Klasifikacija – Stabla odlučivanja

NIKOLA MILIKIĆ

EMAIL: nikola.milikic@fon.bg.ac.rs

URL: http://nikola.milikic.info

Šta je klasifikacija?

- Zadatak određivanja klase kojoj neka instanca pripada
  - instanca je opisana vrednošću atributa;
  - skup mogućih klasa je poznat i dat

Stabla odlučivanja

Primer: Kupovina automobila

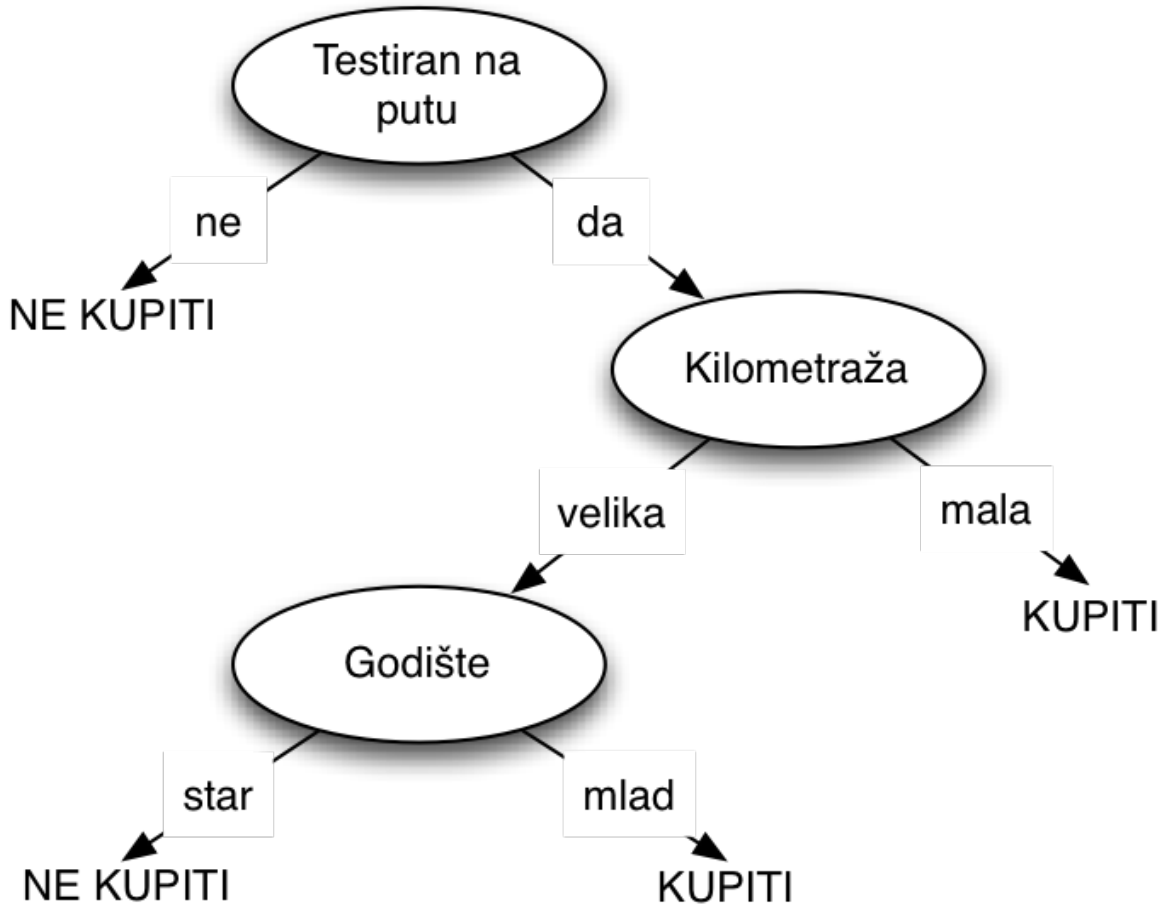

ID3 algoritam

- ID3 - Iterative Dichotomiser 3
- Jedan od najpoznatijih algoritama za generisanje stabla odlučivanja na osnovu datog skupa primera (dataseta)
- Rezultujuće stablo namenjeno je klasifikaciji novih (nepoznatih) instanci

