

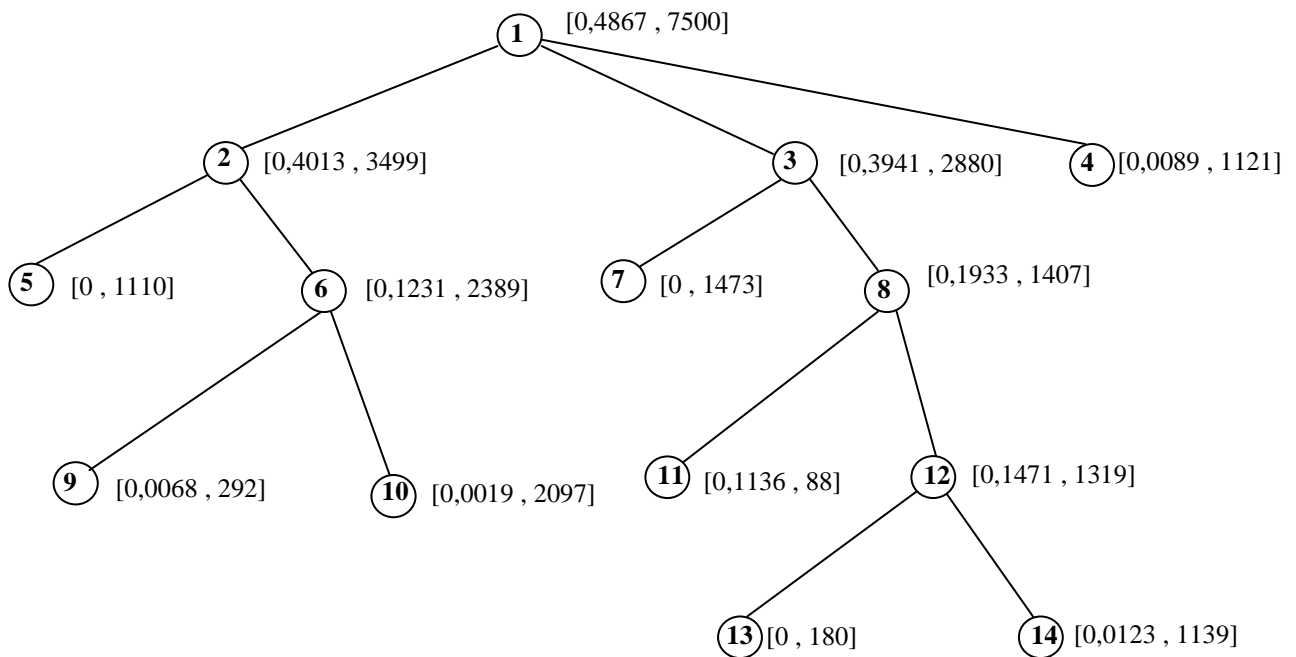
16:15 - 17:35 (80 perc !)

Minden válaszhoz rövid, de áttekinthető indoklást is kérek! Mindkét részből el kell érni a 40-40 %-ot!

Név (nyomatott betűvel):.....Neptun-kód:.....

Aláírás:.....

1. Az alábbi ábrán egy 7500 minta alapján tanítással előállított döntési fa látható (A gyökér csomópontban a C_1 osztályhoz 3650 minta tartozott, a C_2 osztályhoz 3850). A csomópontok mellett 2 szám látható egymás mellett szögletes zárójelben, ez az adott csomópontban mérhető hibaarány, illetve az összes idejuto tanítóminták száma.



- A. Mekkora lesz az információnyereség az 1-es csomópont tesztje nyomán? **(5 pont)**
 - B. A χ^2 szignifikancia vizsgálat alapján megérte-e elvégezni a tesztet az 1-es csomópontban? **(5 pont)**
 - C. Az 1-es csomópontban mekkora az ábrán látható teszt eredményeképp kialakuló *információ nyereség arány*? **(5 pont)**
2. Kétsztályos (bináris) osztályozási feladatot oldunk meg. 17 paramétert mértünk minden mintán, és egy olyan 17 bemenetű, 1 kimenetű eszközt tanítunk, amelynek 8, a tanítás során állítható paramétere van. Ezek közül 4 paraméter a $\{-4,-2,-1,0,1,2,4\}$ értékeket veheti fel, a másik 4 paraméter viszont csak a $\{-1,0,1\}$ értékeket.

