

Strojno učenje

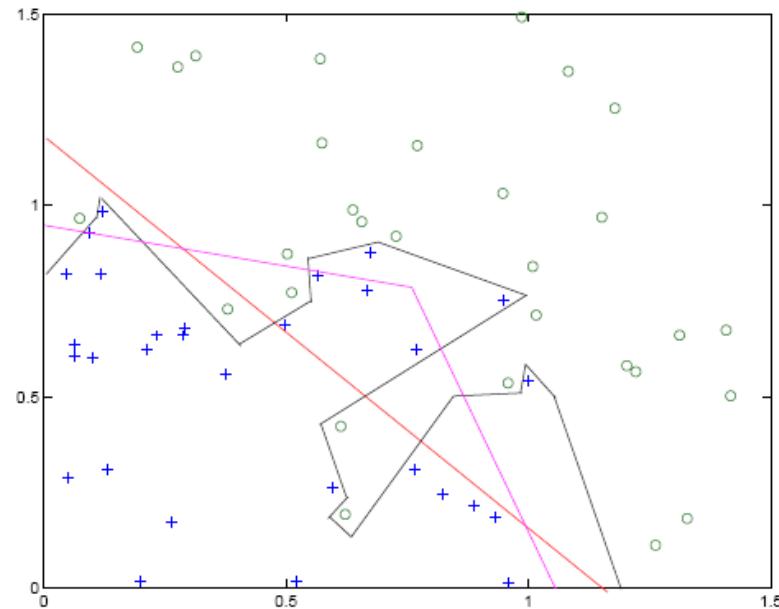
Osnove teorija Strojnog učenja

Tomislav Šmuc

Teorija (računalnog) strojnog učenja (TSU)

COmputational Learning Theory (COLT)

Nothing is more practical than a good theory (V. Vapnik)



Literatura:

- Machine learning, T. Mitchel (ch. 7)
- The Nature of Statistical Learning Theory, V. Vapnik

Bousquet, Boucheron, Lugosi:
Introduction to Statistical Learning Theory,
Advanced Lectures on Machine Learning
Lecture Notes in Artificial Intelligence 3176, 169-207.

C.J.C. Burges:

A tutorial on support vector machines for pattern recognition.
Data Mining and Knowledge Discovery, 2(2):955-974, 1998.

(COLT) daje kvantitativne granice na pitanja vezana uz učenje na osnovu primjera

- u zavisnosti o svojstvima problema
 - Veličini i kompleksnosti prostora hipoteza/modela
 - Točnosti do koje želimo aproksimirati ciljni koncept
 - Vjerojatnosti da će algoritam naučiti uspješnu hipotezu
 - Načinu kako su primjeri prezentirani "učeniku"
 - Slučajno, od strane tutora, na "traženje učenika" ...

Koliko primjera nam treba, da bi naučili neki koncept ?

Zavisi i o načinu-redoslijedu prezentiranja primjera !

Barem 3 različita načina prezentiranja primjera:

- učenik postavlja primjere $\langle x, ? \rangle$ za koje učitelj daje vrijednosti $f(x)$
- učitelj (koji zna vrijednosti ciljne funkcije f) daje primjere $\langle x, f(x) \rangle$ učeniku
- primjeri dolaze prema nekom slučajnom redoslijedu $\langle x, ? \rangle$ (okolina, priroda), a na njih učitelj daje vrijednosti $f(x)$

Induktivno učenje

Tražimo h takav da vrijedi :

$$(\forall \langle x_i, f(x_i) \rangle \in T) \quad (B \wedge h \wedge x_i) \vdash f(x_i)$$

- h – je hipoteza(model) koja reprezentira/aproksimira ciljni koncept $c(f(x))$, u idealnom slučaju – $h(x)=f(x)$. B predstavlja neko prethodno znanje o problemu.
- ono što u najboljem slučaju možemo garantirati učenjem nekim algoritmom strojnog učenja jest da naučena hipoteza h dobro aproksimira ciljni koncept c nad skupom primjera za učenje T
- **Osnovna hipoteza induktivnog učenja:**

*Bilo koja hipoteza koja dobro aproksimira ciljni koncept na **dovoljno velikom skupu primjera dostupnih za učenje**, isto će tako dobro aproksimirati ciljni koncept i na novim, još nedostupnim primjerima.*

Induktivno učenje – učenje na osnovu skupa primjera

Skup primjera za učenje (en. Training set) $\subseteq \Delta$

$$T = \{\langle \mathbf{x}_1, y_1 \rangle, \langle \mathbf{x}_2, y_2 \rangle, \dots, \langle \mathbf{x}_n, y_n \rangle\}$$

x – ulazni vektor atributa/variabli:

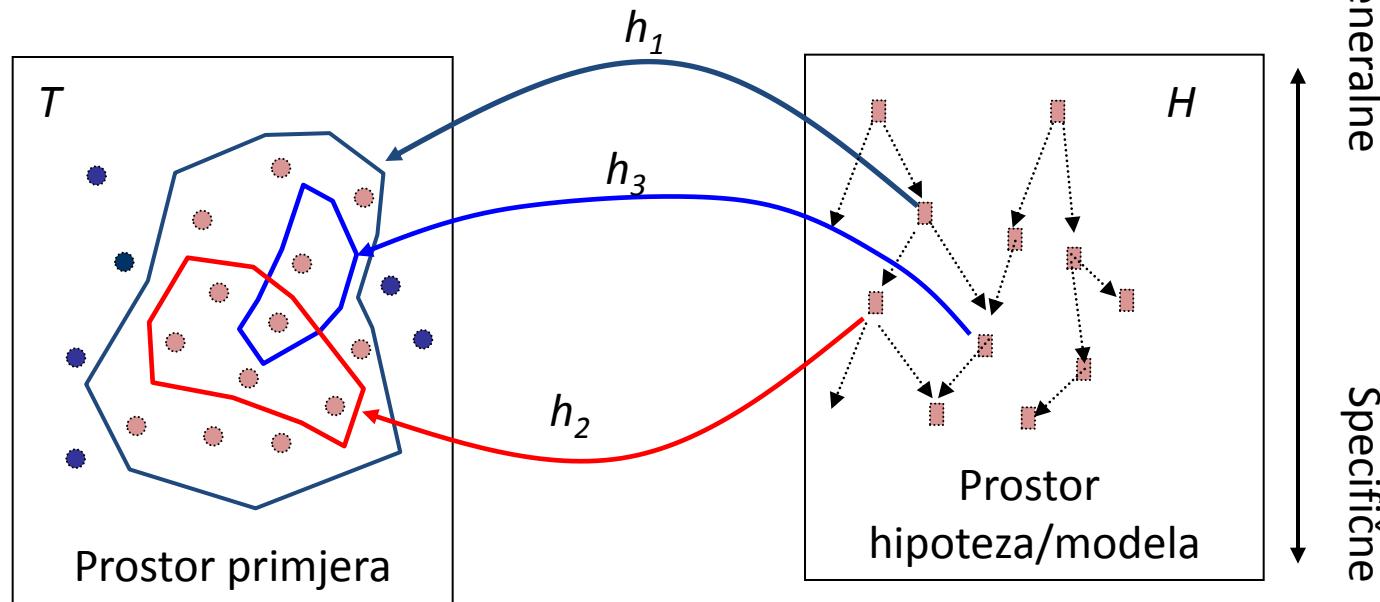
Primjer s igranjem danima za igranje tenisa

