

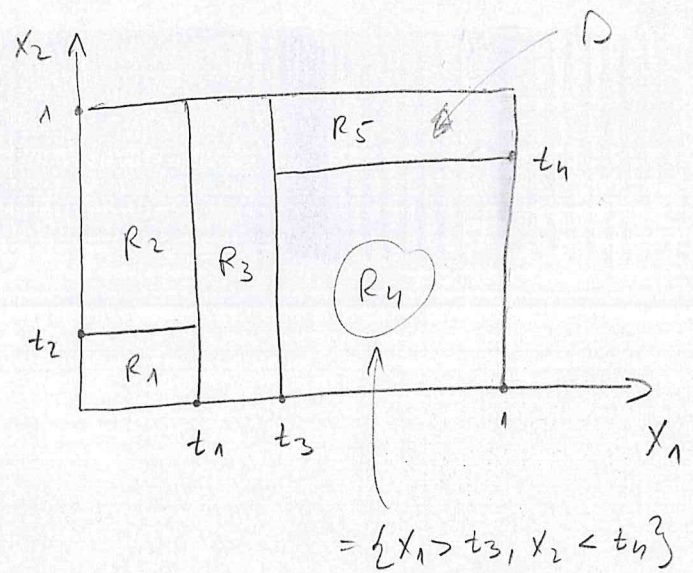
8. Metode binarne na stablima

8.1 CART (Classification and Regression Trees)

• dijelimo prostor prediktora  $D \subseteq \mathbb{R}^p$  na  $p$ -dimenz. pravokutnike te prilagodavamo jednostavnom modelu na svakom pravokutniku

• koristimo rekurzivne binarne particije

Pr. 8.1 |  $Y \in \mathbb{R}$ ,  $X = (x_1, x_2) \in [0, 1]^2 =: D$ , te  $x_1$  i  $x_2$  kvantitativne.



- 1.  $D$  dijelimo u  $x_1 = t_1$
- 2.  $\{x_1 \leq t_1\}$  —||—  $x_2 = t_2$   
 $\{x_1 > t_1\}$  —||—  $x_1 = t_3$
- 3.  $\{x_1 > t_3\}$  —||—  $x_2 = t_4$

↳ particija  $R_1, \dots, R_5$  od  $D$

↳ za jednu particiju,  $\forall x \in D \cap \mathbb{R}^2$ ,

$$\hat{f}(x) := \sum_{m=1}^5 e_m \mathbb{1}_{\{x \in R_m\}} = c_k \text{ ako } x \in R_k,$$

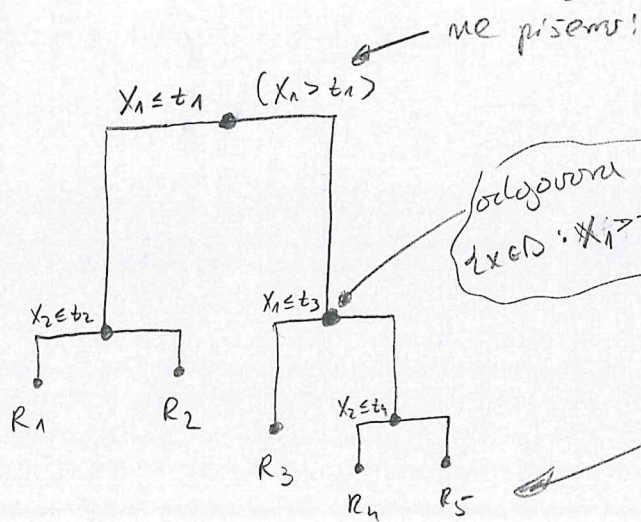
za neke  $e_1, \dots, e_5 \in \mathbb{R}$ .

• ako  $L(y, \hat{y}) = (y - \hat{y})^2 \rightarrow$

$$e_m := \frac{1}{\#\{x^{(i)} \in R_m\}} \cdot \sum_{x^{(i)} \in R_m} y_i$$



↳ ekvivalentan zapis preko binarnog stabla:



odgovora  $\{x \in D : \exists i > t_i, y \in D\}$

[stablo možemo crtati i za  $p > 3$ !]

$R_1, \dots, R_5 = \text{listovi}$

Prednosti:

- interpretacija [npr. primjene u medicini]
- automatski odabir korijeta i interakcije među njima
- invarijantnost na monotone transformacije korijeta

Mane:

- prediktivna sposobnost
- ↳ bagging, slučajne šume, boosting

[konstrukcija stabala u CART algoritmu?]

