 20 se zanemaruje. Trajanje ispita je 180 minuta. Primjerak ispita morate predati zajedno sa svojim rješenjima.

Cjelina 4: Procjena parametara i Bayesov klasifikator (8 pitanja)

- 1 (P) Uz određene restrikcije na parametre Gaussovog Bayesovog klasifikatora, Gaussov Bayesov klasifikator i logistička regresija su generativno-diskriminativni par modela. U pravilu, logistička regresija imat će manje parametara od njoj odgovarajućeg modela Gaussovog Bayesovog klasifikatora. Razmotrite slučaj binarne klasifikacije u ulaznome prostoru dimenzije $n = 200$ pomoću modela logističke regresije i njoj odgovarajućeg modela Gaussovog Bayesovog klasifikatora. **Koliko će model Gaussovog Bayesovog klasifikatora imati više parametara od modela logističke regresije?**

A 45450 B 90600 C 20300 D 40400

- 2 (N) Treniramo Bayesov klasifikator za odluku o dobroj destinaciji za Erasmus+ studijski boravak. Skup primjera za učenje, izgrađen na temelju iskustava prijatelja i prijatelja prijatelja, je sljedeći:

i	Država	Stipendija	Semestar	Studij	GovoriJezik	$y^{(i)}$
1	Njemačka	da	ljetni	dipl	da	1
2	Poljska	ne	zimski	preddipl	ne	1
3	Italija	da	ljetni	dipl	da	1
4	Njemačka	ne	zimski	preddipl	ne	0
5	Austrija	da	ljetni	dipl	da	1
6	Poljska	ne	zimski	dipl	ne	1
7	Austrija	da	zimski	dipl	ne	1
8	Njemačka	ne	zimski	dipl	ne	0

Očekujemo zavisnost između varijabli *Država* i *Stipendija*, pa koristimo polunaivan Bayesov klasifikator u kojemu su te dvije varijable združene. Procjene izglednosti klasa radimo Laplaceovim MAP-procjeniteljem. Zanima nas klasifikacija za $\mathbf{x} = (\text{Italija}, \text{ne}, \text{zimski}, \text{preddipl}, \text{ne})$. **Koliko iznosi aposteriorna vjerojatnost $P(y = 1|\mathbf{x})$?**

A 0.588 B 0.488 C 0.741 D 0.322

- 3 (P) Gaussov Bayesov klasifikator koristimo za klasifikaciju jednodimenzijskih podataka u tri klase. Procijenjene izglednosti klasa su $p(x|y = 1) = \mathcal{N}(-10, 2)$, $p(x|y = 2) = \mathcal{N}(2, 2)$ i $p(x|y = 3) = \mathcal{N}(8, 2)$, a procijenjene apriorne vjerojatnosti klasa su $P(y = 1) = P(y = 2) = 2/5$ i $P(y = 3) = 1/5$. Međutim, nakon što smo naučili ovaj model, zaključili smo da na ispitnom skupu postoji pomak u distribuciji podataka u odnosu na skup za učenje te da zbog toga model ne generalizira dobro. Zaključili smo da se ovo može ispraviti tako da se naučeni model malo izmijeni, i to tako da se varijanca izglednosti klase $y = 1$ postavi na 5 i da se apriorne vjerojatnosti klasa ujednače, $P(y = 1) = P(y = 2) = P(y = 3) = 1/3$. Skicirajte gustoće zajedničke vjerojatnosti naučenog i izmijenjenog modela. Neka su h_1 i h_2 MAP-hipoteze prvog i drugog modela, te neka su a i b pozitivne konstante. Razmotrite segment ulaznog prostora za koji vrijedi $-10 \leq x \leq 10$. **Na kojim se dijelovima tog segmenta ulaznog prostora MAP-hipoteze prvog i drugog modela razlikuju?**

A $[-4 - a, -4] \cup [5 - b, 5]$ B $[-4 - a, 5 + b]$ C $[-4 - a, -4 + b]$ D $[-4, -4 + a] \cup [5, 5 + b]$

- 4 (N) Zadan je uzorak kontinuirane slučajne varijable, $\mathcal{D} = \{-10, 5, 6, 2\}$. Pretpostavljamo razdiobu $\mathcal{N}(\mu, \sigma^2)$, čija je gustoća vjerojatnosti:

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

Za procjenu parametra μ koristimo procjenitelj $\hat{\mu}_{MLE}$, a za procjenu parametra σ^2 procjenitelj $\hat{\sigma}_{UB}^2$, koji je nepristran procjenitelj izveden odgovarajućom korekcijom iz procjenitelja $\hat{\sigma}_{MLE}^2$. Izračunajte log-izglednost procijenjenih parametara na skupu \mathcal{D} , tj. $\ln \mathcal{L}(\hat{\mu}_{MLE}, \hat{\sigma}_{UB}^2 | \mathcal{D})$. **Koliko iznosi ta log-izglednost?**

- A -10.832 B -15.200 C -12.873 D -13.163

5 (T) Bayesov klasifikator temelji se na hipotezi *maximum a posteriori* (MAP). Za treniranje Bayesovog klasifikatora možemo koristiti procjenitelj MLE. **Koja je razlika između hipoteze MAP kod Bayesovog klasifikatora i procjenitelja MLE?**

- A Procjenitelj MLE određuje apriornu vjerojatnost klase, a hipoteza MAP maksimizira aposterionu vjerojatnost parametara
 B Hipoteza MAP određuje koju klasu odabrati za primjer, a procjenitelj MLE određuje koju vrijednost odabrati za parametar
 C Procjenitelj MLE primjer klasificira u klasu koja je za njega navjerojatnija, a hipoteza MAP tu odluku kombinira s apriornim znanjem
 D Hipoteza MAP maksimizira aposterionu vjerojatnost parametara, a procjenitelj MLE određuje aposterionu vjerojatnost klase za zadani primjer

6 (T) Polunaivan Bayesov klasifikator može ostvariti veću klasifikacijsku točnost od naivnog Bayesovog klasifikatora u situacijama kada između značajki postoji zavisnost. Jedan način određivanja zavisnosti između značajki temelji se na izračunu Kullback-Leiblerove divergencije (KL-divergencije) između distribucija dviju varijabli. **Koji je princip uporabe KL-divergencije u izgradnji polunaivnog Bayesovog klasifikatora?**

- A Što je manja KL-divergencija između $P(x_1)$ i $P(x_2)$, to su varijable x_1 i x_2 više zavisne, pa je to veća korist od njihovog združivanja u jedan faktor
 B Ako je KL-divergencija između $P(x_1|x_2)$ i $P(x_2|x_1)$ vrlo mala, onda su varijable x_1 i x_2 vrlo zavisne i treba ih odvojiti u zasebne faktore
 C Što je veća KL-divergencija između $P(x_1)P(x_2)$ i $P(x_1, x_2)$, to su varijable x_1 i x_2 manje nezavisne, pa je to veća korist od njihovog združivanja u jedan faktor
 D Ako je KL-divergencija između $P(x_1)P(x_2)$ i $P(x_1, x_2)$ jednaka nuli, onda su varijable linearno zavisne i treba ih odvojiti u zasebne faktore

7 (N) Na skupu označenih primjera u ulaznome prostoru dimenzije $n = 2$ treniramo Gaussov Bayesov klasifikator za klasifikaciju primjera u $K = 2$ klase, uz pretpostavku dijeljene i dijagonalne kovarijacijske matrice. Izglednost klase s oznakom $y = j$ definirana je multivarijantnom Gaussovom gustoćom vjerojatnosti:

$$p(\mathbf{x}|y = j) = \frac{1}{(2\pi)^{n/2} |\Sigma_j|^{1/2}} \exp \left\{ -\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu}_j)^T \Sigma_j^{-1} (\mathbf{x} - \boldsymbol{\mu}_j) \right\}$$

Model treniramo na skupu podataka od $N = 7$ primjera:

$$\mathcal{D} = \{(\mathbf{x}^{(i)}, y^{(i)})\}_i = \{((-4, -2), 0), ((0, 0), 0), ((4, 2), 0), ((3, -1), 1), ((4, -1), 1), ((4, 1), 1), ((5, 1), 1)\}$$