$(x_1 \text{ (Prognoza)}, x_2 \text{ (Vlažnost)}, x_3 \text{ (Vjetar)}, \dots)$

y – ciljna varijabla $Igrati_tenis \{0,1\}$

- H – prostor hipoteza/modela – konjunkcija uvjeta na vrijednosti atributa/variabile x (npr. $x_1 = \text{sunčano}/\text{oblačno}/\text{kiša}/\#$)
- Ciljni koncept $c: X \rightarrow Y$
- Δ stvarna i kompletna distribucija svih primjera X
 $(T \subseteq \Delta)$

Prostor primjera i prostor hipoteza



$x_1 = \langle \text{oblačno}, \text{vlažno}, \text{vjetrovito}, \text{obaveze} \rangle$

$x_2 = \langle \text{sunčano}, \text{suhu}, \text{vjetrovito}, \text{bez_obaveza} \rangle$

$$h_1 = \langle \text{oblačno}, \#, \#, \# \rangle$$

$$h_2 = \langle \text{oblačno}, \text{suhu}, \#, \# \rangle$$

$$h_3 = \langle \text{oblačno}, \text{suhu}, \#, \text{obaveze} \rangle$$

Dva viđenja greške pri induktivnom učenju

Greška na skupu za učenje hipoteze h s obzirom na ciljni koncept c

- mjeri kako često $h(x) \neq c(x)$ na skupu primjera iz T

$$e_T(h) \equiv P_{x \in T} [h(x) \neq c(x)] \equiv \frac{\sum_{x \in T} \delta(h(x) \neq c(x))}{|T|}$$

Stvarna greška hipoteze h s obzirom na ciljni koncept c

- mjeri kako često $h(x) \neq c(x)$ na bilo kojem skupu slučajno odabralih primjera na osnovu distribucije Δ

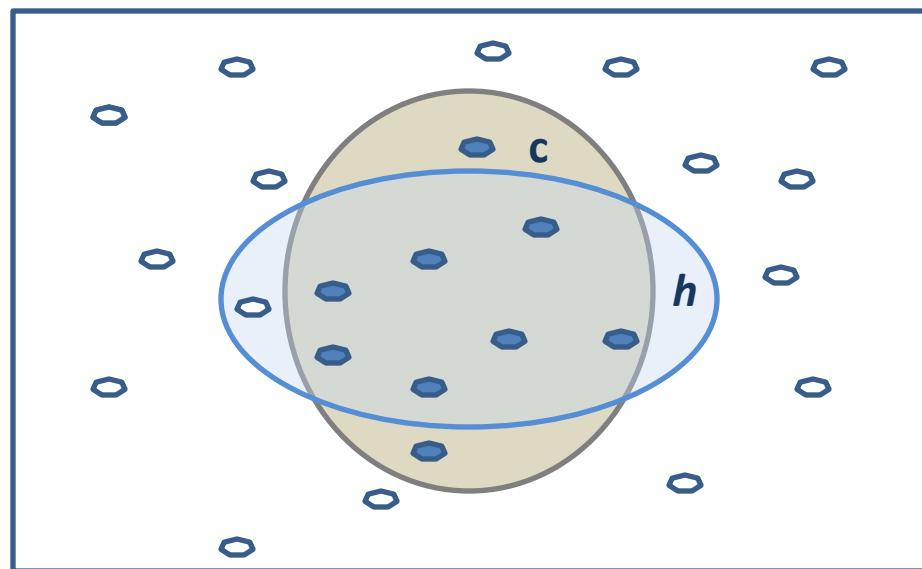
$$e_\Delta(h) \equiv P_{x \in \Delta} [h(x) \neq c(x)]$$



Dva viđenja greške pri induktivnom učenju

Možemo li predvidjeti stvarnu grešku na osnovu izmjerene
greške na dostupnom skupu primjera ?

Prostor primjera $X_{P(x)} = \Delta$



PAC Learning – Probably Approximately Correct (1988, Haussler)

Pretpostavimo da imamo klasu mogućih ciljnih koncepata C definiranu preko skupa primjera X duljine n , te algoritam učenja L koji koristi prostor hipoteza H .

Definicija:

Koncept iz C je moguće naučiti u **PAC smislu** od strane algoritma L korištenjem prostora hipoteza H , ako za sve $c \in C$, te distribuciju Δ preko primjera X , konstantu ε takvu da vrijedi $0 < \varepsilon < \frac{1}{2}$, i vjerojatnost δ ($0 < \delta < \frac{1}{2}$), algoritam L s vjerojatnošću najmanje $(1 - \delta)$ vraća hipotezu $h \in H$ takvu da za nju vrijedi $e_{\Delta}(h) \leq \varepsilon$, u vremenu koje je polinomijalno s obzirom na $1/\varepsilon$, $1/\delta$, n i $|C|$.

(svodi se na to da:

L treba samo polinomijalni broj primjera za učenje, te da je i vrijeme procesiranja po primjeru polinomijalno !!)