2.1.1 Regresijska stabla

•  $y \in \mathbb{R}$ , te pretp.  $X \in D \subseteq \mathbb{R}^p$  (sva  $x_j$  kont.)

Za svako binarno stablo  $T$ , svaki čvor  $t \in T$  i identifikiramo s odgovarajućim područjem od  $D$ , te

$$\tilde{T} := \{t \in T : t \text{ je list}\}.$$

↳  $I(t) := \{(x^{(i)}, y_i) : x^{(i)} \in t\}$  (2.1)

•  $n(t) := |I(t)|$



$$\bar{y}(t) := \frac{1}{n(t)} \sum_{x^{(i)} \in t} y_i, \quad (8.2)$$

$$\hat{A}_T(x) := \sum_{t \in \tilde{T}} \bar{y}(t) \mathbb{1}_{\{x \in t\}}, \quad x \in D$$

[dakle, pretpostavili smo  $L(y, \hat{y}) = (y - \hat{y})^2$ ]

Neka je "cost"

$$C(T) := \frac{1}{n} \sum_{i=1}^n (y_i - \hat{A}_T(x^{(i)}))^2 \quad (= L_T(\hat{A}_T)) \quad (8.3)$$

$$= \frac{1}{n} \sum_{t \in \tilde{T}} \sum_{\substack{x^{(i)} \in t \\ =: \text{RSS}(t)}} (y_i - \bar{y}(t))^2$$

Kritarij dijeljenja: u svakom listu  $t \in \tilde{T}$ , neka su

$$t_L = t_L(j, s) := \{x \in t : x_j \leq s\}, \quad j \in \{1, \dots, p\}, s \in \mathbb{R},$$

$$t_R = t_R(j, s) := \{x \in t : x_j > s\}$$

Sve moguće podjele, te  $T(j, s)$  rezultirajuće stabler.

$\hookrightarrow$  tražimo [za  $s$  dovoljno glatki samo  $n(t)$  uprednosti!]

$$(j^*, s^*) := \underset{j, s}{\operatorname{argmax}} \left\{ \underbrace{C(T) - C(T(j, s))}_{=: \Delta C(t, j, s)} \right\} \quad (8.4)$$

Nap. 8.2.1  
 (a) iz (8.3) odmah slijedi

$$\Delta C(t, j, s) = \frac{1}{n} (RSS(t) - RSS(t_L) - RSS(t_R)) \quad (8.5)$$

$$t \in (j^*, s^*) = \underset{j, s}{\operatorname{argmin}} \{ RSS(t_L) + RSS(t_R) \} \quad (8.6)$$

↑  
 onim samo u  $T(t)$ !  
 $\frac{1}{n(t_L)} RSS(t_L) = \hat{\operatorname{Var}}(y_i : x^{(i)} \in t_L)$



(b) Knjedi:  $\Delta C(t, j, s) \geq 0, \forall t, j, s$  te (102) 84

$$\Delta C(t, j, s) = 0 \Leftrightarrow \bar{y}(t) = \bar{y}(t_L) = \bar{y}(t_0). \quad \Rightarrow$$

Kriterij zaustavljanja?

↳ broj listova  $|\tilde{T}|$  kontrolira kompleksnost!

↳ Ue dijeli  $t \in \tilde{T}$  ako

(1)  $\Delta C(t, j^*, s^*) \leq \delta$  za neki  $\delta \geq 0$ , [mindeu]  
↳ [previše "kružokidno" za velike  $\delta$ ]

ili

(2)  $\min \{ m(t_L^*), n(t_0^*) \} < g_1$  [mincut]

za  $g_1 \in \mathbb{N}$

ili

(3)  $m(t) < g_2$  [minsize]

za  $g_2 \in \mathbb{N}$

↳ Kako odrediti  $\delta, g_1, g_2$ ?