Procijenite parametre modela na ovom skupu primjera. Budući da je skup primjera malen, za procjenu kovarijacijske matrice koristite nepristran procjenitelj. Izlaz modela za klasu $y = j$ neka je zajednička gustoća vjerojatnosti, $h_j(\mathbf{x}) = \ln p(\mathbf{x}, y = j)$. **Koliko iznosi $h_0(\mathbf{x})$ za primjer $\mathbf{x} = (0, 0)$?**

- A -3.84 B -3.03 C -2.75 D -4.13

8 (P) Gausovim Bayesovim klasifikatorom rješavamo problem klasifikacije u $K = 10$ klasa sa $n = 100$ značajki. Prisjetite se da kod Gaussovog Bayesovog klasifikatora uvođenjem odgovarajućih pretpostavki na kovarijacijsku matricu Σ možemo utjecati na broj parametara modela a time onda i na složenost modela. Razmatramo tri modela s kovarijacijskim matricama u koje smo ugradili sljedeće pretpostavke:

\mathcal{H}_1 : Značajke imaju različite varijance, ali iste za sve klase, te nisu korelirane

\mathcal{H}_2 : Značajke nisu korelirane, imaju jednaku varijancu unutar svake klase, no različitu za svaku klasu

\mathcal{H}_3 : Između značajki postoje korelacije, ali se one ne razlikuju između klasa

Neka ‘ \supset ’ označava relaciju “složeniji od”, a neka ‘ $>$ ’ označava relaciju “ima više parametara od”. **Što možemo zaključiti o složenosti i broju parametara za gornja četiri modela?**

- A $\mathcal{H}_3 > \mathcal{H}_2 > \mathcal{H}_1, \mathcal{H}_3 \supset \mathcal{H}_1 \supset \mathcal{H}_2$ C $\mathcal{H}_3 > \mathcal{H}_1 > \mathcal{H}_2, \mathcal{H}_3 \supset \mathcal{H}_1$
 B $\mathcal{H}_1 > \mathcal{H}_2 > \mathcal{H}_3, \mathcal{H}_1 \supset \mathcal{H}_2$ D $\mathcal{H}_1 > \mathcal{H}_3 > \mathcal{H}_2, \mathcal{H}_1 \supset \mathcal{H}_2 \supset \mathcal{H}_3$

Cjelina 5: Probabilistički grafički modeli (5 pitanja)

9 (T) Probabilistički grafički modeli na sažet način prikazuju zajedničku distribuciju n slučajnih varijabli. Ta je distribucija prikazana usmjerenim grafom. Neka graf sadrži čvor označen sa x . Čemu odgovara taj čvor?

- A Distribuciji varijable x uvjetovane vrijednostima varijabli roditeljskih čvorova od x
 B Marginalnoj vjerojatnosti $P(x)$ ili marginalnoj gustoći vjerojatnosti $p(x)$
 C Zajedničkoj vjerojatnosti varijable x i varijabli roditeljskih čvorova od x
 D Distribuciji varijable x uz opažene sve varijable koje varijabli x prethode u topološkom uređaju

10 (N) Razmotrite jednostavnu Bayesovu mrežu koja odgovara faktorizaciji $P(x, y, z, w) = P(z)P(w)P(y|z, w)P(x|y)$. Sve varijable su binarne. Vrijedi $P(z = 1) = 0.1$, $P(w = 1) = 0.2$, $P(x = 1|y = 0) = 0.2$ i $P(x = 1|y = 1) = 0.6$. Tablica uvjetne vjerojatnosti za čvor y je sljedeća:

z	w	$p(y = 1 z, w)$
0	0	0
0	1	0.4
1	0	0.2
1	1	0.7

Postupkom uzorkovanja s odbijanjem uzorkujemo iz aposteriorne distribucije $P(w|x = 0, z = 1)$. Uzorkovanje smo ponovili ukupno $N = 10000$ puta, od čega smo neke vektore morali odbaciti, pa je naš konačni uzorak manji od N . U uzorku neodbačenih vektora, koliko je očekivano više vektora sa $w = 0$ od vektora sa $w = 1$?