Primer – Predviđanje da li će se predstava odigrati

ToPlayOtNotToPlay.arff dataset

Outlook	Temp.	Humidity	Windy	Play
sunny	hot	high	false	no
sunny	hot	high	true	no
overcast	hot	high	false	yes
rainy	mild	high	false	yes
rainy	cool	normal	false	yes
rainy	cool	normal	true	no
overcast	cool	normal	true	yes
sunny	mild	high	false	no
sunny	cool	normal	false	yes
rainy	mild	normal	false	yes
sunny	mild	normal	true	yes
overcast	mild	high	true	yes
overcast	hot	normal	false	yes
rainy	mild	high	true	no

Top-down pristup

Rekurzivno podeli i vladaj:

- Odabrati atribut za čvor stabla
  - kreirati granu za svaku vrednost atributa
- Podeliti instance na podskupove
  - po jedan podskup za svaku vrednost atributa
- Ponavljati rekurzivno za svaku granu
  - koristeći samo instance date grane
- Stati
  - kada sve instance u datoj grani imaju istu klasu (tzv. čist čvor)

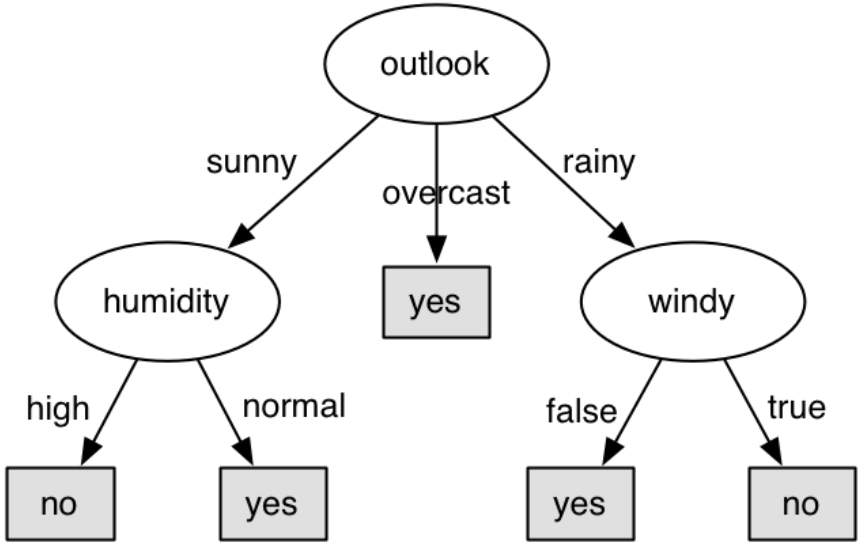

Koji atribut odabrati?

