

Strojno učenje

Marko Bohanec
Institut Jožef Stefan, Ljubljana in
Univerza v Novi Gorici


Marko Bohanec

Kazalo

- Uvod
 - Zakaj strojno učenje?
 - Kaj je strojno učenje?
 - Zahteve strojnega učenja
 - Področja uporabe
 - Literatura in viri
- Metode strojnega učenja


Marko Bohanec

Arhitektura ES



Marko Bohanec

Strojno učenje



poročilo prof. Bogdan Gostinik, Strojno učenje

Marko Boharac


Primer

Dobiček	Starost	Konkurenca	Vrsta
pada	staro	ne	SW
pada	srednje	da	SW
narašča	srednje	ne	HW
pada	staro	ne	HW
narašča	novo	ne	HW
narašča	novo	ne	SW
narašča	srednje	ne	SW
narašča	novo	da	SW
pada	srednje	da	HW
pada	staro	da	SW

poročilo prof. Bogdan Gostinik, Strojno učenje

Marko Boharac

Primer: Odločitveno drevo



Uporaba:

1. opisuje zakonitosti v obstoječih podatkih
2. napoveduje (klasificira) nove primere

poročilo prof. Bogdan Gostinik, Strojno učenje

Marko Boharac

Metode strojnega učenja

- Statistične metode
 - Bayesov klasifikator
 - *k*-najbližjih sosedov (*k-Nearest Neighbors*, *k-NN*)
 - diskriminantna analiza
- Simbolično induktivno učenje
 - odločitvena drevesa (*Decision Trees*)
 - odločitvena pravila (*Decision Rules*)
 - učenje konceptov (*Concept Learning*)
 - indukcija logičnih programov (*ILP: Inductive Logic Programming*)
- Umetne nevronske mreže
 - večnivojske usmerjene NM
 - Kohonenove NM
 - Hopfieldove NM
 - Bayesove

Marko Bohanec

Zahteve pri strojnem učenju

- Zanesljivost delovanja
 - velika klasifikacijska točnost
- Transparentnost naučenega znanja
 - eksplicitna simbolična predstavitev, razumljiva ekspertom
- Sposobnost pojasnjevanja
 - argumentiranje in podpora ekspertnim odločitvam
- Odpornost na "šum" v podatkih
 - delovanje ob manjkajočih, nepopolnih ali nenatančnih podatkih
 - problemi iz realnega sveta


Marko Bohanec

Nekatera področja uporabe


- Medicina
 - Diagnostika in prognostika
- Industrija
 - Kontrola kvalitete
 - Procesna kontrola
- Upravljanje in odločanje
 - Analiza podatkov o poslovanju
- "Podatkovno rudarjenje" (*Data Mining*)

Marko Bohanec

Viri



Tom M. Mitchell: *Machine Learning*.
McGraw-Hill, 1997.



Igor Kononenko: *Strojno učenje, druga izdaja*.
Založba FE in FRI, 2005.

Marko Bohanec

Kazalo

- Uvod
- Metode strojnega učenja
 - Atributno učenje
 - Učenje odločitvenih dreves
 - Statistične metode
 - Umetne nevronske mreže
 - HINT: učenje hierarhičnih modelov (DEX)

Marko Bohanec

Atributno učenje

Podano:

- tabela "rešenih" primerov,
- opisanih z vrednostmi atributov A_1 do A_N
- in razredom C

C	A_1	A_2	$\dots$	A_N
C_1	$V_{1,1}$	$V_{1,2}$	$\dots$	$V_{1,N}$
C_2	$V_{2,1}$	$V_{2,2}$	$\dots$	$V_{2,N}$
$\dots$				
C_M	$V_{M,1}$	$V_{M,2}$	$\dots$	$V_{M,N}$

Naloga: poiskati pravilo za razred C glede na vrednosti A_1 do A_N

Marko Bohanec

Odločitvena drevesa

- Vozlišča predstavljajo pogoje (teste)
 - praviloma: preverjanje vrednosti atributa
 - pogosto: binarna vejitev (pogoji tipa $A = v$ ali $A \geq v$)
- Listi predstavljajo razrede
- Drevo omogoča klasifikacijo novih primerov:
 - začni pri korenu
 - potuj navzdol v skladu z rezultati testov
 - odgovor (razred) je v listu