PAC Learning – Probably Approximately Correct (1988, Haussler)

PAC Learning princip – jednostavnim riječima:

- Ukoliko je neka hipoteza izrazito pogrešna - tada će to biti vidljivo već na malom podskupu primjera (preko velike pogreške), s velikom vjerojatnošću;
- I obratno - za bilo koju hipotezu konzistentnu s dovoljno velikim brojem primjera malo je vjerojatno da je izrazito pogrešna
 - t.j. **vjerojatno je približno točna (PAC)**

Podprostor konzistentnih hipoteza (en. Version space)

- Hipoteza/model ***h je konzistentna*** sa skupom primjera za učenje T nekog ciljnog koncepta $c(\mathbf{x})$ samo ako vrijedi:

$$\text{Konzistentna}(h, T) \equiv (\forall (\mathbf{x}, c(\mathbf{x})) \in T) h(\mathbf{x}) = c(\mathbf{x})$$

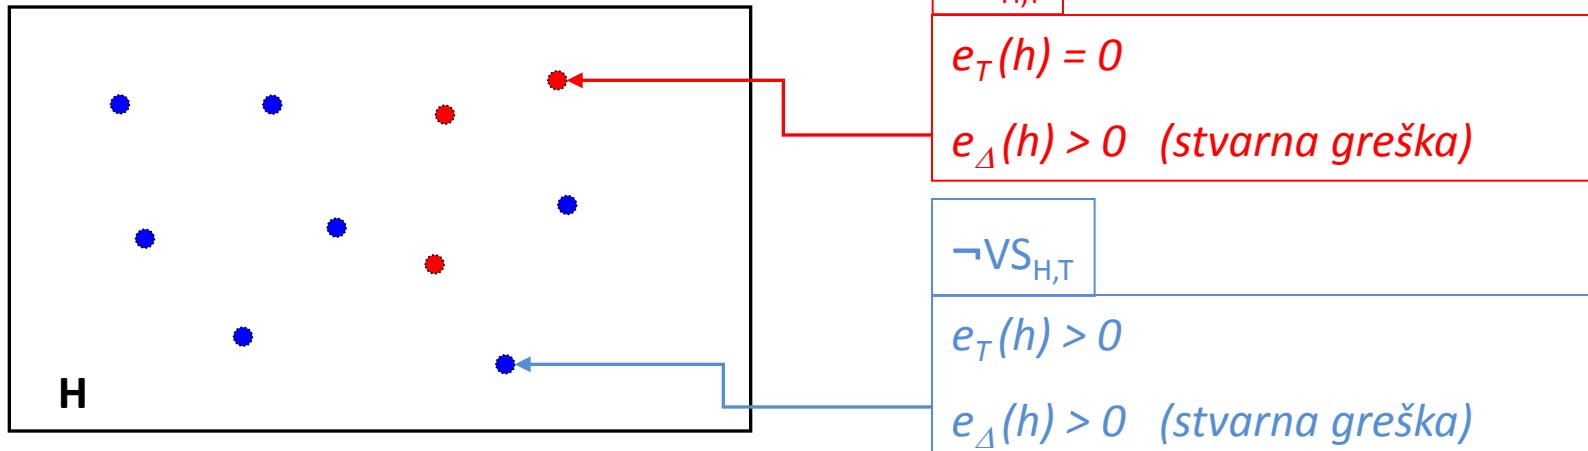
- **Version space – $VS_{H,T}$** definicija :

$$VS_{H,T} \equiv \{h \in H \mid \text{Konzistentna } (h, T)\}$$

Pretpostavlja se da je $c(\mathbf{x}) \in H !!$

$VS_{H,T}$ u odnosu na prostor hipoteza H i skup primjera predstavlja podskup hipoteza konzistentnih u odnosu na sve primjere skupa T

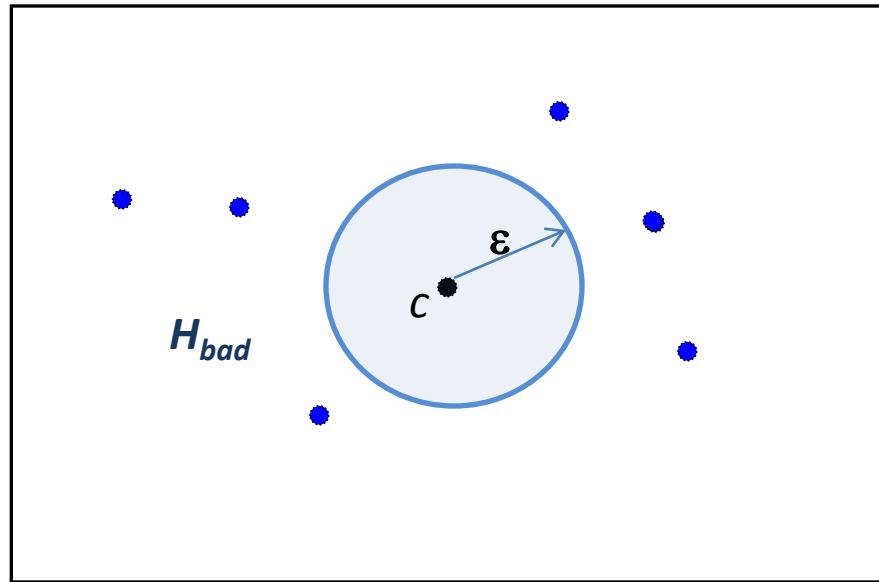
ε - iscrpivost/kompletnost $VS_{H,T}$ (ε - exhausted $VS_{H,T}$)

Prostor hipoteza H 

$VS_{H,T}$ je ε - iscrpiv/kompletnost (s obzirom na c i T) ako za svaku hipotezu/model u $VS_{H,T}$ vrijedi da ima stvarnu grešku manju od ε :

$$(\forall h \in VS_{H,T}) e_{\Delta}(h) < \varepsilon$$

Prostor hipoteza H



$$(\forall h \in VS_{H,T}) e_{\Delta}(h) < \varepsilon$$

-za svaku takvu h kažemo da je
približno točna (PAC)

Cilj nam je pokazati za koliko
primjera to vrijedi za čitav $VS_{H,T}$!