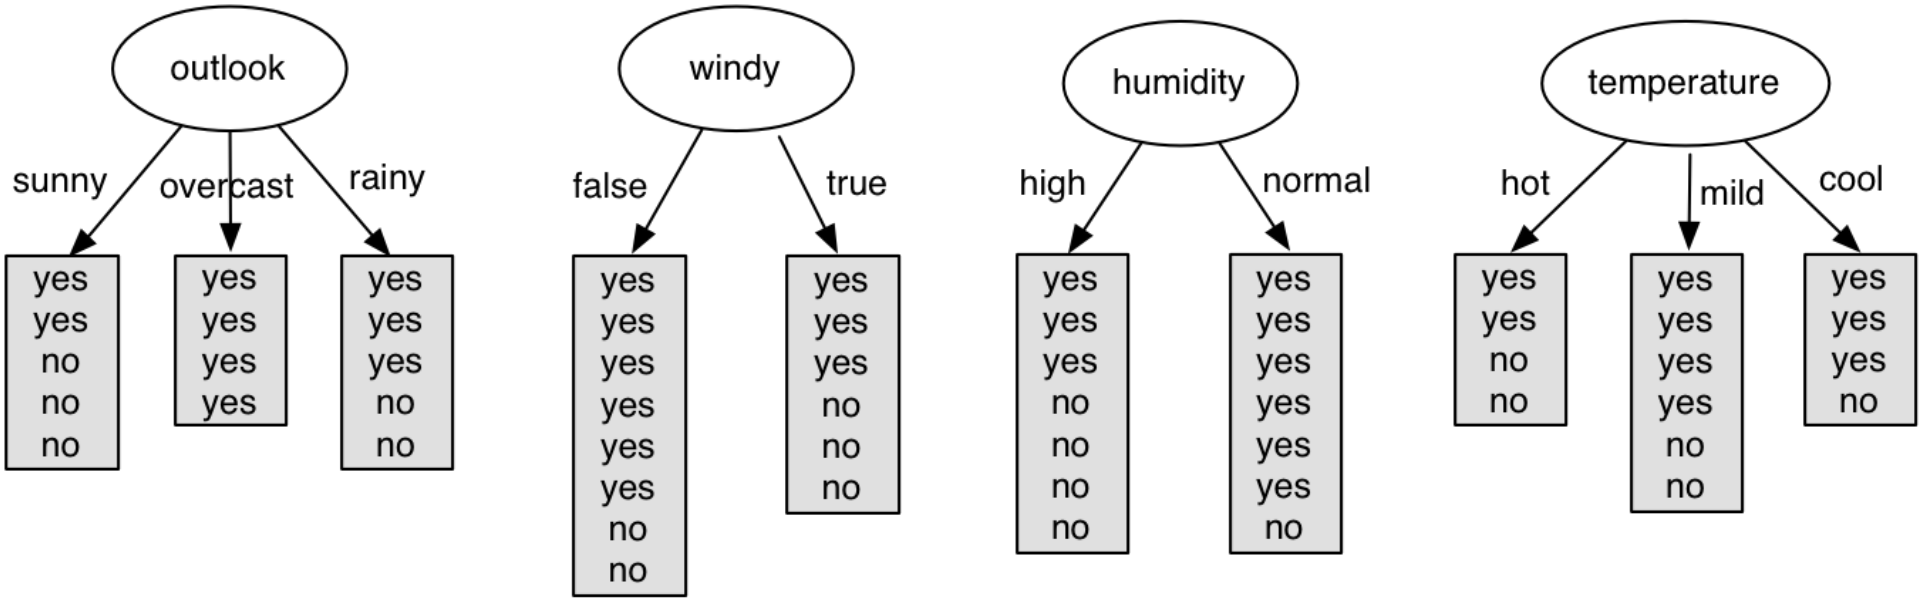

Koji atribut odabrati?

- **Cilj**: kreirati najmanje stablo sa što je moguće većom prediktivnom moći
- **Kako**: koristeći metrike iz teorije informacija: entropiju i informacionu dobit
- **Entropija** kvantifikuje stepen neizvesnoti po pitanju vrednosti neke slučajne promenljive ili po pitanju ishoda slučajnog događaja
- **Informaciona dobit** kvantifikuje smanjenje entropije (neizvesnosti) kroz sticanje znanja (tj mogućnost pristupa podacima) o slučajnoj promenljivoj / procesu

Entropija dataset-a

U kontekstu problema klasifikacije, entropija (H) se odnosi na neizvesnost po pitanju pripadnosti instanci nekoj od raspoloživih klasa

$$H(S) = -\sum_{i=1}^{N} p_i \log_2 p_i$$

gde je:

- *H(S)* – entropija skupa S (skup svih instanci u dataset-u)
- N – broj mogućih ishoda (tj raspoloživih klasa)
- p_i – verovatnoća ishoda i (tj određene klase)

Entropija dataset-a

Od ukupno 14 instanci u dataset-u iz razmatranog primera, imamo:

- 9 instanci “yes”
- 5 instanci “no”

$$H(S) = -\sum_{i=1}^{N} p_i \log_2 p_i$$

$$H(S) = -\frac{9}{14}\log_2 \frac{9}{14} - \frac{5}{14}\log_2 \frac{5}{14} = 0.940$$

Informaciona dobit

- Informaciona dobit *Gain(A, S)* atributa A nad skupom instanci S predstavlja količinu informacija koja se dobija poznavanjem vrednosti atributa A
- Informaciona dobit predstavlja razliku entropije pre grananja i entropije nakon grananja nad atributom A

Informaciona dobit

$$Gain(A,S) = H(S) - H(A,S) = H(S) - \sum_{j=1}^{v} \frac{|S_j|}{|S|} \cdot H(S_j)$$

gde je:

- H(S) – entropija skupa instanci S
- H(A, S) – entropija atributa A u okviru skupa S
- $|S_j|$ – broj instanci sa *j*-tom vrednošću atributa A
- |S| – ukupan broj instanci u skupu S
- v – broj mogućih vrednosti atributa A
- $H(S_j)$ – entropija podskupa instanci sa *j*-tom vrednošću atributa A

Biramo atribut sa najvećom informacionom dobiti

Informaciona dobit atributa “windy”

- Od ukupno 14 instanci imamo:
  - 8 instanci “false”
  - 6 instanci “true”

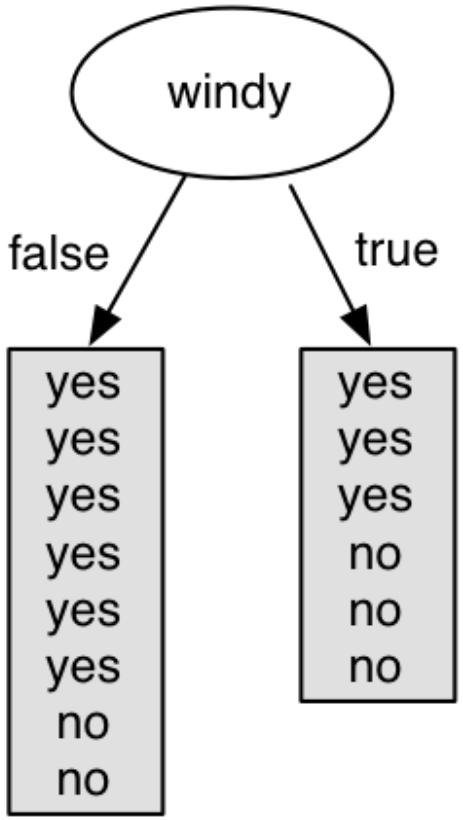

$$Gain(A,S) = H(S) - \sum_{j=1}^{v} \frac{|S_j|}{|S|} \cdot H(S_j)$$

$$Gain(A_{Windy}, S) = 0.940 - \frac{8}{14} \cdot \left(-\left(\frac{6}{8} \cdot \log_2 \frac{6}{8} + \frac{2}{8} \cdot \log_2 \frac{2}{8} \right) \right) - \frac{6}{14} \cdot \left(-\left(\frac{3}{6} \cdot \log_2 \frac{3}{6} + \frac{3}{6} \cdot \log_2 \frac{3}{6} \right) \right) = 0.048$$

Informaciona dobit atributa "outlook"

- Od ukupno 14 instanci imamo:
  - 5 instanci "sunny"
  - 4 instanci "overcast"
  - 5 instanci "rainy"