Marko Bohanec

Učenje odločitvenih dreves

TDIDT: Top-Down Induction of Decision Trees

Oseba	Starost	Spol	Dohodki	Stranka
Ana Kranjc	32	Ž	10.000	da
Micka Kovač	53	Ž	1.000.000	da
Meta Novak	27	Ž	20.000	ne
Jana Bevc	55	Ž	20.000	da
Peter Dolenc	26	M	100.000	da
Janez Gorenc	50	M	200.000	da

primeri s posneti pos: Statistični inštitut Republike Slovenije

Marko Bohanec


Klasifikacija in regresija

- **Klasifikacija:**
 - razred C je diskretna spremenljivka
 - pravilo (Oseba, Starost, Spol, Dohodki) $\Rightarrow$ Stranka
- **Regresija:**
 - "razred" C je zvezna spremenljivka
 - pravilo (Oseba, Starost, Spol, Stranka) $\Rightarrow$ Dohodki

Marko Bohanec

Klasifikacijsko odločitveno drevo


Oseba	Starost	Spol	Dohodki	Stranka
Ana Kranjc	32	Ž	10.000	da
Micka Kovač	53	Ž	1.000.000	da
Mela Novak	27	Ž	20.000	ne
Jana Bevc	55	Ž	20.000	da
Peter Dolenc	26	M	100.000	da
Janez Gorenc	50	M	200.000	da



Marko Boharac

Regresijsko odločitveno drevo

Oseba	Starost	Spol	Dohodki	Stranka
Ana Kranjc	32	Ž	10.000	da
Micka Kovač	53	Ž	1.000.000	da
Mela Novak	27	Ž	20.000	ne
Jana Bevc	55	Ž	20.000	da
Peter Dolenc	26	M	100.000	da
Janez Gorenc	50	M	200.000	da



primeri praznati po: Baldo Džuranič, Džuranič, Trnava

Marko Boharac

Učenje odločitvenih dreves

KLJUČNI KONCEPTI


1. Gradnja drevesa
 - algoritem
 - izbiranje atributov
2. Preverjanje kakovosti drevesa
 - učna in testna množica
 - klasifikacijska točnost
3. Rezanje drevesa
 - rezanje naprej
 - rezanje nazaj

Marko Boharac

Gradnja klasifikacijskega drevesa

ALGORITEM

- Če vsi učni primeri pripadajo istemu razredu C , potem je rezultat list C
- Sicer
 - Izberi *najboljši* atribut A (ali *najboljšo* delitev po A)
 - Razdeli učno množico glede na vrednosti A
 - Rekurzivno zgradi poddrevesa $T_1..T_k$ za vsako podmnožico
 - Rezultat je drevo z vozliščem A in poddrevesi $T_1..T_k$



poročilo por. Biseri Gorenjki, Stran 10 od 10


Marko Boharac

Primer

Oseba	Starost	Spol	Dohodki	Stranka
Ana Kranjc	32	Ž	10.000	da
Micka Kovač	53	Ž	1.000.000	da
Meta Novak	27	Ž	20.000	ne
Jana Bevc	55	Ž	20.000	da
Peter Dolenc	26	M	100.000	da
Janez Gorenc	50	M	200.000	da

Vsi primeri v istem razredu?

Najboljša delitev?



Oseba	Starost	Spol	Dohodki	Stranka
Ana Kranjc	32	Ž	10.000	da
Meta Novak	27	Ž	20.000	ne
Jana Bevc	55	Ž	20.000	da

Oseba	Starost	Spol	Dohodki	Stranka
Micka Kovač	53	Ž	1.000.000	da
Peter Dolenc	26	M	100.000	da
Janez Gorenc	50	M	200.000	da

Marko Boharac

Izbiranje atributov (delitev)

ZAHTEVA: Delitev na čim bolj "čiste" podmnožice

MERE "NEČISTOČE"

za dva razreda, $p(C_1)=p_1$, $p(C_2)=p_2$

- Entropija E : $-p_1 \log_2 p_1 - p_2 \log_2 p_2$
- Napaka prevladujočega razreda: $1 - \max(p_1, p_2)$
- Indeks Gini: $1 - (p_1^2 + p_2^2)$

INFORMACIJSKI PRISPEVEK: Koliko pridobimo ob delitvi?

