

Strojno učenje


Osnove teorije SU

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 ?

Zависи i o načinu-redoslijedu prezentiranja primjera !

Barem 3 različita načina prezentiranja primjera:

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

Induktivno učenje

Tražimo h takav da vrijedi :

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

- h – je hipoteza(model) koja reprezentira/aproksimira ciljni koncept $c(=f(\mathbf{x}))$, u idealnom slučaju – $h(\mathbf{x})=f(\mathbf{x})$. 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) $\subseteq \Delta$

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

\mathbf{x} – ulazni vektor atributa/varijabli:


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/varijable \mathbf{x} (npr. $x_1 = \text{sunčano/oblačno/kiša/\#}$)
- Ciljni koncept $c: \mathbf{X} \rightarrow y$
- Δ stvarna i kompletna distribucija svih primjera \mathbf{X}
($T \subseteq \Delta$)

Prostor primjera i prostor hipoteza



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

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

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

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

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

Dva viđenja greške pri induktivnom učenju

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

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

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


Skup primjera

Distribucija
vjerojatnosti

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 – **P**robably **A**pproximately **C**orrect (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



$VS_{H,T}$

$$e_T(h) = 0$$

$$e_{\Delta}(h) > 0 \text{ (stvarna greška)}$$

$\neg VS_{H,T}$


$$e_T(h) > 0$$

$$e_{\Delta}(h) > 0 \text{ (stvarna greška)}$$

$VS_{H,T}$ je ε - iscrpiv/kompletnan (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 :

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

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

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 literala (npr. $h_i = \langle \text{oblačno, vlažno, \#, \#} \rangle$)
- $|\mathbf{H}| = ?$

Učenje konjunkcija Boole-ovih literala

- Pretpostavimo H i neka je stvarni koncept $c \in H$. H je 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 ?

$$|H| = ?$$

$$|H| = 2^{3^n} \quad !!$$

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

PAC učenje - kad vrijedi $c \in H$

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

Kako ograničiti broj potrebnih primjera ?

Osnovna dilema:

- a) Kako 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 h 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 proglasimo δ možemo opet postaviti pitanje koliko nam promjera treba:

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

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 $N \geq \frac{1}{\varepsilon} (\ln \frac{1}{\delta} + \ln |H|)$ 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 $N \geq \frac{1}{2\varepsilon^2} (\ln \frac{1}{\delta} + \ln |H|)$ 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 particioniranja skupa primjera od strane nekog prostora hipoteza H
(en. **shattering**; hr.drobljenje, razbijanje)

Definicija. Skup primjera $S=\{\mathbf{x}_i\}_{i=1,N}$ 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 particionirati 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 apsolutno 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 - $[a, b]$ | $b > a$



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


$|H| = ?$

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 $h(\mathbf{x}, \Theta)$ i određivanja $VC(h)$

Poluprostori - 2

$$h(\mathbf{x}, \Theta) \in H$$

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



$$VC(h(\mathbf{x}, \Theta)) = ?$$

$$|H| = ?$$

VC dimenzija prostora hipoteza H na prostoru primjera X je veličina najvećeg konačnog podskupa x koji se može rastaviti hipotezama iz H
(makar to bio samo jedan podskup te veličine!)

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

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

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

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

(**podskup veličine 2** se ne može rastaviti)


(**podskup veličine 3** se ne može rastaviti)

(**podskup veličine 3** se ne može rastaviti)

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

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

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



.....

- $VC(\mathbf{w}^* \mathbf{x} - \mathbf{b})$ – gdje je \mathbf{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 $VC(H)$ \Rightarrow SRM

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

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)

Pretpostavimo da imamo na izbor niz “strojeva”












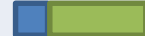

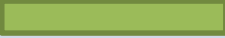

– koji uče hipoteze iz prostora H_i (funkcije) različitih $VC(H_i)$ tako da vrijedi:

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

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	$\sqrt{VC(H) \dots}$	$\sim e_{test}$	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
- cilj je dobiti **dobra svojstva generalizacije** naučenim modelom podataka:
 - kad je **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)**

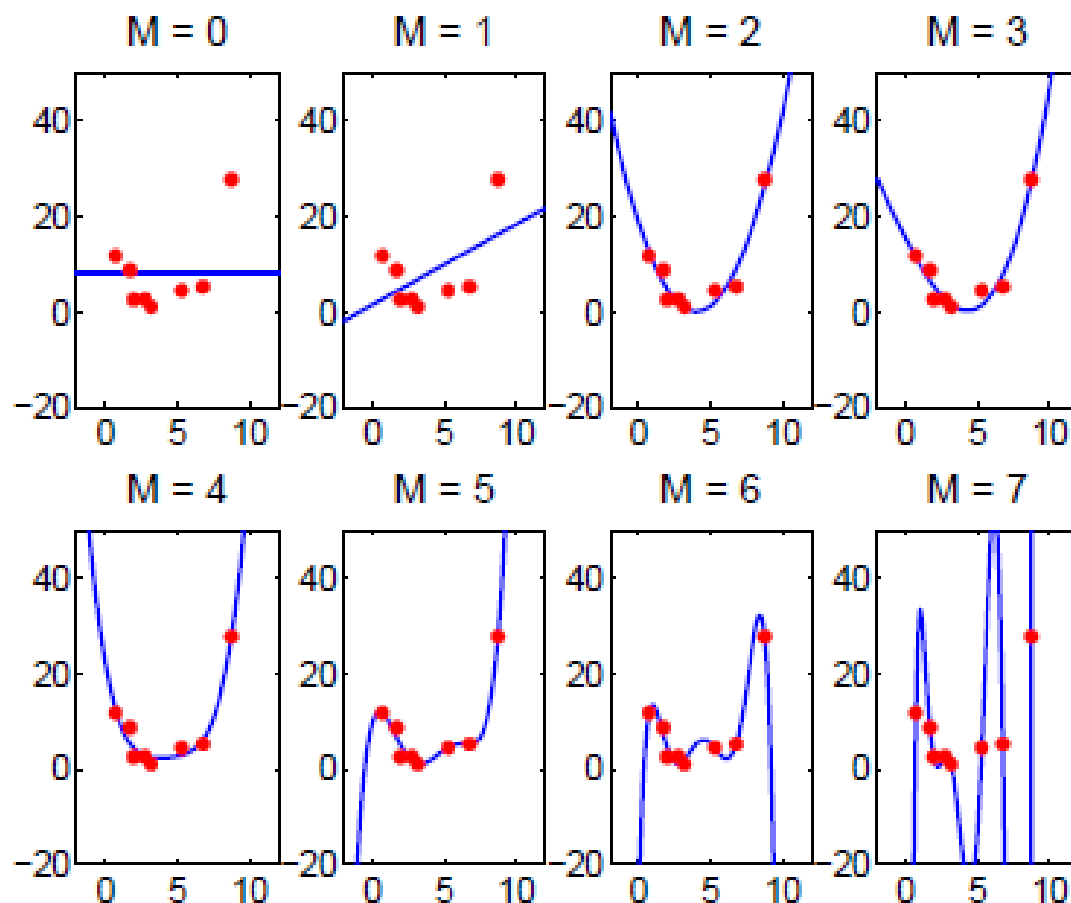
Tipično ponašanje



Primjer - klasifikacija



Primjer - regresija



Nastavak priče:

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