Az a piaci igény, hogy legalább 97%-os pontosságot érjen el az eszközünk, az ésszerű kockázatvállaláshoz ezt legalább 95% biztonsággal kell tudnunk garantálni. Az eszközünket 300 mintán tanítottuk, ezen 100% pontosságot ért el. Elég-e ez ahhoz, hogy a megfelelő biztonsággal vállaljuk a kívánt pontosságot? **(5 pont)**

3. Szakértő együtteseknél az a célunk, hogy egymástól minél inkább különböző, de minél pontosabb szakértőket hozzunk létre. Milyen módokon próbáljuk elérni, hogy a szakértőink különbözőek legyenek? **(3 pont)**
4. Egy osztályozásra használt eszközt turbózással (adaboost) javítunk. A kiinduló mintahalmazunkat az első, kiinduló eszköz így osztályozta (C_i az i -edik bemeneti minta valós osztálybasorolása, Y_i az i -edik bemeneti mintának az eszközünk által adott osztálybasorolása):

i	1	2	3	4	5	6	7	8	9
C_i	+1	+1	-1	+1	+1	-1	-1	-1	+1
Y_{li}	+1	+1	+1	+1	-1	-1	-1	-1	-1

A. Hogyan kell súlyoznunk a mintákat a következő neuronháló tanításához? Ha az algoritmusunk nem tud közvetlenül mintasúlyokkal dolgozni (pl. egy tipikus MLP neuronháló), akkor hogyan oldhatjuk meg, hogy mégis két tizedesjegy pontossággal figyelembe vegyük a minták súlyait? **(4 pont)**


B. Tegyük fel, hogy a turbózás során kapott második eszköz által adott eredmény:

i	1	2	3	4	5	6	7	8	9
C_i	+1	+1	-1	+1	+1	-1	-1	-1	+1
Y_{2i}	+1	+1	-1	+1	-1	-1	-1	-1	-1

Rajzolja fel a kialakuló eredő rendszert, amennyiben e két háló kialakítása után befejezzük a turbózási eljárást! Adja meg az egyes hálókhoz tartozó súlyokat! **(2 pont)**


5. Egy 2 bemenetű 1 kimenetű MOE struktúrában *lineáris* kapuzó hálózatot és két *lineáris* szakértőt használunk. A szakértők paraméterei rendre $\theta_1=[0 \ -0,3 \ 0,2]^T$, $\theta_2=[0.1 \ 0.2 \ -0.2]^T$. Az *első* paraméter tartozik az eltoláshoz. A kapuzó hálózat megfelelő paramétervektorai $v_1=[1 \ 0 \ 0]^T$, $v_2=[0 \ 1 \ 1]^T$, itt is az *első* paraméter tartozik az eltoláshoz. A tanítás során a két szakértő kimenetéhez nem Gauss zajt asszociálunk, hanem a következő sűrűségfüggvénnyel rendelkező zajt:

$$P(y - \mu) = \begin{cases} \cos(y - \mu)/2 & \text{ha } -\pi/2 \leq (y - \mu) \leq \pi/2 \\ 0 & \text{különben} \end{cases}$$



- A. Adja meg a MOE struktúra kimeneti jelét, ha a bemeneti vektor $x = [+1 \ 0]^T$! **(2 pont)**
- B. Adja meg a második szakértő paramétervektorának új értékét, miután egy lépésben tanítottunk az $y^{(\ell)} = 0,3 \ x^{(\ell)} = [+1 \ 0]^T$ mintával! (A tanítás során a bátorsági faktor 0,1). **(4 pont)**

6. Egy szekvenciális döntési problémában 3 állapot alkotja az állapotteret, S_3 a végállapot. Minden állapotban kétféle cselekvés (a_1 és a_2) közt választhatunk. Az alábbi baloldali ábrán láthatók az a_1 -hez tartozó állapot-átmenet valószínűségek, a jobboldali ábrán az a_2 cselekvéshez tartozók. A leszámítási tényező $\gamma=0,1$. A $T(s \rightarrow s', a_i)$ állapot-átmenet valószínűségeket a következő két táblázat tartalmazza:



Az egyes állapotokhoz tartozó jutalmak $R(S_1) = - 1$; $R(S_2) = +0,4$; $R(S_3)=+2$. Értékiterációs algoritmust alkalmazunk, a kiinduló hasznosságok $U_0(S_1) = U_0(S_2) = 0$, $U_0(S_3)= R(S_3)= 2$. Mi lesz a következő két (első és második) iterációs ciklusban az S_2 állapothoz tartozó hasznosság kiszámított értéke? **(5 pont)**

Jó munkát !

