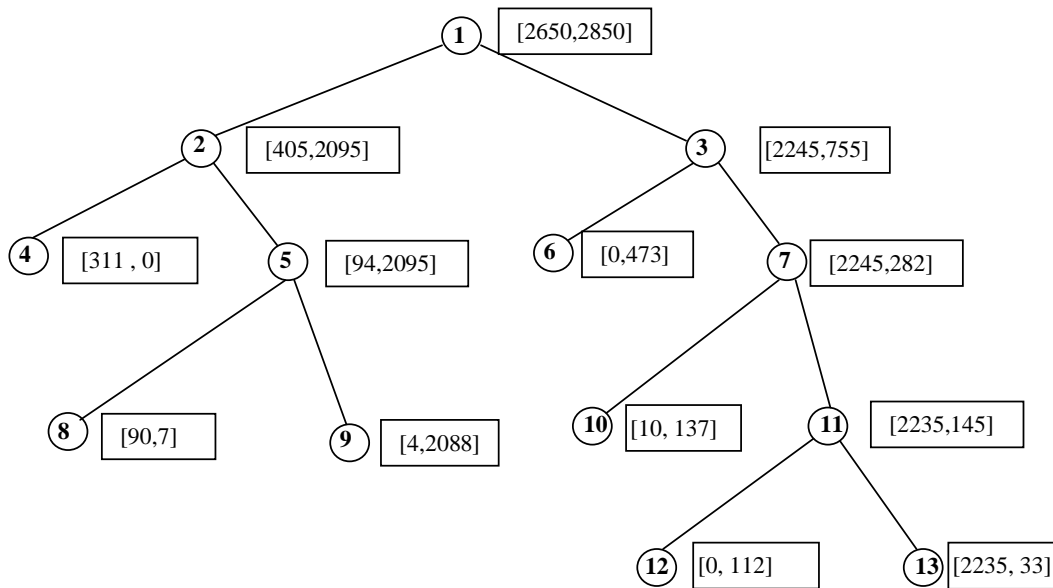


Minden válaszhoz rövid, de áttekinthető indoklást is kérek, kivéve az IGAZ/HAMIS feleletválasztós kérdéseket (2. feladat)! A megfelelt szint: 40%.

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

Alíírás:.....

1. Az alábbi ábrán egy 5500 minta alapján tanítással előállított döntési fa látható. A csomópontok mellett 2 szám látható egymás mellett bekeretezve szögletes zárójelben, ez a C_1 , illetve C_2 osztályba jutó tanítóminták száma az adott csomópontban.



- A. Mekkora lesz az információnyereség az 2-es csomópont tesztje nyomán? **(5 pont)**
- B. Két kollégánk fogadott, hogy az 2-es vagy a 7-es csomópontot kell-e előbb bezárni, ha a hibaarány-komplexitás kompromisszumon alapuló becslést használjuk. A komplexitást a levelek számával mérjük. Melyiküknek lesz igaza? **(3 pont)**
2. **a.** Kétbemenetű lineáris eszközünk öt paraméterrel rendelkezik, a paraméterek csak a 0, +1 vagy +2 értékeket vehetik fel, ezért ennek az eszköznek a VC dimenziója kisebb mint 5. **a. Igaz Hamis**
- b.** Egy bináris osztályozási feladatnál a $P(d^{(tanító)} \neq y^{(tanító)})$ valószínűség az általánosító képességet adja meg. **b. Igaz Hamis**
- c.** A mintatér minden előzetes ismeret nélküli részekre bontása is segíthet egy bonyolult probléma egyszerűbb részfeladatokra való dekomponálásánál. **c. Igaz Hamis**
- d.** Egy döntési fa csomópontjában elvégzett attribútum vizsgálat relevanciáját nézzük meg χ^2 teszttel. A döntési fában elvégzett attribútum vizsgálat akkor releváns, ha a χ^2 tesztben kiszámított valószínűségi változó nulla közelében van (kisebb egy adott limitnél). **d. Igaz Hamis**
- e.** Ha 10-bemenetű (egy kimenetű) logikai függvényt megvalósító eszközt tanítunk, akkor a hipotézistér mérete $2^{10}=1024$. **e. Igaz Hamis**
- f.** Két döntési fa készült ugyanazon problémára. A két fa *különböző attribútumokat* tesztl, de ettől még lehetnek konzisztensek ugyanazzal a mintahalmazzal. **f. Igaz Hamis**