- $\text{Gain}(S, A) = E(S) - \sum_v |S_v|/|S| E(S_v)$
- maksimiziramo Gain

poročilo por. Biseri Gorenjki, Stran 11 od 10

Marko Boharac

Primer

(1 od 3)

Vreme	Temp	Vlaga	Veter	Tenis
sončno	vroče	visoka	ne	ne
sončno	vroče	visoka	da	ne
oblačno	vroče	visoka	ne	da
dež	zmešno	visoka	ne	da
dež	hladno	norm	ne	da
dež	hladno	norm	da	ne
oblačno	hladno	norm	da	da
sončno	zmešno	visoka	ne	ne
sončno	hladno	norm	ne	da
dež	zmešno	norm	ne	da
sončno	zmešno	norm	da	da
oblačno	zmešno	visoka	da	da
oblačno	vroče	norm	ne	da
dež	zmešno	visoka	da	ne

Vreme? sončno [2+, 3-] $E=0,97$
 oblačno [4+, 0-] $E=0$
 dež [3+, 2-] $E=0,97$

Vlaga? visoka [3+, 4-] $E=0,99$
 norm [6+, 1-] $E=0,59$

Veter? ne [6+, 2-] $E=0,81$
 da [3+, 3-] $E=1,00$

Martina Boharac

Primer

(2 od 3)

Veter? ne [6+, 2-] $E=0,81$
 da [3+, 3-] $E=1,00$

$\text{Gain}(S, A) = E(S) - \sum_v |S_v|/|S| E(S_v)$

$E(S) = E(9+, 5-) = -(9/14)\log_2(9/14) - (5/14)\log_2(5/14) = 0,94$

$E(S_{\text{Veter}=ne}) = 0,81$

$E(S_{\text{Veter}=da}) = 1,00$

$\text{Gain}(S, \text{Veter}) = 0,94 - (8/14)0,81 - (6/14)1,00 = \mathbf{0,048}$

$\text{Gain}(S, \text{Vreme}) = \mathbf{0,246 \text{ (max)}}$


$\text{Gain}(S, \text{Vlaga}) = \mathbf{0,151}$

$\text{Gain}(S, \text{Temp}) = \mathbf{0,029}$

Martina Boharac

Primer

(3 od 3)



Martina Boharac

Mere kvalitete odločitvenih dreves

Klasifikacijska točnost:

Kako točno drevo klasificira nove primere?
Kakšna je točnost v primerjavi z *apriorno* ("naivni klasifikator")?

Razumljivost:

Ali ekspert razume drevo in njegovo vsebino?
Ali ga lahko interpretira, utemelji?

Velikost:


Povezano z razumljivostjo: zaželeno čim manjša drevesa!

Marko Bohanec

Klasifikacijska točnost

Postopek gradnje in preverjanja klasifikatorja:

- množico primerov S razdelimo na:
 - **učno** množico U (npr. 70%) in
 - **testno** množico T (30%)
- zgradimo drevo upoštevajoč samo U
- na T preverimo **točnost klasifikacije** = delež pravilnih klasifikacij




Marko Bohanec

Prečno preverjanje

Slov: Prečno preverjanje, npr. "10-kratno prečno preverjanje"
Angl: "Cross validation", e.g., "10-fold cross validation"

Postopek preverjanja klasifikatorja:

- celotno množico primerov S naključno razdelimo na n čim bolj enakih delov
- n krat ponovimo: učimo na $n-1$ delih, testiramo na preostalem enem delu
- celotna točnost klasifikacije je povprečje n takšnih klasifikacij



Marko Bohanec


Rezanje dreves

Spodnji deli drevesa (okrog listov) so manj zanesljivi:

- manjše število učnih primerov
- prevelika prilagoditev podatkom (*overfitting*)

Rezanje (*pruning*):

- **Naprej**: predčasno ustavimo gradnjo
- **Nazaj**: drevo zgradimo do konca, nato režemo manj zanesljive dele (bolje!)