Prostor hipoteza H

Za svaku $h_{bad} \in H_{bad}$

$$e_{\Delta}(h_{bad}) > \varepsilon$$

Za neki novi primjer x_i iz Δ predikcija neke h_{bad} je točna s vjerojatnosti :

$$p(e_{\Delta}(h_{bad}) > \varepsilon, h_{bad}(x_i) = f(x_i)) \leq (1-\varepsilon)$$

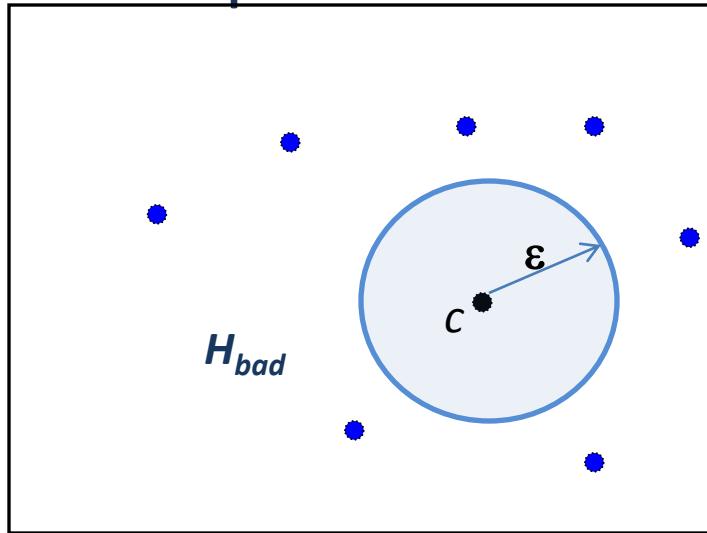
Za N novih primjer x_i iz Δ vrijedi:

$$p(e_{\Delta}(h_{bad}) > \varepsilon, h_{bad}(x_i) = f(x_i), \forall x_i \in \{x_1, \dots, x_N\}) \leq (1-\varepsilon)^N$$

Vjerojatnost da ćemo nabasati na barem jednu hipotezu h za koju vrijedi:

$$p(e_{\Delta}(h) > \varepsilon, h(x_i) = f(x_i), \forall x_i \in \{x_1, \dots, x_N\}) \leq |H_{bad}|(1-\varepsilon)^N \leq |H|(1-\varepsilon)^N$$

Prostor hipoteza H



Želimo da ova vjerojatnost bude što manja:

$$p(e_{\Delta}(h) > \varepsilon \mid e_{\{x_1, \dots, x_N\}}(h) = 0) \leq |H| (1 - \varepsilon)^N$$

Dakle $|H| (1 - \varepsilon)^N \leq \delta$; gdje je δ po volji mali

S obzirom da vrijedi: $1 - \varepsilon \leq e^{-\varepsilon}$

$$p(e_{\Delta}(h) > \varepsilon \mid e_{\{x_1, \dots, x_N\}}(h) = 0) \leq |H| e^{-\varepsilon N}$$

ovu ćemo vjerojatnost δ postići nakon učenja na N primjera :

$$N \geq \frac{1}{\varepsilon} (\ln \frac{1}{\delta} + \ln |H|)$$

$$N \geq \frac{1}{\varepsilon} (\ln \frac{1}{\delta} + \ln |\mathbf{H}|)$$

Ako algoritam vrati hipotezu koja je točna na N primjera, tada s vjerojatnošću od najmanje $(1-\delta)$ možemo očekivati da je njena stvarna greška najviše ε !

- Brojem N zapravo označavamo kompleksnost prostora hipoteza
- Veličina $|\mathbf{H}|$ najviše utječe na N
- $|\mathbf{H}|$ zavisi o "jeziku" kojim je opisan prostor primjera
- Za prostor primjera s n varijabli opisan konjunkcijama Boole-ovih literalja (npr. $h_i = \langle \text{oblačno}, \text{vlažno}, \#, \# \rangle$)
- $|\mathbf{H}| = ?$

Učenje konjunkcija Boole-ovih literala

- ❑ Neka H i neka je stvarni koncept $c \in H$. Neka je H opisan konjunkcijama uvjeta na n Boole-ovih varijabli (=Boole-ovi literali *). (U našem primjeru sa igranjem tenisa svaka varijabla ima 3 moguće vrijednosti).

Tada vrijedi

$$|H|=3^n$$

pa je broj potrebnih primjera:

$$N \geq \frac{1}{\varepsilon} \left(\ln \frac{1}{\delta} + n \ln 3 \right)$$

Za $\varepsilon=0.05$; $\delta=0.01$

$$N \geq \frac{1}{0.05} \left(\ln \frac{1}{0.01} + 10 \ln 3 \right) = 312 \text{ primjera}$$

PAC učenje - kad vrijedi $c \in H$

$$N \geq \frac{1}{\varepsilon} \left(\ln \frac{1}{\delta} + \ln |\mathbf{H}| \right)$$

Što ako želimo moći naučiti bilo koji ciljni koncept ($c \in C$) koji možemo zamisliti nad skupom primjera opisanim uvjetima na n Boole-ovih varijabli ?

$$|C| = ?$$

$$|C| = 2^{3^n}$$

!!

želimo li $c \in H \Rightarrow N \geq \frac{1}{\varepsilon} \left(\ln \frac{1}{\delta} + 3^n \ln 2 \right)$

PAC učenje - kad vrijedi $c \in H$

$$|C| = 2^{3^n} \text{ želimo li } c \in H \Rightarrow N \geq \frac{1}{\varepsilon} (\ln \frac{1}{\delta} + 3^n \ln 2)$$

Kako ograničiti broj potrebnih primjera ?

Osnovna dilema:

- a) Napraviti restrikcije na prostor hipoteza (restrikcija jezika, reprezentabilnih funkcija)
- b) Dovoljno kompleksan prostor, ali inzistirati da konzistentne hipoteze budu što jednostavnije

PAC učenje - kad **ne** vrijedi $c \in H$ (agnostičko učenje)

- Možemo probati naučiti h koja radi najmanje grešaka na T !
- Koliko nam tada treba primjera? Kako mjerimo stvarnu grešku?