- A 472 B 348 C 944 D 596


11 (P) Bayesova mreža ima pet varijabli, s topološkim uređajem v, w, x, y, z . Uz takav uređaj, u mreži vrijede sljedeće uvjetne nezavisnosti:

$$\{v, w\} \perp y | x \quad \{v, x\} \perp z | \{w, y\}$$

Primjenom algoritma d-odvajanja ispitujemo zavisnosti između parova varijabli. Koje od sljedećih tvrdnji o nezavisnosti vrijede u ovoj Bayesovoj mreži?

- A $v \perp z | x$ B $w \perp y | z$ C $x \perp z | y$ D $w \perp y | x$

12 (N) Na slici ispod prikazana je Bayesova mreža za problem prskalice za travu. Varijable su: C (oblačno/*cloudy*), S (prskalica/*sprinkler*), R (kiša/*rain*) i W (mokra trava/*wet grass*). Dane su i tablice uvjetnih vjerojatnosti.



C	$P(S = 1 C)$
0	0.5
1	0.3


C	$P(R = 1 C)$
0	0.2
1	0.8

S	R	$P(W = 1 S, R)$
0	0	0.0
0	1	0.9
1	0	0.1
1	1	0.99

Izračunajte aposteriornu vjerojatnost da radi prskalica ako trava nije mokra i oblačno je.

- A 0.144 B 0.309 C 0.069 D 0.223

13 (P) Na slici ispod prikazana je Bayesova mreža koja odgovara polunaivnom Bayesovom klasifikatoru. Pretpostavite da su značajke x_1 , x_2 i x_3 ternarne varijable te da je oznaka klase y također ternarna varijabla. Označimo ovaj model sa \mathcal{H}_2 . Model \mathcal{H}_2 može se pojednostaviti ako se ukloni brid između varijabli x_2 i x_3 . Označimo takav model sa \mathcal{H}_1 . S druge strane, od modela \mathcal{H}_2 može se napraviti još složeniji model tako da se doda brid između varijabli x_1 i x_2 . Označimo takav model sa \mathcal{H}_3 .



Razmotrite koliko parametara imaju modeli \mathcal{H}_1 , \mathcal{H}_2 i \mathcal{H}_3 . Koliko model \mathcal{H}_2 ima više parametara od modela \mathcal{H}_1 , a koliko manje parametara od modela \mathcal{H}_3 ?

- A 12 više, 12 manje B 8 više, 8 manje C 4 više, 4 manje D 12 više, 8 manje

Cjelina 6: Grupiranje i vrednovanje modela (9 pitanja)

- 14 (P) Skup neoznačenih primjera u dvodimenzijaskome ulaznom prostoru neka je sljedeći:

$$\mathcal{D} = \{\mathbf{x}^{(i)}\}_i = \{(1, 1), (1, 3), (1, 4), (3, 4)\}$$

Primjere grupiramo u $K = 2$ grupe algoritmom K-means++. Konačna vrijednost funkcije pogreške J bit će različita za različita pokretanja algoritma. Razmotrite sve moguće konačne vrijednosti funkcije J , tj. vrijednosti funkcije J nakon što se algoritam K-means++ zaustavi. **Koliko iznosi maksimalna moguća konačna vrijednost funkcije J ?**

- A 11/2 B 10/3 C 14/3 D 4

- 15 (P) Raspoložemo sa 750 označenih primjera. Na tom skupu treniramo i vrednujemo algoritam SVM, optimizirajući hiperparametre C i γ . Za vrednovanje koristimo ugniježđenu unakrsnu provjeru sa 5 preklopa u vanjskoj petlji i 5 preklopa u unutarnjoj petlji. To znači da za svaku kombinaciju vrijednosti hiperparametara C i γ treniramo pet modela. Ti modeli trenirani su na skupovima za učenje koji nisu disjunktne: svaki par treniranih modela dijele određeni broj primjera za učenje. Izračunajte koliko primjera za učenje dijele svaki par modela koje treniramo u unutarnjoj petlji ugniježđene unakrsne provjere. **Za koliko bi taj broj narastao kada bismo broj preklopa u unutarnjoj petlji povećali na 10?**

