

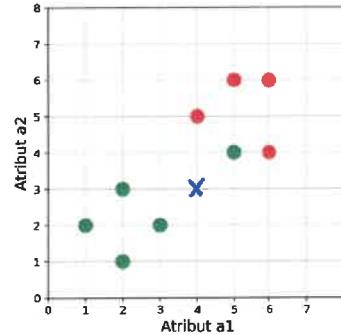
Odgovarjajte kratko in jedrnato, točno na zastavljena vprašanja. Vse odgovore pišite na črto pod vprašanji in izključno na ta list, ki ga edinega oddate na koncu! Čas pisanja: 45 minut.

(1)

Na sliki je podanih devet primerov, ki so opisani z dvema atributoma, a_1 in a_2 , barva pa označuje njihov razred. Za klasifikacijo teh primerov uporabljamo algoritem k-NN, pri čemer parameter k nastavimo na 1, uporabljamo pa evklidsko razdaljo.

- (a) Za oceno klasifikacijske točnosti uporabljamo 3-kratno prečno preverjanje. Ob tem so podatki razdeljeni v tri podmnožice takole: $\{(a_1=1, a_2=2), (3,2), (6,6)\}$, $\{(2,1), (5,4), (5,6)\}$ in $\{(2,3), (4,5), (6,4)\}$. Kakšna je tako ocenjena klasifikacijska točnost, če se primer $(a_1=4, a_2=5)$ označi za rdečega?

$$100\% \quad 2/3, 2/3; \text{ odg: } 7/9 = 78\%$$



- (b) Zdaj pa za oceno kvalitete napovedi uporabljamo metodo izpusti enega (leave-one-out). Pri tem se zgodi, da se primer $(a_1=4, a_2=5)$ označi za rdečega. Kakšna je tako ocenjena klasifikacijska točnost? Kaj pa priklic za zeleni razred?

$$\text{klasifikacijska točnost: } 7/8 = 87.5\% \quad \text{priklic (zelen): } 4/5 = 80\%$$

- (c) Kako bi ta algoritem klasificiral primer $(a_1=4, a_2=3)$ pri $k=1$? Kaj pa pri $k=5$ in navadnem glasovanju?

$$k=1: \text{ zelen} \quad k=5: \text{ zelen}$$

(2)

Sedaj na sliki iz prve naloge zgoraj zanemarimo barvo, torej za naše primere nimamo podatka o razredu. Tako se soočimo s problemom nenadzorovanega učenja. Lotimo se ga s pomočjo algoritma k-voditeljev (k-means). Tudi tu uporabljamo evklidsko razdaljo.

- (a) Začetni točki dveh ($k=2$) centroidov sta $(1,3)$ in $(5,4)$. Kakšni sta njuni končni koordinati?

$$c_1: (2, 2) \quad c_2: (5 \frac{1}{5}, 5)$$

- (b) V katero gručo bi model zgrajen v nalogi (a) uvrstil primer $(a_1=4, a_2=3)$?

V gručo C1 (blizej je centroid s koordinato (2,2))

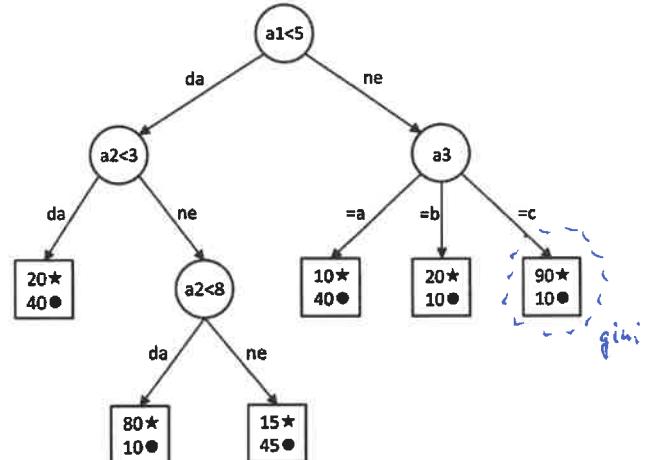
- (c) Recimo, da nam domenski ekspert pove, da primer $(6,4)$ spada v rdeč razred, primer $(2,3)$ pa v zelen razred. Ostale primere iz iste gruče (vsak je v eni) kot sta označena primera po principu delno nadzorovanega učenja (semi-supervised learning) »pobarvamo« z isto barvo kot dana primera. Tako imamo pred seboj spet problem nadzorovanega učenja. A bodimo pozorni, pravilne barve razredov so takšne kot so na sliki zgoraj!