(≤ 3 jó válasz **0 pont**, $<$ jó válasz **(jó válaszok száma-3) pont**, 6 jó válasz **3 pont**)

3. 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 $\mathbf{v}_1=[2 \ 0 \ 0]^T$, $\mathbf{v}_2=[1 \ 0 \ 1]^T$, itt is az *első* paraméter tartozik az eltoláshoz. A tanítás során a két szakértő kimenetéhez nulla várhatóértékű Gauss zajt asszociálunk, az egyes szórások rendre $\sigma_1=0,5$ és $\sigma_2=2$.
- 3.A** Adja meg a MOE struktúra kimeneti jelét, ha a bemeneti vektor $\mathbf{x} = [+1 \ -1]^T$! **(2 pont)**
- 3.B** Adja meg a kapuzó hálózat paramétervektorainak új értékét, miután egy lépésben tanítottuk az $\mathbf{x}^{(\ell)} = [+1 \ -1]^T$, $y^{(\ell)} = -0,2$ mintával! (A tanítás során a bátorsági faktor 0,05). **(4 pont)**
4. Egy bináris osztályozási problémát Adaboost eljárással akarunk megoldani. Matematikus barátunk bebizonyította, hogy a felhasznált alap eljárás az adott probléma bármelyik mintahalmazára, bármilyen – az Adaboostban használt – súlyozás esetén legfeljebb 48% osztályozási hibát vét. Hány turbózási lépést hajtsunk végre, hogy az eredő eszközzel az 57 313 876 tanítómintán biztosan elérjünk 90% pontosságot? **(5 pont)**
5. 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)**

Jó munkát !

A pótzárthelyin használható összefüggések

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

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

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

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

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

$$h(\mathbf{x}) = \text{sign}\left(\sum_{t=1}^T \alpha_t h_t(\mathbf{x})\right) \quad \alpha_t = \frac{1}{2} \ln\left(\frac{1 - \varepsilon_t}{\varepsilon_t}\right)$$

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

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

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

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

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

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

$$\Pr(h(\mathbf{x}_{\text{teszt}}) \neq d) \leq \Pr(h(\mathbf{x}_{\text{tanító}}) \neq d) + O\left(\sqrt{\frac{T d_{\text{VC}}}{N}}\right)$$

$$m(\mathbf{x}_k, d_k) = \frac{d_k \sum_t \alpha_t h_t(\mathbf{x}_k)}{\sum_t \alpha_t} = \frac{d_k \cdot h'(\mathbf{x}_k)}{\sum_t \alpha_t}$$

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

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

$$\frac{\partial L}{\partial \Theta_i} = h_i^{(\ell)} \cdot \frac{(y^{(\ell)} - \mu_i^{(\ell)}) \mathbf{x}^{(\ell)}}{\sigma_i^2} \quad \text{Gauss eloszlású asszociált zaj, lineáris szakértő}$$

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

$$E\{z_i^{(\ell)}(t+1)\} = \hat{P}(i|x^{(\ell)}, \boldsymbol{\theta}(t+1)) = \frac{\frac{1}{\hat{\sigma}_i(t)} e^{-\frac{(x^{(\ell)} - \hat{\mu}_i(t))^2}{2 \cdot \hat{\sigma}_i(t)^2}} \hat{P}_i(t)}{\sum_{j=1}^K \frac{1}{\hat{\sigma}_j(t)} e^{-\frac{(x^{(\ell)} - \hat{\mu}_j(t))^2}{2 \cdot \hat{\sigma}_j(t)^2}} \hat{P}_j(t)}$$

$$\hat{\mu}_i(t+1) = \frac{\sum_{\ell=1}^L E\{z_i^{(\ell)}(t+1)\} \cdot x^{(\ell)}}{\sum_{\ell=1}^L E\{z_i^{(\ell)}(t+1)\}}$$

$$\hat{\sigma}_i(t+1)^2 = \frac{\sum_{\ell=1}^L E\{z_i^{(\ell)}(t+1)\} \cdot (x^{(\ell)} - \hat{\mu}_i(t+1))^2}{\sum_{\ell=1}^L E\{z_i^{(\ell)}(t+1)\}}$$

$$\hat{P}_i(t+1) = \frac{1}{L} \sum_{\ell=1}^L \hat{P}(i|x^{(\ell)}, \boldsymbol{\theta}(t+1)) = \frac{1}{L} \sum_{\ell=1}^L E\{z_i^{(\ell)}(t+1)\}$$

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