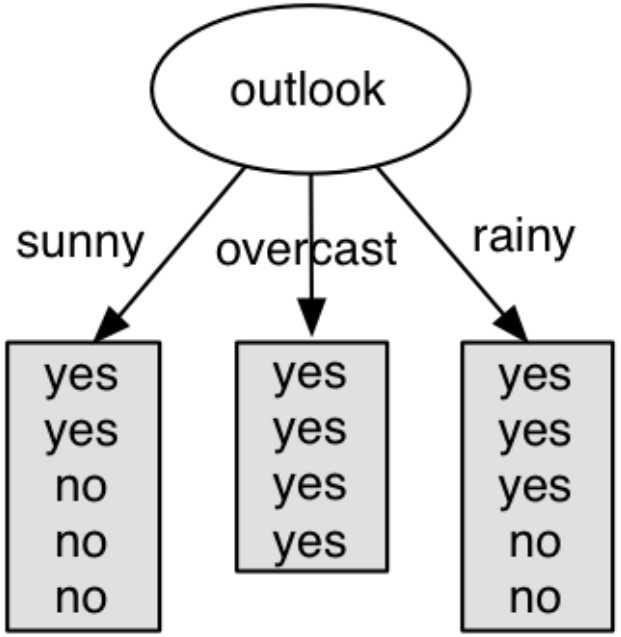

$$Gain(A_{Outlook}, S) = 0.940 - \frac{5}{14} \cdot \left(-\left(\frac{2}{5}\log_2\frac{2}{5} + \frac{3}{5}\log_2\frac{3}{5}\right)\right) - \frac{4}{14} \cdot \left(-\left(\frac{4}{4}\log_2\frac{4}{4}\right)\right) - \frac{5}{14} \cdot \left(-\left(\frac{3}{5} \cdot \log_2\frac{3}{5} + \frac{2}{5} \cdot \log_2\frac{2}{5}\right)\right) = 0.247$$

Informaciona dobit atributa "humidity"

- Od ukupno 14 instanci imamo:
  - 7 instanci "high"
  - 7 instanci "normal"

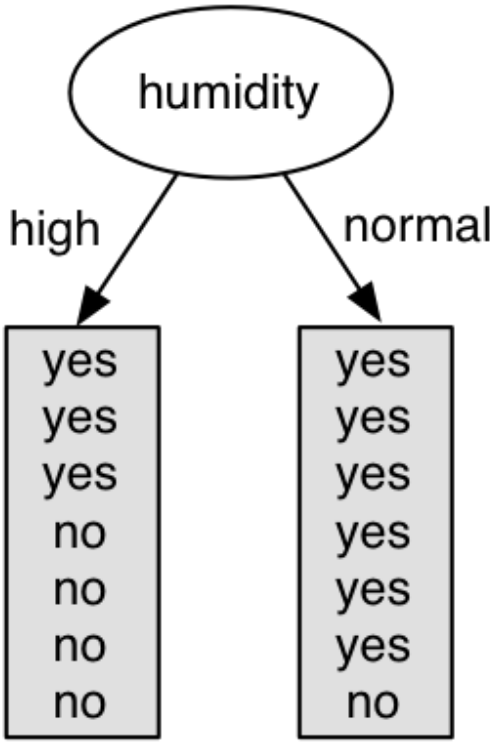

$$Gain(A_{Humidity}, S) = 0.940 - \frac{7}{14} \cdot \left(-\left(\frac{3}{7} \cdot \log_2 \frac{3}{7} + \frac{4}{7} \cdot \log_2 \frac{4}{7}\right)\right) - \frac{7}{14} \cdot \left(-\left(\frac{6}{7} \cdot \log_2 \frac{6}{7} + \frac{1}{7} \cdot \log_2 \frac{1}{7}\right)\right) = 0.151$$

Informaciona dobit atributa "temperature"

- Od ukupno 14 instanci imamo:
  - 4 instance "hot"
  - 6 instanci "mild"
  - 4 instanci "cool"