- Ustvari možemo samo garantirati (za bilo koju h !):

$$P[e_{\Delta}(h) > e_T(h) + \varepsilon] \leq e^{-2N\varepsilon^2}$$

- moramo garantirati da ovo vrijedi za svaku iz H - pa onda i za najbolju!

$$P[(\exists h \in H) | e_{\Delta}(h) > e_T(h) + \varepsilon] \leq |H|e^{-2N\varepsilon^2}$$

- ako gornju vjerojatnost proglašimo δ možemo opet postaviti pitanje koliko nam promjera treba:

$$N \geq \frac{1}{2\varepsilon^2} (\ln \frac{1}{\delta} + \ln |\mathbf{H}|)$$

Ovo nije garancija da će algoritam naći najbolju h !

Napomena: ε je sada samo razlika između $e_{\Delta}(h)$ i $e_T(h)$
- tj. mjera overfitting-a!

PAC učenje - sažetak

- Konačni prostor H , i $c \in H$, vrijedi:

$$P[\exists h \in H \mid (e_{\Delta}(h) > \varepsilon) \wedge (e_T(h) = 0)] \leq |H| e^{-\varepsilon \cdot N}$$

pa možemo garantirati da je za točnost ε uz vjerojatnost $P \leq \delta$

dovoljno $N \geq \frac{1}{\varepsilon} (\ln \frac{1}{\delta} + \ln |\mathbf{H}|)$ primjera

- Konačni prostor H i vjerojatno $c \notin H$ vrijedi

$$P[(\exists h \in H) \mid e_{\Delta}(h) > e_T(h) + \varepsilon] \leq |H| e^{-2N\varepsilon^2}$$

pa možemo garantirati da je za točnost ε uz vjerojatnost $P \leq \delta$

dovoljno $N \geq \frac{1}{2\varepsilon^2} (\ln \frac{1}{\delta} + \ln |\mathbf{H}|)$ primjera

PAC učenje - problem kad $|H| \rightarrow \infty$

Osnovna dilema:

- a) Napraviti restrikcije na prostor hipoteza H (restrikcija jezika, reprezentabilnih funkcija) = konačni $H \Rightarrow$ PAC bounds
- b) Dovoljno kompleksan prostor H , ali inzistirati da konzistentne hipoteze budu što jednostavnije = **beskonačni H ????**

Vapnik-Chervonenkis dimenzija !

Shattering => Sposobnost particoniranja skupa primjera od strane nekog prostora hipoteza H
(en. **shattering**; hr.drobljenje, razbijanje)

Definicija. Skup primjera $S=\{x_i\}_{i=1,N}$ moguće je **particionirati/rastaviti** skupom hipoteza H , onda i samo onda ako za svaku **dihotomiju** skupa S , postoji $h \in H$ koja je konzistentna s takvom dihotomijom.

Dihotomija. Particija skupa primjera S u npr. pozitivne i negativne primjere.
Npr. za $N = 3$: postoji 2^3 mogućih dihotomija.

Skup S je moguće **particionirati/rastaviti** skupom hipoteza H , ako za svaku particiju primjera iz S u pozitivne i negativne primjere, postoji hipoteza/funkcija h iz H koja daje upravo iste oznake primjerima

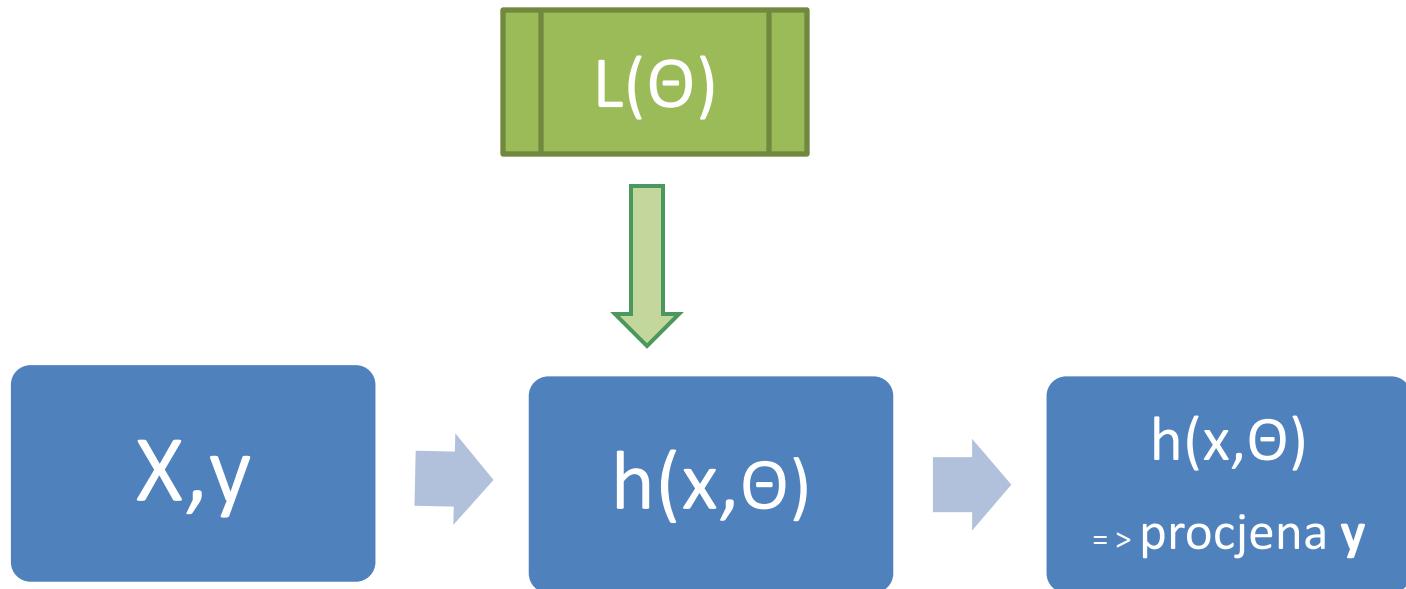
(Intuitivno: Kompleksniji skup funkcija H može **particionirati** veći skup S !)