↳ Alternativa

Obrezivanje stabla (engl. "pruning")

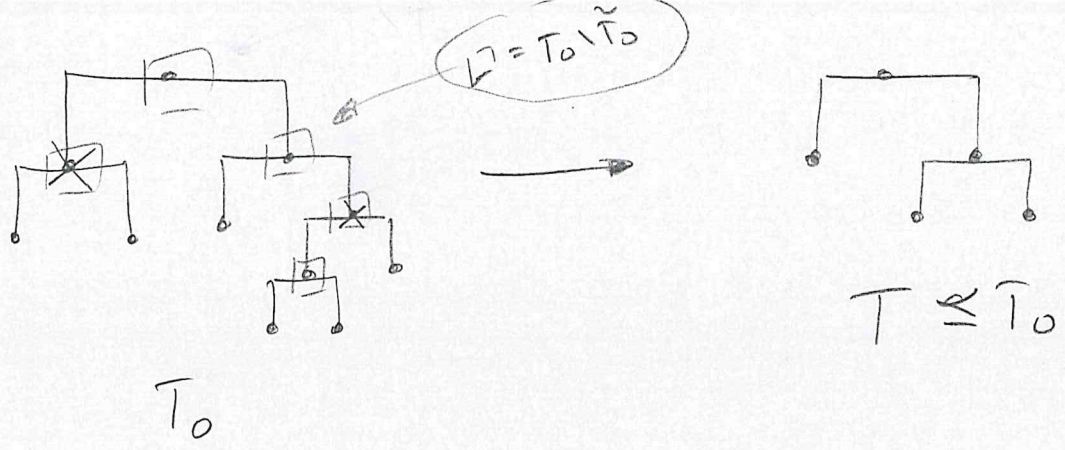
• naprimo "veliku" stabla (npr.  $\delta=0, g_1=1, g_2=5$  gase)

→  $T_0$

•  $T \in T_0$  je podstablo od  $T_0$  (" $T \leq T_0$ ")

ako je dobiveno "obrezivanjem" bilo kojeg broja čvorova  $t \in T_0 \setminus \tilde{T}_0$ .

mp.



[spejamo neke elemente particije (unutra)]

• Za sve  $\alpha \geq 0$ ,

$$C_\alpha(T) := C(T) + \alpha \cdot |\tilde{T}| \quad (8.7)$$

te

$$T(\alpha) := \operatorname{argmin}_{T \leq T_0} C_\alpha(T). \quad (8.8)$$

penalizacija kompleksnosti

Nap. 8.31

(a)  $\alpha = 0 \Rightarrow T(0) = T_0$

veći  $\alpha \Rightarrow$  manji  $|\tilde{T}(\alpha)|$

(b) Može se pokazati da postoji  $k \in \mathbb{N}$  te

$$0 = \alpha_0 < \alpha_1 < \dots < \alpha_k < \alpha_{k+1} = +\infty,$$

i niz stabala  $T^0 \geq T^1 \geq \dots \geq T^k$  t.d.

$$T(\alpha) = T^i \text{ za } \alpha \in [\alpha_i, \alpha_{i+1}), i=0, \dots, k \quad (8.9)$$

(vidi Ripley (1996))

$$(T^0 = T_0, |\tilde{T}^k| = 1)$$



(2)  $\alpha(t_j, i)$  odabiremo CV metodom ili na bestnom skupu. [86]

[za CV  $\rightarrow \forall T_k, k=1, \dots, K$ , ponovo računamo  
 $T_0 = T_0(T_k), T(x) = T(x, T_k), x \geq 0, (!)$   
 te grešku prognoziramo na  $T - T_k =$ ]

California Housing. R

### 8.1.2 Klasifikacijska stabla

$\bullet Y \in \{0, 1, \dots, K-1\} =: S$

Za stablo  $T$ , i sve  $t \in T$ ,

$$m_k(t) := |\{x^{(i)} \in t : y_i = k\}|, \quad (8.10)$$

te

$$\hat{P}(Y=k | X \in t) = P_k(t) := \frac{m_k(t)}{m(t)}. \quad (8.11)$$

$$\hat{A}_T(x) := \sum_{t \in \tilde{T}} k(t) \mathbb{1}_{\{x \in t\}}, \quad x \in D,$$

te ako je gubitak 0-1, stajemo

$$k(t) = \arg \max_{h \in S} \hat{P}_h(t). \quad (8.12)$$

$$= \underset{(8.11)}{\text{---}} m_k(t)$$



Kako djelimo čvorove?