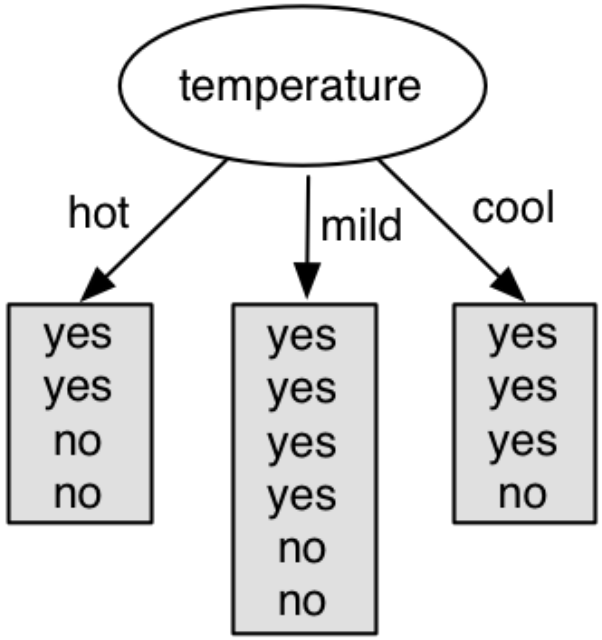

$$Gain(A_{Temperature}, S) = 0.940 - \frac{4}{14} \cdot \left(-\left(\frac{2}{4} \cdot \log_2 \frac{2}{4} + \frac{2}{4} \cdot \log_2 \frac{2}{4}\right)\right) - \frac{6}{14} \cdot \left(-\left(\frac{4}{6} \cdot \log_2 \frac{4}{6} + \frac{2}{6} \cdot \log_2 \frac{2}{6}\right)\right) - \frac{4}{14} \cdot \left(-\left(\frac{3}{4} \cdot \log_2 \frac{3}{4} + \frac{1}{4} \cdot \log_2 \frac{1}{4}\right)\right) = 0.029$$

Koji atribut odabrati?