Definicija (Vapnik-Chervonenkis dimenzija skupa hipoteza H - $VC(H)$)

$VC(H)$ prostora hipoteza H , definiranog preko prostora primjera X je **veličina najvećeg podskupa od X** koji je moguće particionirati/rastaviti korištenjem H . Ako je pomoću H moguće rastaviti po volji velike podskupove X , tada vrijedi $VC(H) \equiv \infty$.

$(h \in H$ mogu generirati bilo koju klasifikaciju na skupu primjera $S)$

$h(x, \Theta)$ predstavlja neku funkciju koju možemo naučiti algoritmom L



Malo drugačiji pogled....

Algoritam **L** kojom može partitionirati skup točaka S onda ako:

Za svaku moguću dihotomiju u obliku $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ može naučiti/proizvesti funkciju $h(x, \Theta)$ koja absolutno točno razdvaja primjere tog skupa (ima grešku =0!)

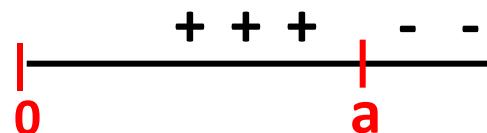


Postoji 2^n takvih dihotomija, s različitim kombinacijama $y \in (+1, -1)$

Primjeri $h(x, \Theta)$ i određivanja $VC(h)$

Polu-intervali:

$h(x, \Theta) \in H$; H - intervali tipa $[0, a)$, za neki realni $a > 0$



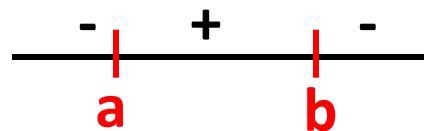
$$VC(h(x, \Theta)) = ?$$

$$|H| = ?$$

Primjeri $h(x, \Theta)$ i određivanja $VC(h)$

Intervali

$h(x, \Theta) \in H$; H - intervali na realnoj osi - $[a,b] \mid b > a$



$$VC(h(x, \Theta)) = ?$$

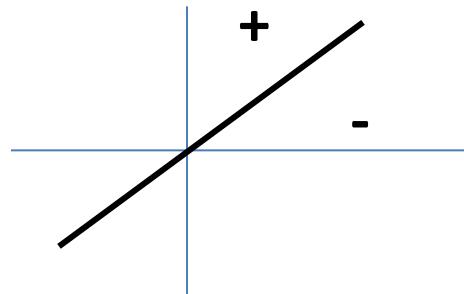
$$|H| = ?$$

Primjeri $h(x, \Theta)$ i određivanja $VC(h)$

Poluprostori - 1

$$h(x, \Theta) \in H$$

$$h(x, \Theta) = \text{sign}(x \cdot \Theta)$$



$$VC(h(x, \Theta)) = ?$$

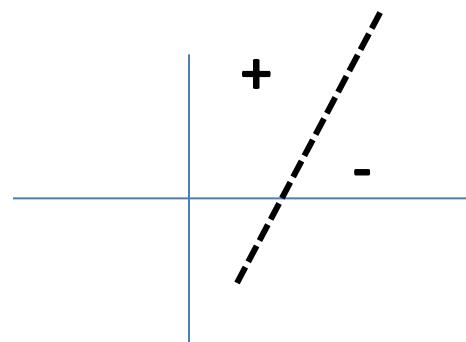
$$|H| = ?$$

Primjeri $h(x, \Theta)$ i određivanja $VC(h)$

Poluprostori - 2

$h(x, \Theta) \in H$

$$h(x, \Theta) = \text{sign}(x \cdot \Theta_1 + \Theta_2)$$



$$VC(h(x, \Theta)) = ?$$

$$|H| = ?$$

VC dimenzija prostora hipoteza H na prostoru primjera X je veličina najvećeg konačnog podskupa x koji se još može rastaviti hipotezama iz H

Ako postoji podskup veličine d koji se može rastaviti, tada vrijedi - $VC(H) \geq d$

$$\underline{VC(\text{Poluintervali})} = 1$$

$$\underline{VC(\text{Intervali})} = 2$$

$$\underline{VC(\text{Poluprostori 1})} = 2$$

(nijedan podskup veličine 2 se ne može rastaviti)

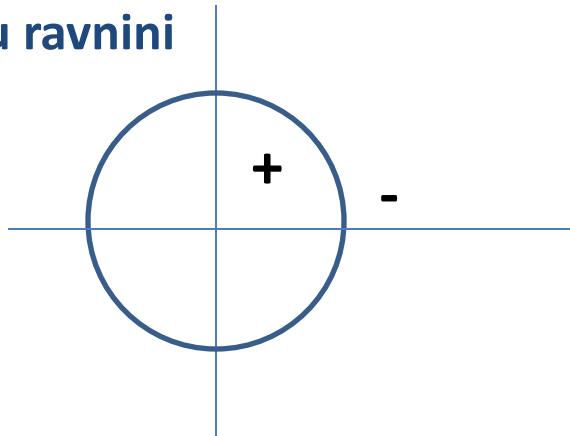
(nijedan podskup veličine 3 se ne može rastaviti)

(nijedan podskup veličine 3 se ne može rastaviti)

Drugi primjeri $h(x, \Theta)$, $VC(h)$ - za vježbu ?

$h(x, \Theta) \in H$; – kružnice u ravnini

$$h(x, \Theta) = \text{sign}(\Theta_1 \cdot x \cdot x - \Theta_2)$$



.....

- $VC(w^*x - b)$ – gdje je x – n dimenzionalni prostor
- $VC(\sin(x))$
- $VC(\text{stabla odlučivanja})$
- $VC(\text{perceptron})$
- $VC(\text{neuralne mreže})$

Gornja granica broja primjera

PAC učenje – uz korištenje $VC(H)$ => SRM

$$N \geq \frac{1}{\varepsilon} (4 \log_2 (\frac{2}{\delta}) + 8VC(H) \log_2 (13/\varepsilon))$$

Osim toga Vapnik je pokazao da s vjerojatnošću $(1-\eta)$ vrijedi

$$e_{\Delta} \approx e_{test} \leq e_T + \sqrt{\frac{VC(H)(\log(2N/VC(H)) + 1) - \log(\eta/4)}{N}}$$

Dakle – imamo procjenu greške na novim primjerima na osnovu greške na skupu za učenje i $VC(H)$!

