

**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:.....

Aláírás:.....

1. **1.A** Egy 2-dimenziós (bemeneti paraméterek:  $x_1, x_2$ ) háromosztályos osztályozási feladatot úgy oldottunk meg, hogy kétosztályos részfeladatokat tanítunk, és a részproblémák megoldásait integráljuk. Rajzolja fel a szakértőkből álló moduláris megoldást, a végső eredményt adó rendszerintegráló blokkokkal együtt! **(3 pont)**
  - 1.B** Adja meg, hogy a harmadik (C3) osztályba eső minta esetén a moduláris megoldás egyes blokkjainak kimenetein milyen értéket vár! **(1 pont)**
2. **a.** Turbózás (boosting) eljárásnál az *ötödik* iterációban a tanításnál csökkentjük azoknak a mintáknak a súlyát, amelyeket az *első* osztályozó jól osztályozott. **a. Igaz Hamis**
  - b.** Egy adott, rögzített mintahalmazon a túltanulás jelentkezése rendszerint csökkenti a *tesztmintákon* elért pontosságot, miközben a *tanítóminta* halmazon még javul a tanítás pontossága. **b. Igaz Hamis**
  - c.** Egy kétbemenetű lineáris eszköz VC dimenziója 3. Ez azt jelenti, hogy a kétdimenziós tér minden (akár speciális helyzetű) ponthármasát képes tetszőleges címkézés mellett – megfelelő paraméterezés esetén – a kívánt két osztályba sorolni? **c. Igaz Hamis**
  - d.** Egy döntési fa csomópontjában elvégzett attribútum vizsgálat relevanciáját nézzük meg  $\chi^2$  teszttel. A döntési fában elvégzett attribútum vizsgálat akkor irreleváns, ha a  $\chi^2$  tesztben kiszámított valószínűségi változó nulla közelében van. **d. Igaz Hamis**
  - e.** Ha 6-bemenetű (egy kimenetű) logikai függvényt megvalósító eszközt tanítunk, akkor a hipotézisér mérete  $2^6=64$ . **e. Igaz Hamis**
  - f.** Két döntési fa készült ugyanazon problémára. A két fa különböző sorrendben teszteli az attribútumokat, de ettől még lehetnek konzisztensek ugyanazzal a mintahalmazzal. **f. Igaz Hamis**

(  $\leq 3$  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  $v_1=[1 \ 0 \ 0]^T$ ,  $v_2=[1 \ 0 \ 1]^T$ , 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  $x = [+1 \ -1]^T$ ! **(2 pont)**
  - 3.B** Adja meg a második szakértő paramétervektorának új értékét, miután egy lépésben tanítottuk az  $x^{(\ell)} = [+1 \ -1]^T$ ,  $y^{(\ell)} = -0,2$  mintával! (A tanítás során a bátorsági faktor 0,05). **(4 pont)**

4. 5 dimenziós mintákat sorolunk 2 osztályba, lineáris osztályozórendszerrel tanítva (az osztályozónknak van eltolás paramétere is) Adaboost eljárással (turbózás). 5 rész osztályozót tanítottunk, a 100 elemű tanítóminta halmazon.

Az egyes részosztályozók az alábbi tanítóminta pontokat osztályozták rosszul, a többi mintát mindegyik részosztályozó egyöntetűen jól sorolta be.

$k$	17	32	43	61	86
$d_k$	+1	-1	+1	-1	-1
$h_1(\mathbf{x}_k)$	-1	+1	-1	-1	+1
$h_2(\mathbf{x}_k)$	+1	+1	+1	-1	+1
$h_3(\mathbf{x}_k)$	-1	+1	-1	+1	+1
$h_4(\mathbf{x}_k)$	+1	-1	+1	-1	+1
$h_5(\mathbf{x}_k)$	+1	-1	-1	-1	-1

4.A Mekkora az egyes részosztályozók hibája a tanítóminta halmazon mérve? (2 pont)

4.B Milyen pontosságot vállalhatunk nagy valószínűséggel az eszközre, ha a tanítóminta halmaz jól reprezentálja a problémát? (A felső korlát becslést pontos képletként felfogva – ami ordító módon nem igaz amúgy. Bármelyik felső korlát becslést használhatja, nem kell mindkettőt kiszámítani.

(5 pont)

**Jó munkát !**

**Zárthelyin használható összefüggések**

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

$\chi^2$  táblázat

SzF	P <sub>0,5</sub>	P <sub>0,2</sub>	P <sub>0,1</sub>	P <sub>0,05</sub>	P <sub>0,01</sub>	P <sub>0,005</sub>	P <sub>0,001</sub>
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