- A 120 B 60 C 144 D 75

- 16 (N) Algoritmom hijerarhijskog aglomerativnog grupiranja (HAC) grupiramo $N = 5$ primjera. Za grupiranje koristimo mjeru sličnosti, definiranu sljedećom matricom:

$$\begin{pmatrix} 1.0 & 0.2 & 0.6 & 0.7 & 0.4 \\ 0.2 & 1.0 & 0.3 & 0.3 & 0.7 \\ 0.6 & 0.3 & 1.0 & 0.9 & 0.5 \\ 0.7 & 0.3 & 0.9 & 1.0 & 0.4 \\ 0.4 & 0.7 & 0.5 & 0.4 & 1.0 \end{pmatrix}$$

Provedite grupiranje algoritmom HAC s potpunim povezivanjem. Pritom u svakoj iteraciji bilježite na kojoj razini sličnosti se odvija stapanje dviju grupa. **Koliko iznosi zbroj po svim razinama sličnosti na kojima se odvija stapanje grupa?**

- A 1.9 B 2.4 C 2.0 D 1.8

- 17 (P) Podatke u dvodimenzijaskome ulaznom prostoru ($n = 2$) grupiramo u dvije grupe ($K = 2$) algoritmom Gaussove mješavine (GMM). Skup podataka je sljedeći:

$$\mathcal{D} = \{\mathbf{x}^{(i)}\}_{i=1}^8 = \{(-2, -2), (-2, -1), (-1, -2), (-1, -1), (1, 2), (3, 1), (3, 3), (5, 2)\}$$

Razmatramo dva modela: \mathcal{H}_1 i \mathcal{H}_2 . Oba modela koriste punu kovarijacijsku matricu, međutim kod modela \mathcal{H}_1 kovarijacijska matrica nije dijeljena, dok je kod modela \mathcal{H}_2 kovarijacijska matrica dijeljena. Za svaki model razmotrite ono grupiranje koje maksimizira log-izglednost na skupu \mathcal{D} . Neka je $p_j(\mathbf{x}^{(i)}|y = k)$ izglednost grupe $y = k$ za primjer $\mathbf{x}^{(i)}$ prema modelu \mathcal{H}_j . Oznake grupa su $y = 1$ i $y = 2$, te pretpostavite da je grupiranje takvo da vrijedi $\|\mu_1\| > \|\mu_2\|$. **Što od sljedećega vrijedi?**

- A $p_2(\mathbf{x}^{(1)}|y = 2) > p_1(\mathbf{x}^{(2)}|y = 2)$ C $p_2(\mathbf{x}^{(4)}|y = 2) > p_1(\mathbf{x}^{(3)}|y = 2)$
 B $p_2(\mathbf{x}^{(6)}|y = 1) < p_1(\mathbf{x}^{(7)}|y = 1)$ D $p_2(\mathbf{x}^{(8)}|y = 1) < p_1(\mathbf{x}^{(5)}|y = 1)$

- 18 (N) Particijskim algoritmom grupiranja grupiramo $N = 1000$ primjera. Na temelju znanja o problemu zaključili smo da bi primjeri trebali formirati $K = 3$ grupe, pa smo s tim brojem grupa proveli grupiranje. Kako bismo evaluirali točnost grupiranja, slučajnim odabirom smo iz skupa primjera uzorkovali 10 primjera, ručno smo označili primjere iz tog uzorka, i zatim na tom uzorku računamo Randov indeks. Označavanje smo proveli tako da smo svakom primjeru iz uzorka dodijelili oznaku točne grupe. Oznake grupe dobivene algoritmom grupiranja y_{pred} i oznake točnih grupa y_{true} za svih deset primjera u uzorku su sljedeće:

i	1	2	3	4	5	6	7	8	9	10
$y_{pred}^{(i)}$	0	1	2	1	1	0	0	2	1	2
$y_{true}^{(i)}$	1	0	0	2	1	0	2	1	0	1

Koliko iznosi Randov indeks grupiranja izračunat na ovom uzorku?