Uoči, za regresijsku tablicu,

$$C(T) = \frac{1}{n} \sum_{t \in \tilde{T}} \sum_{x^{(i)} \in t} (y_i - \bar{y}(t))^2$$

$$= \sum_{t \in \tilde{T}} \hat{p}(t) \cdot i(t) \quad (8.13)$$

Za

$$\hat{p}(t) := \frac{n(t)}{n} \quad (= \hat{P}(X \in t)) \quad (8.14)$$

$$i(t) := \frac{1}{n(t)} \sum_{x^{(i)} \in t} (y_i - \bar{y}(t))^2$$

$$= \widehat{\text{Var}}(y_i : x^{(i)} \in t)$$

Mjera "nečistoće"  
(engl. "impurity")  
čvoru t

Za konstrukciju stabla u klasifikaciji koristimo

(1.) Ginijev indeks:

$$i(t) = \sum_{\substack{k \neq k', \\ k, k' \in S}} \hat{p}_k(t) \hat{p}_{k'}(t) = \sum_{k \in S} \hat{p}_k(t) (1 - \hat{p}_k(t)) \quad (8.15)$$

ili

(2.) Entropija:

$$i(t) = - \sum_{k \in S} \hat{p}_k(t) \log(\hat{p}_k(t)) \quad (8.16)$$

↳ upodi •  $i(t)$  maksimalna ako  $(\hat{p}_0(t), \dots, \hat{p}_{k-1}(t)) = (\frac{1}{k}, \dots, \frac{1}{k})$

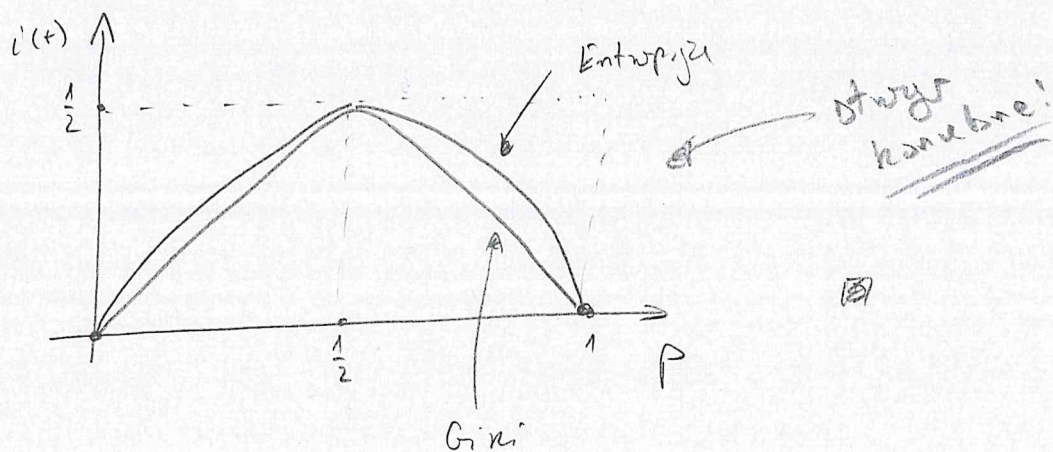
•  $i(t)$  minimalna ako  $\hat{p}_k(t) = 1$  za neki  $k \in S$ .



Pr. 8.4 |  $S = \{0, 1\}$   $\rightarrow$   $\left[ p := \hat{p}_1(t), \hat{p}_0(t) = 1-p \right]$  (88)

$\Rightarrow$  Gini  $\rightarrow i(t) = 2p(1-p)$

Entropija  $\rightarrow i(t) = -p \log(p) - (1-p) \log(1-p)$



Kriterij dijeljenja: za  $t \in T$ , tražimo

$$(j^*, s^*) = \underset{j, s}{\operatorname{argmax}} \{ \Delta C(t, j, s) \}$$

$$(8.17) = \dots \{ \hat{p}(t) i(t) - \hat{p}(t_L) i(t_L) - \hat{p}(t_R) i(t_R) \}$$

$$= \underset{j, s}{\operatorname{argmin}} \{ \hat{p}(t_L) i(t_L) + \hat{p}(t_R) i(t_R) \}$$