Kam bi algoritem 5-NN uvrstil primer $(a_1=4, a_2=3)$? Kakšna bi bila ocenjena klasifikacijska točnost tega algoritma (5-NN) ob uporabi metode izpusti enega? Algoritem uporablja navadno glasovanje.

$$(4,3) \text{ se uvrsti kot: rdeč} \quad \text{klasifikacijska točnost: } 8/9$$

(3)

Podano je odločitveno drevo, ki ločuje črne luknje (●) od (ostalih) zvezd (★) na podlagi treh atributov. V listih drevesa na desni so podane tudi frekvence učnih primerov, ki pripadajo dani veji. List napove tisti razred, ki ima v njem večino.



1 (a) Izračunajte gini nečistočo v listu veje $a1 \geq 5$ in $a3 = 'c'$.

$$G = 1 - \left(\frac{20}{40} \right)^2 + \left(\frac{90}{100} \right)^2 = 0,18$$

1 (b) Kateri izmed treh atributov je v tem modelu najpomembnejši?

a1, atribut v korenju drevesa

2 (c) Kako bi podano odločitveno drevo klasificiralo naslednjih osem primerov 1: $<a1=3, a2=2, a3=c>$, 2: $<4,5,a>$, 3: $<6,5,b>$, 4: $<6,2,a>$, 5: $<1,9,b>$, 6: $<8,8,a>$, 7: $<8,3,c>$, 8: $<7,1,b>$?

Po vrsti (1-8): 0, ★, ★, 0, 0, 0, ★, ★

1 (d) Resnične vrednosti razredov za primere iz naloge (c) so po vrsti [●, ●, ★, ●, ★, ●, ★, ★]. Kakšna je vrednost AUROC, torej ploščine pod ROC krivuljo gledano s strani razreda ★?

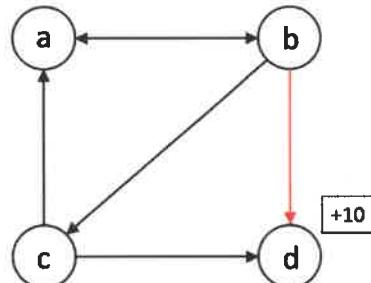
Napovedi urejimo po verjetnosti, da je ★ (privor 1 je npr. 33%, da je ★). AUROC = \frac{12}{16} = 75\%

1 (e) V kateri točki koordinatnega sistema (x,y) smo, ko narišemo prvih pet primerov na ROC krivuljo? Koordinati x in y izrazite v odstotkih!

x = 50\%, y = 75\%

(4)

Na sliki je podan preprost svet, ki se ga naš agent uči s pomočjo spodbujevanega učenja (reinforcement learning). Stanja so označena s črkami a-d, možne akcije v stanjih predstavljajo puščice. Tako je npr. v stanju b možno izbrati akcije »pojdij v a«, »pojdij v c« ali »pojdij v d«. Stanje d je končno, tam agent dobi nagrado +10 točk. Vse akcije so deterministične, edina izjema je označena z rdečo puščico. Tukaj se v tretjini primerov res zgodi akcija »pojdij v d«, v preostalih primerih pa se preprosto ne zgodi nič. Pri spodnjih vprašanjih konkretno napišite kako bi agent ravnal v stanjih b in c (pri a in d seveda nima izbire).



1 (a) Katere (optimalne) strategije se nauči naš agent, če ob vsaki akciji dobi še nagrado -1, tudi ob prehodih v končno stanje in tudi, če se po akciji ne zgodi nič?

b: pojdi v c, c: pojdi v d (strategija: čim hitrej na cilj)

1 (b) Kaj pa, če ob vsakem prehodu dobi nagrado +1?

b: a ali c (useeno), c: pojdi v a (strategija: nikoli ne končaj)

1 (c) Sedaj pa agent ob nobeni akciji ne dobi nagrade (izjema je +10, ko doseže stanje d). Ob tem se uči tako, da ima parameter γ (discount factor) nastavljen na 0,99. Katere strategije se agent nauči?

Funkne strategije kot v nalogi (a).