Pridobimo:

- Manjše drevo – večja preglednost in razumljivost
- Večja točnost na testni množici primerov

Marko Bohanec


Rezanje dreves

Klasifikacijska točnost v odvisnosti od velikosti drevesa



Marko Bohanec

Od dreves k pravilom



PRAVILA

```

if Dohodki ≥ 100.000
then Stranka=da
if Dohodki < 100.000 and
Starost ≥ 32
then Stranka=da
if Dohodki < 100.000 and
Starost < 32
then Stranka=ne
  
```

ODLOČITVENI SEZNAM

```

if Dohodki ≥ 100.000
then Stranka=da
else if Starost ≥ 32
then Stranka=da
else Stranka=ne
  
```

Marko Bohanec

Nekaj učnih algoritmov in programov

KLASIFIKACIJA


- ID3 (Quinlan 1979)
- CART (Breiman et al. 1984)
- Assistant (Čestnik et al. 1987)
- C4.5 (Quinlan 1993)

REGRESIJA

- CART (Breiman et al. 1984)
- RETIS (Karalič 1992)
- M5 (Quinlan 1993)
- C5.0, See5 (RuleQuest)
- Cubist (RuleQuest)
 - Weka (Waikato University, NZ)
 - Orange (Univerza v Ljubljani, FRI)

Marko Boharac

See5 (RuleQuest)




<http://www.rulequest.com/>

Marko Boharac


Weka

<http://www.cs.waikato.ac.nz/~ml/weka/>



Marko Boharac

<http://magix.fri.uni-lj.si/orange/>



- Uvod
- Metode strojnega učenja
 - Atributno učenje
 - Učenje odločitvenih dreves
 - Statistične metode
 - Bayesovo pravilo
 - k-NN: k najbližjih sosedov
 - Umetne nevronske mreže
 - HINT: učenje hierarhičnih modelov (DEX)

- Bayesovo pravilo: verjetnost razreda C pri pogoju $V_1 \dots V_n$

$$P(C|V_1..V_n) = P(C) \frac{P(V_1..V_n|C)}{P(V_1..V_n)}$$

- “Naivno” Bayesovo pravilo: predpostavka neodvisnosti $V_1, \dots, V_n$

$$P(C|V_1..V_n) = P(C) \prod_{i=1}^n \frac{P(C|V_i)}{P(C)}$$

Primer

Vreme	Temp	Vlaga	Veter	Tenis
sončno	vroče	visoka	ne	ne
sončno	vroče	visoka	da	ne
oblačno	vroče	visoka	ne	da
dež	zmejno	visoka	ne	da
dež	hladno	norm	ne	da
dež	hladno	norm	da	ne
oblačno	hladno	norm	da	da
sončno	zmejno	visoka	ne	ne
sončno	hladno	norm	ne	da
dež	zmejno	norm	ne	da
sončno	zmejno	norm	da	da
oblačno	zmejno	visoka	da	da
oblačno	vroče	norm	ne	da
dež	zmejno	visoka	da	ne

Vreme	Temp	Vlaga	Veter	Tenis
sončno	hladno	norm	da	?

$$P(C|V_1 \dots V_n) = P(C) \prod_{i=1}^n \frac{P(C|V_i)}{P(C)}$$

$$P(da|son, hla, norm, da) =$$

$$= P(da) \frac{P(da|son)}{P(da)} \frac{P(da|hla)}{P(da)} \frac{P(da|norm)}{P(da)} \frac{P(da|da)}{P(da)}$$

$$= \frac{9}{14} \left(\frac{2}{5} \right) \left(\frac{3}{4} \right) \left(\frac{1}{4} \right) \left(\frac{6}{7} \right) \left(\frac{1}{9} \right) \left(\frac{3}{6} \right) \left(\frac{1}{9} \right) = 0,48$$

$\Rightarrow$ **Tenis=da**

$$P(ne|son, hla, norm, da) =$$

$$= P(ne) \frac{P(ne|son)}{P(ne)} \frac{P(ne|hla)}{P(ne)} \frac{P(ne|norm)}{P(ne)} \frac{P(ne|da)}{P(ne)}$$

$$= \frac{5}{14} \left(\frac{3}{5} \right) \left(\frac{1}{4} \right) \left(\frac{1}{5} \right) \left(\frac{1}{7} \right) \left(\frac{1}{6} \right) \left(\frac{3}{5} \right) \left(\frac{1}{4} \right) = 0,24$$


Marko Bolharac

K-najbližjih sosedov (k-NN)

- Pri klasifikaciji primera $X = V_1 \dots V_n$ v učni množici poiščemo k najbližjih sosedov
- Primer X klasificiramo v večinski razred C

Definirati je potrebno:

- k
- mero razdalje med primeri



Marko Bolharac

Primer

Vreme	Temp	Vlaga	Veter	Tenis	Razd
sončno	vroče	visoka	ne	ne	4
sončno	vroče	visoka	da	ne	3
oblačno	vroče	visoka	ne	da	5
dež	zmejno	visoka	ne	da	5
dež	hladno	norm	ne	da	3
dež	hladno	norm	da	ne	2
oblačno	hladno	norm	da	da	1
sončno	zmejno	visoka	ne	ne	3
sončno	hladno	norm	ne	da	1
dež	zmejno	norm	ne	da	4
sončno	zmejno	norm	da	da	1
oblačno	zmejno	visoka	da	da	3
oblačno	vroče	norm	ne	da	4
dež	zmejno	visoka	da	ne	4

Vreme	Temp	Vlaga	Veter	Tenis
sončno	hladno	norm	da	?

$k = 4$, razdalja "Manhattan"

$\Rightarrow$ **Tenis=da (3:1)**

Marko Bolharac


Kazalo

- Uvod
- Metode strojnega učenja
 - Atributno učenje
 - Učenje odločitvenih dreves
 - Statistične metode
 - Bayesovo pravilo
 - k -NN: k najbližjih sosedov
 - Umetne nevronske mreže
 - HINT: učenje hierarhičnih modelov (DEX)

Marko Bohanec

Umetne nevronske mreže

Naravni nevron




Umetni nevron

Izhod: $f(\sum_{i,i \neq k} w_{ik} X_i)$

Stanje: 1 ali -1


Uteži: w_{1k}, w_{2k}, w_{nk}

Vhodi: X_1, X_2, X_n



Marko Bohanec

Primer: XOR (ekskluzivni "ali")




X_1	X_2	Y
1	1	-1
1	-1	1
-1	1	1
-1	-1	-1

Marko Bohanec

Primer

Vreme	Temp	Vlaga	Veter	Tenis
sončno	vroče	visoka	ne	ne
sončno	vroče	visoka	da	ne
oblačno	vroče	visoka	ne	da
dež	zmerno	visoka	ne	da
dež	hladno	norm	ne	da
dež	hladno	norm	da	ne
oblačno	hladno	norm	da	da
sončno	zmerno	visoka	ne	ne
sončno	hladno	norm	ne	da
dež	zmerno	norm	ne	da
sončno	zmerno	norm	da	da
oblačno	zmerno	visoka	da	da
oblačno	vroče	norm	ne	da
dež	zmerno	visoka	da	ne



Marko Boharac

Lastnosti umetnih nevronske mreže

- Matematična osnova
linearna algebra
- Paralelizem
nevroni hkrati izvajajo operacije
- Večsmerno izvajanje
vhod je lahko tudi izhod in obratno
- Robustnost
majhna občutljivost na okvare nevronov in sinaps
- Učenje
s spontanim spreminjanjem uteži
razmeroma počasno
- Razlaga odločitve
slaba, praktično nemogoča

Marko Boharac

Kazalo


- Uvod
- Metode strojnega učenja
 - Atributno učenje
 - Učenje odločitvenih dreves
 - Statistične metode
 - Bayesovo pravilo
 - k-NN: k najbližjih sosedov
 - Umetne nevronske mreže
 - HINT: učenje hierarhičnih modelov (DEX)

Marko Boharac

HINT: Učenje hierarhičnih modelov


Cilj: učenje hierarhičnih modelov tipa DEX

Algoritem temelji na Ashenhurst-Curtisovi dekompoziciji logičnih funkcij




Marko Bohanec

HINT: Osnovni korak




Marko Bohanec

HINT: Izbira najboljše delitve



Marko Bohanec

HINT: Oblikovanje hierarhije konceptov



Marko Bohanec

Strojno učenje: Povzetek

- Rešujejo problem "ozkega grla" (*Feigenbaum's Bottleneck*)
- Učenje je "avtomatizirano" (skupaj z ekspertom), ne "avtomatsko"
- Številne metode: statistične, simbolične, nevronske mreže
- Pomembni koncepti:
 - klasifikacija, regresija
 - klasifikacijska točnost
 - razumljivost, velikost modelov
 - učna in testna množica
 - prilagoditev podatkom (*overfitting*)
- Odločitvena drevesa: razširjena, pogosta uporaba; koncept rezanja
- Statistične metode: dobre, a ne gradijo opisov konceptov
- Nevronske mreže: zanimive lastnosti, zahtevno učenje, problem razumljivosti
- HINT: učenje konceptov po načelu razgradnje funkcij

Marko Bohanec