Nap. 8.5 | u regresiji imamo  $L(y, \hat{y}) = (y - \hat{y})^2$  te koristimo

$$i(t) = \frac{1}{n(t)} \sum_{x^{(i)} \in t} L(y_i, \underbrace{\hat{A}_T(x^{(i)})}_{= \hat{y}(t)})$$

tj.  $C(T) = L_T(\hat{A}_T)$

$\rightarrow$  zašto u klasifikaciji ne koristimo 0-1 gubitak


$$i(t) = \frac{1}{n(t)} \sum_{x^{(i)} \in t} \mathbb{1}_{\{y_i \neq \hat{A}_T(x^{(i)})\}}$$



$$= 1 - \hat{p}_{n(t)}(t) \quad (8.12)$$

mfn. |  $S = 10,13,$

$$t = (4, 16)$$



te gledamo podjelu

$$t_L = (4, 6)$$

$$t_0 = (0, 10)$$

"čist čvor"



$$\Delta C = \hat{p}(t) i(t) - \hat{p}(t_L) i(t_L) - \hat{p}(t_0) i(t_0)$$

$$= \frac{1}{n} \left\{ \begin{array}{l} 0, \quad 0-1 \\ 1.6, \quad \text{Gini} \\ 3.27, \quad \text{entropija} \end{array} \right.$$

jer  $k(t_L) = k(t_0) = h(t)!$   
(= 1)

[ problem je u tome što je 0-1 t-ja neistota  
nije strogo konveksna! ]

Ipak, 0-1 mijenu koristimo pri obretiocuju

[jer mo> zamima predikciju]





~~tpoh, 0-1 mjera konstante pri obrezivanju stabla.~~

~~[Zanimanje nas predhaju]~~ [0,0]

### 8.1.3 Generalizacije

#### Kategorijalne koordinate

Ako je  $x_j \in \{0, 1, \dots, k_j - 1\} =: S_j$ , imamo  $2^{k_j - 1} - 1$

možućih podjela  $S_j$  na dvije grupe

(npr.  $t_L = \{x \in t : x_j \in \{0, 1, 3\}\}$ ,  $t_R = \{x \in t : x_j \in \{2, 1, 3\}\}$ )

→ za velike  $k_j$  imamo pristupačnost za izbor  $x_j$  za podjelu!

Funkcija gubitka → pretp.  $S = \{0, 1, 3\}$

Umjesto samo  $L(\hat{A}) = P(Y \neq \hat{A}(X))$ , često nas više zanimaju

- $P(Y = \hat{A}(X) | Y = 1) \rightarrow$  "sensitivity"
- $P(Y = \hat{A}(X) | Y = 0) \rightarrow$  "specificity"

npr. (a) 0 = nije bolest, 1 = bolest

→ želimo što veću sens.

(b) 0 = nije spom, 1 = spom

→ ——— "specif." ■



↳ Matrica gubitka je  $L = (L_{k,k'} : k, k' \in \{0,1\})$ , gdje je (t-je)

0.1

- $L_{k,k} = 0$ , ( $\forall k$ )

- $L_{k,k'} =$  trošak ako stavimo mjehot ( $k$ ) ( $\geq 0$ ) predviđamo  $s$  ( $k'$ ), ( $k \neq k'$ )

Za stablo  $T$ , ako je  $x \in t$  ( $t \in \tilde{T}$ ), iz

imamo

$$\hat{A}_T(x) = k(t) := \underset{k \in \{0,1\}}{\operatorname{argmin}} \sum_{\ell \in \{0,1\}} L_{\ell,k} \hat{P}_\ell(t) = \hat{P}(Y=e | X \in t)$$

$$= \hat{E}[L_{Y,k} | X \in t]$$

$$\stackrel{L_{k,k}=0}{=} \underset{k \in \{0,1\}}{\operatorname{argmin}} L_{1-k,k} \hat{P}_{1-k}(t),$$

ti:

$$\hat{A}_T(x) = 1 \iff L_{0,1} \hat{P}_0(t) \leq L_{1,0} \hat{P}_1(t)$$

$$\iff \hat{P}_1(t) \geq \frac{L_{0,1}}{L_{1,0} + L_{0,1}} =: \alpha$$

$\hat{P}_0 = 1 - \hat{P}_1$

↳ •  $L_{0,1} > L_{1,0}$  (npr. 0 = nije spem, 1 = spem)

$\Rightarrow \alpha > \frac{1}{2}$  te vodi specificity.

•  $L_{0,1} < L_{1,0}$  (npr. 0 = nije bolest, 1 = bolest)

$\Rightarrow \alpha < \frac{1}{2}$  te vodi sensitivity

•  $L_{0,1} = L_{1,0}$  (0-1 gubitak)

$\Rightarrow \alpha = \frac{1}{2}$



• uvijek postoji "tradeoff" između sensit. i specif.

→ ROC krivulja

92

• umjesto kod predikcija,  $L$  se može uzeti u obzir i pri konstrukciji stabla

→ Carseats.R