Megadott paraméterek, használható összefüggések

χ^2 táblázat

SzF	$P_{0,5}$	$P_{0,2}$	$P_{0,1}$	$P_{0,05}$	$P_{0,01}$	$P_{0,005}$	$P_{0,001}$
1	0,46	1,64	2,71	3,84	6,64	7,88	10,83
2	1,39	3,22	4,61	5,99	9,21	10,60	13,82
3	2,37	4,64	6,25	7,82	11,35	12,84	16,27
4	3,36	5,99	7,78	9,49	13,28	14,86	18,47
5	4,35	7,29	9,24	11,07	15,09	16,75	20,52
6	5,35	8,56	10,65	12,59	16,81	18,55	22,46
7	6,35	9,80	12,02	14,07	18,48	20,28	24,32
8	7,34	11,03	13,36	15,51	20,09	21,96	26,12
9	8,34	12,24	14,68	16,92	21,67	23,59	27,88
10	9,34	13,44	15,99	18,31	23,21	25,19	29,59

$$I(P(v_1), \dots, P v_K) = - \sum_{i=1}^K P(v_i) \cdot \log_2(P(v_i))$$

$$M(A) = \sum_{i=1}^N \frac{n_{i,1} + \dots + n_{i,N}}{n_1 + \dots + n_N} \cdot I(P(v_{i1}), \dots, P(v_{iK}))$$

$$D = \sum_{i=1}^k \left(\frac{(p_i - \hat{p}_i)^2}{\hat{p}_i} + \frac{(n_i - \hat{n}_i)^2}{\hat{n}_i} \right)$$

$$R(T_n) + \alpha \cdot |T_n| = R(\{T_n\}) + \alpha \cdot |\{T_n\}|$$

$$\Pr(y(\mathbf{x}_{teszt}) \neq d_{teszt}) \leq \Pr(y(\mathbf{x}_{tanító}) \neq d_{tanító}) + O\left(\sqrt{\frac{Td_{VC}}{N}}\right)$$

$$U^\pi(s) = R(s) + \gamma \max_a \sum_{s'} T(s, a, s') U^\pi(s')$$

$$\pi^*(s) = \arg \max_a \sum_{s'} T(s, a, s') U(s')$$

$$\frac{1}{\epsilon} (\ln(|H|) - \ln(\delta)) \leq N$$

$$\epsilon_t = \sum_{\substack{i=1 \\ y_t(\mathbf{x}_i) \neq d_i}}^N D_t(i)$$

$$\alpha_t = \frac{1}{2} \ln\left(\frac{1 - \epsilon_t}{\epsilon_t}\right)$$

$$D_{t+1}^*(i) = \begin{cases} D_t(i) \cdot \exp(-\alpha_t) & \text{ha } y_t(\mathbf{x}_i) = d_i \\ D_t(i) \cdot \exp(+\alpha_t) & \text{ha } y_t(\mathbf{x}_i) \neq d_i \end{cases}$$

$$D_{t+1}(i) = \frac{D_{t+1}^*(i)}{\sum_{k=1}^N D_{t+1}^*(k)}$$

$$y(\mathbf{x}) = \text{sign}\left(\sum_{t=1}^T \alpha_t y_t(\mathbf{x})\right)$$

$$m(\mathbf{x}_k, d_k) = \frac{d_k \sum_t \alpha_t y_t(\mathbf{x}_k)}{\sum_t \alpha_t}$$

$$\Pr(y(\mathbf{x}_{teszt}) \neq d_{teszt}) \leq \Pr(|m(\mathbf{x}_{tanító}, d)| \leq \theta) + O\left(\sqrt{\frac{d_{VC}}{N\theta^2}}\right)$$

$$\Pr(y(\mathbf{x}) \neq d) \leq \prod_t [2 \sqrt{\epsilon_t(1 - \epsilon_t)}] = \prod_t \sqrt{1 - 4\gamma_t^2} \leq e^{-2\sum_t \gamma_t^2}$$

$$\Pr(y(\mathbf{x}) \neq d) \leq e^{-2T\gamma^2}$$

$$y = \mu = \sum_{k=1}^K g_k \mu_k$$

$$g_i^{(\ell)} = \frac{e^{f_i(\mathbf{v}_i^T \mathbf{x}^{(\ell)})}}{\sum_{k=1}^K e^{f_k(\mathbf{v}_k^T \mathbf{x}^{(\ell)})}}$$

$$h_i^{(\ell)} = \frac{g_i^{(\ell)} P(y^{(\ell)} | \mathbf{x}^{(\ell)}, \Theta_i)}{\sum_j g_j^{(\ell)} P(y^{(\ell)} | \mathbf{x}^{(\ell)}, \Theta_j)}$$

$$\frac{\partial L}{\partial \mu_i} = \frac{g_i^{(\ell)}}{\sum_j g_j^{(\ell)} P(y^{(\ell)} | \mathbf{x}^{(\ell)}, \Theta_j)} \cdot \frac{\partial}{\partial \mu_i} P(y^{(\ell)} | \mathbf{x}^{(\ell)}, \Theta_i)$$

$$\frac{\partial L}{\partial \Theta_i} = h_i^{(\ell)} \cdot \frac{(y^{(\ell)} - \mu_i^{(\ell)}) \mathbf{x}^{(\ell)}}{\sigma_i^2}$$

$$\frac{\partial L}{\partial \mathbf{v}_i} = (h_i^{(\ell)} - g_i^{(\ell)}) \cdot \mathbf{x}^{(\ell)}$$