- A 0.53 B 0.58 C 0.49 D 0.62

- 19** (T) Kod vrednovanja algoritma strojnog učenja važno je da vrednujemo model optimalne složenosti. Zbog toga označeni skup podataka dijelimo na tri disjunktne podskupa: skup za učenje, skup za provjeru i ispitni skup. Za odabir modela (tj. optimizaciju hiperparametara) koristimo skup za učenje i skup za provjeru, dok točnost optimalnog modela ispitujemo na ispitnome skupu. Zamislite da smo zaboravili upotrijebiti skup za provjeru: umjesto toga hiperparametre modela optimirali smo na skupu za učenje, a model smo potom ispitali na ispitnom skupu. **U odnosu na to da smo pravilno proveli vrednovanje algoritma, što možemo očekivati u ovom slučaju?**
- A Model će biti prenaučen i imat će manju točnost na ispitnome skupu
- B Model će biti prenaučen, ali imat će veću točnost na ispitnome skupu
- C Model će biti podnaučen, ali imat će veću točnost na ispitnome skupu
- D Model će biti optimalne složenosti i imat će veću točnost na ispitnome skupu
- 20** (T) Za procjenu parametara modela GMM (središta grupa μ_k , kovarijacijske matrice Σ_k i koeficijenti mješavine π_k) tipično se koristi algoritam maksimizacije očekivanja (EM-algoritam). Prije pokretanja EM-algoritma, parametre je potrebno inicijalizirati. U praksi se za inicijalizaciju parametara μ_k koristi algoritam K-sredina. **Koji je očekivani efekt uporabe algoritma K-sredina za inicijalizaciju EM-algoritma?**
- A Veća log-izglednost početnih i konačnih parametara te manje iteracija do konvergencije
- B Manja log-izglednost početnih parametara, ali veća log-izglednost konačnih parametara
- C Veća potpuna log-izglednost konačnih parametara i veće vrijednosti gustoća komponenti
- D Manja log-izglednost početnih i konačnih parametara te optimalan broj grupa K
- 21** (N) Vrednujemo višeklasni klasifikator koji koristimo kao referentni model za vrednovanje drugih klasifikatora. Klasifikator nasumično dodjeljuje oznake za tri klase ($K = 3$), i to prema distribuciji oznaka na skupu za učenje. Skup za učenje sadrži 100 primjera sa 35, 60 i 5 primjera u prvoj, drugoj odnosno trećoj klasi. S druge strane, ispitni skup sadrži 50 primjera, od kojih je po 20 u prvoj i drugoj klasi, a 10 u trećoj klasi. **Koliko iznosi očekivana makro-F1 vrijednost nasumičnog klasifikatora na ispitnome skupu?**
- A 0.3111 B 0.2156 C 0.2085 D 0.2989
- 22** (T) Algoritam K-sredina iterativno smanjuje vrijednost funkcije pogreške J . Neovisno o broju grupa K , algoritam uvijek konvergira (završava s izvođenjem). Međutim, konačna vrijednost funkcije pogreške J može se razlikovati između dva pokretanja algoritma s istim brojem grupa K . **Zašto?**
- A Zbog izotropnosti kovarijacijskih matrica Σ_k
- B Zbog nelinearnosti granice između K grupa
- C Zbog razlike u početnim središtima μ_k
- D Zbog loše odabrane vrijednosti za broj grupa K

Grupa	1	2	3	4	5	6	7	8	9	0	1	1	1	1	1	1	1	1	1	1	1	2	2	
A	D	C	C	D	B	D	B	A	A	B	B	B	C	B	A	D	B	B	A	B	A	A		
B	A	D	D	B	C	B	A	C	A	C	A	C	B	C	C	A	B	D	B	A	D	A		
C	B	D	D	B	B	C	B	D	B	A	D	A	A	B	B	A	C	D	A	B	D	D		
D	B	B	D	D	A	B	C	A	C	B	A	D	A	A	C	C	D	C	B	B	A	C		
E	B	B	B	B	D	C	C	D	D	C	B	D	C	A	A	B	C	B	A	C	C	D		
F	C	D	C	B	A	D	A	B	B	A	C	D	A	B	A	A	D	D	B	B	B	B		
G	B	B	A	C	D	C	D	A	D	B	C	C	D	C	D	D	A	B	A	C	C	B		
H	C	D	D	D	B	C	D	C	A	A	D	D	A	C	A	B	D	A	A	A	A	C		