Structural Risk Minimization (Vapnik)

Prepostavimo da imamo na izbor niz "strojeva"

- koji uče hipoteze iz prostora H_i (funkcije) različitih $VC(H_i)$ tako da vrijedi:

$$VC(H_1) \leq VC(H_2) \leq VC(H_3) \leq VC(H_4) \leq \dots \leq VC(H_N)$$

Koji ćemo od "strojeva" - algoritama koristiti ?

- Treniramo svaki od strojeva i mjerimo e_T ... i procjenjujemo e_{test} na osnovu:

$$e_{\Delta} \approx e_{test} \leq e_T + \sqrt{\frac{VC(H)(\log(2N/VC(H)) + 1) - \log(\eta/4)}{N}}$$

rbr	H_i	e_T	$\sqrt{VC(H)....}$	$\sim e_{test}$	Rang
1	H_1				4
2	H_2				1
3	H_3				1
4	H_4				1
5	H_5				5

VC-dimenzija + SRM – sažetak

- VC-dimenzija je mjera informacija o aproksimacijskoj snazi nekog "stroja za učenje" – algoritma izražena kroz ekspresivnost prostora hipoteza (funkcija) koji taj algoritam koristi;
- SRM: odabir algoritma koji ima minimalnu procjenu greške na novim primjerima

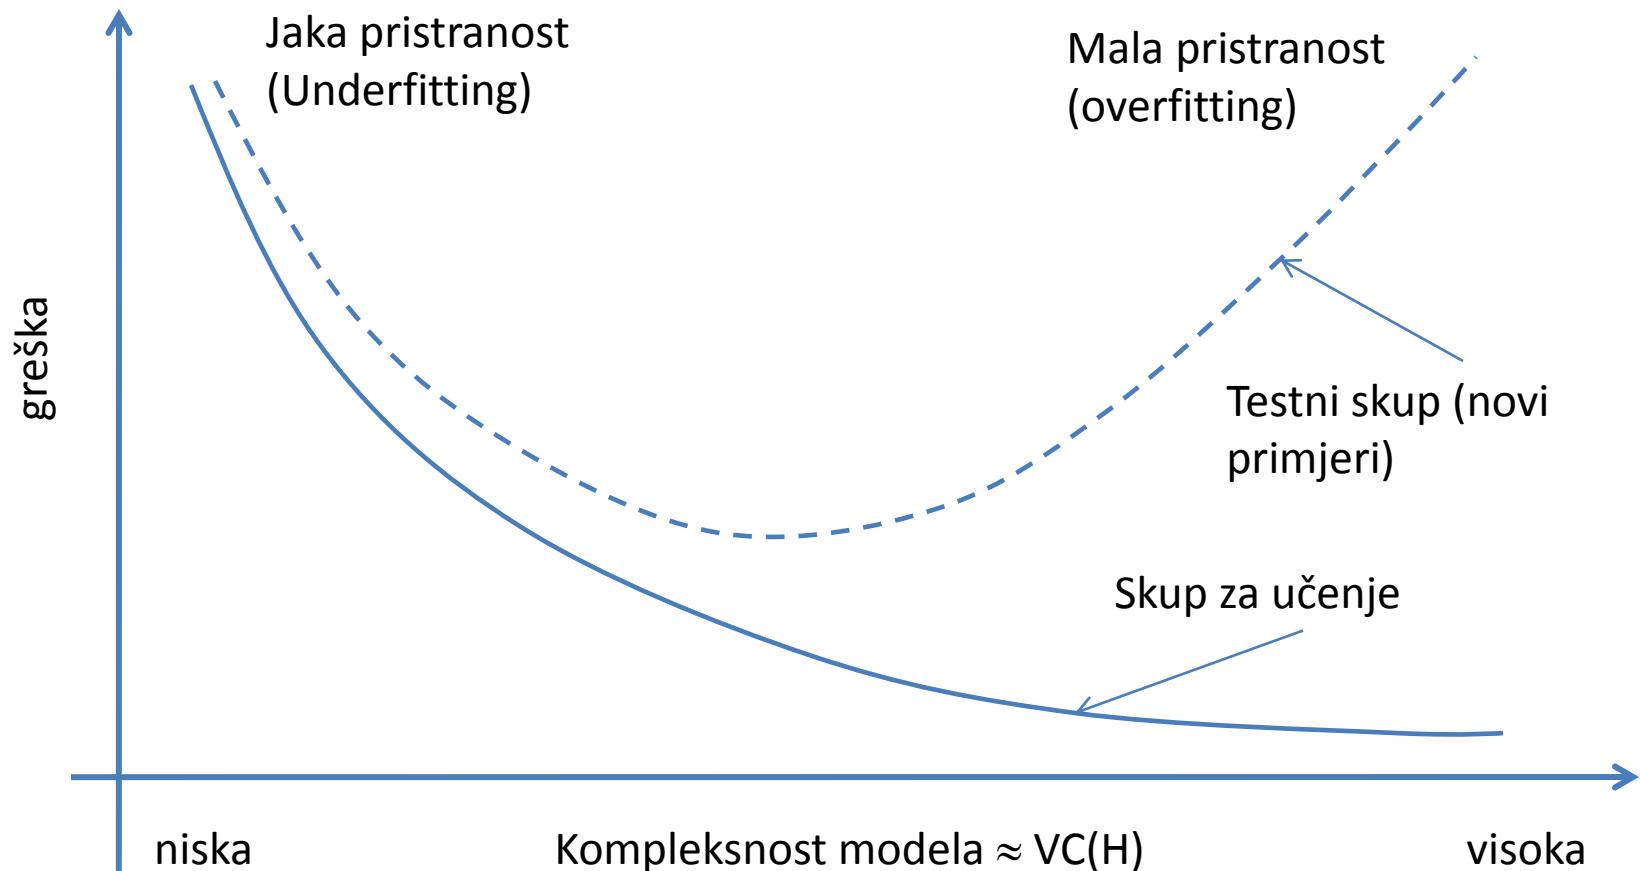
Trebalo bi zapamtiti:

- Shattering
- definiciju VC-dimenzije
- neke od primjera H i $VC(H)$
- SRM i čemu služi

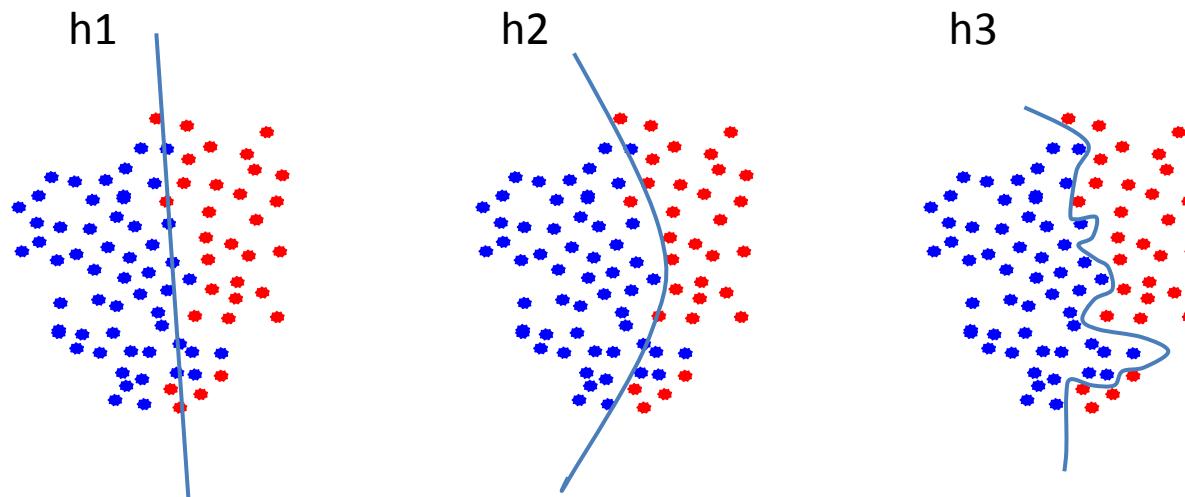
SRM i sposobnost generalizacije algoritma

- generalizacijom algoritma možemo nazvati kvalitetu predikcije na novim (testnim) podacima
- naš osnovni cilj je dobiti dobra svojstva generalizacije naučenim modelom podataka
- kad je naš model pre-kompleksan za neki skup podataka – može se desiti da uči ili memorira dijelove “šuma” ili grešaka, pored stvarne strukture podataka – pretreniranje (overfitting, model variance)
- Nasuprot tome kad je naš model nedovoljno kompleksan, tada ne može naučiti (dobro aproksimirati) stvarnu strukturu podataka, bez obzira na njihovu količinu – pristranost modela (en. underfitting, model bias)

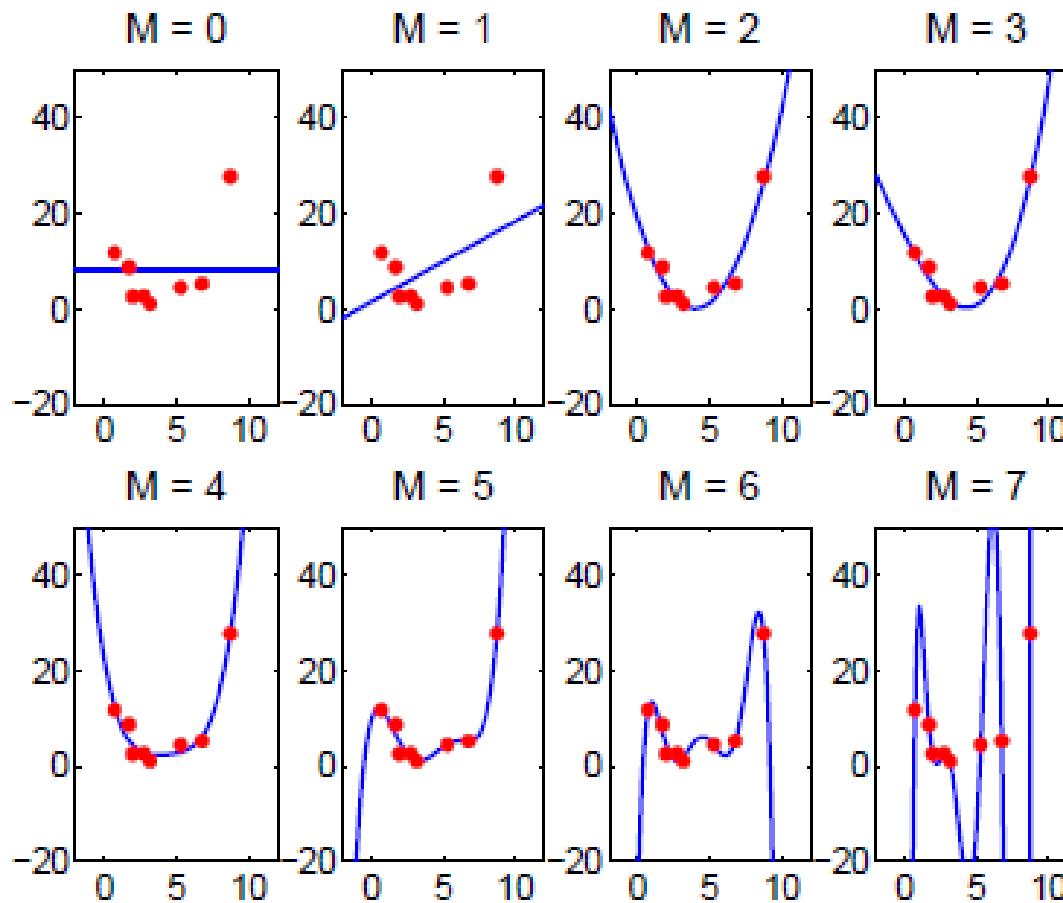
Tipično ponašanje



Primjer - klasifikacija



Primjer - regresija



Drugi put

Nastavak priče:

- struktura i klasifikacija algoritama strojnog učenja
- tehnike evaluacije modela, bias & variance;
- metrike u ocjenjivanju modela