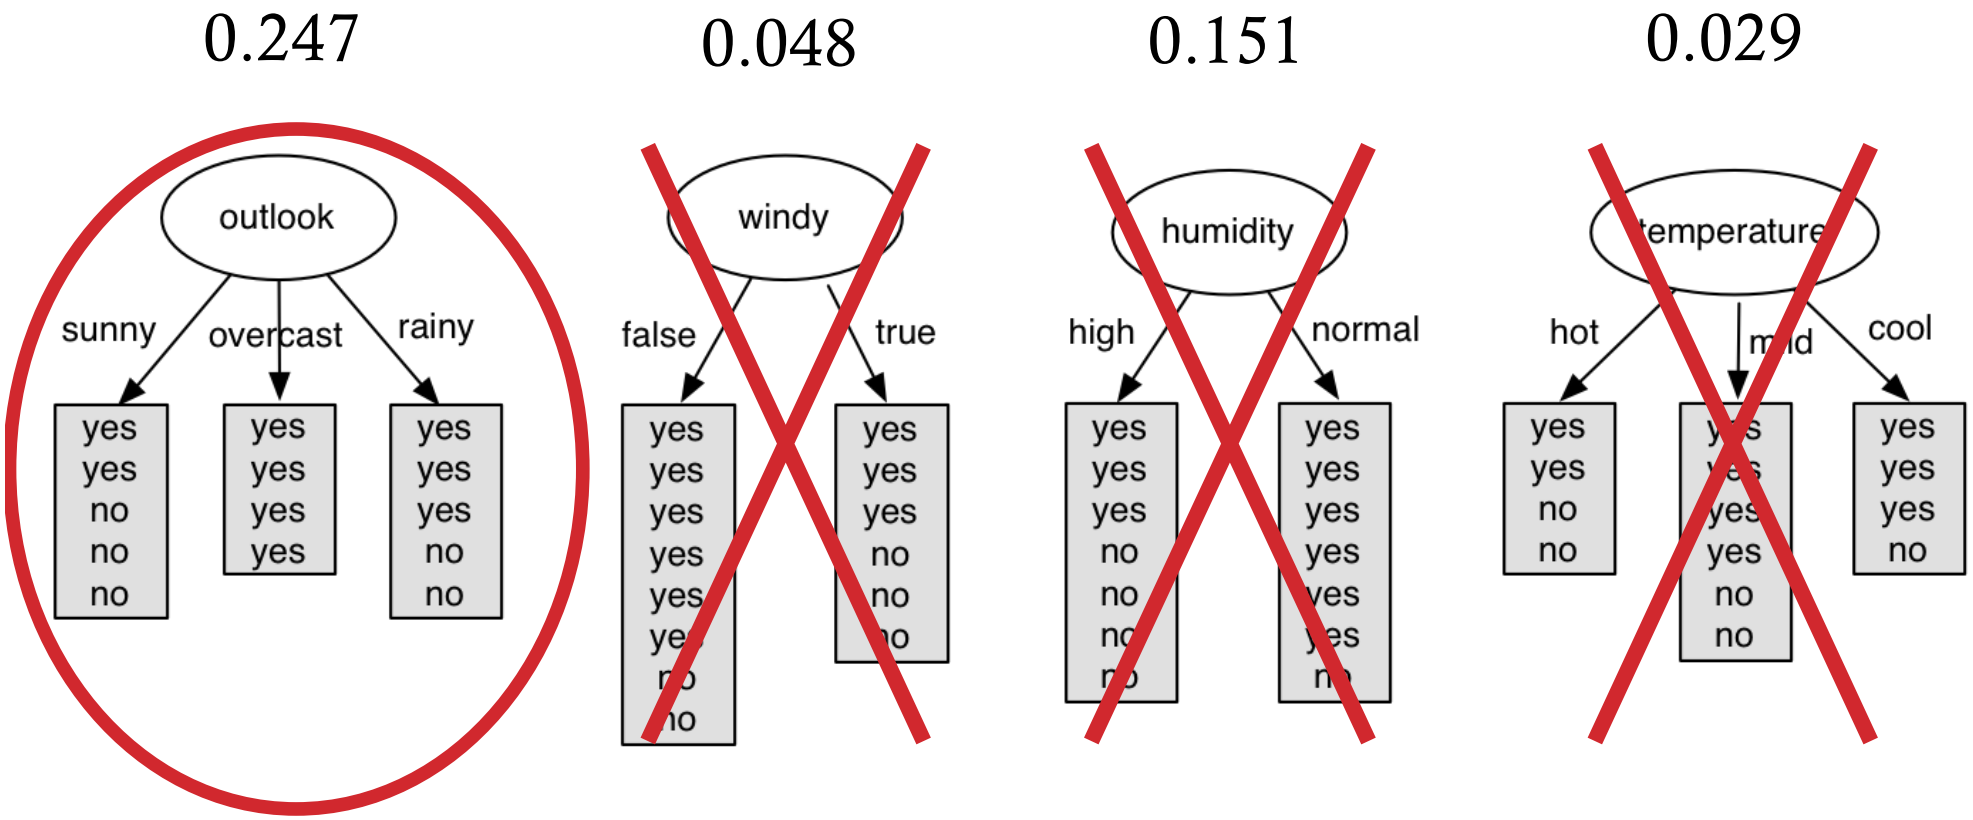

Biramo atribut sa najvećom informacionom dobiti

Iteracija 2: Ponavljamo postupak za svaku granu

0.571

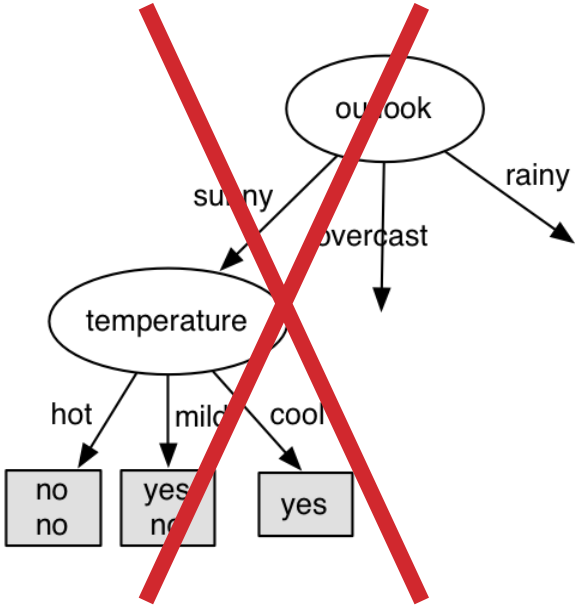

0.020

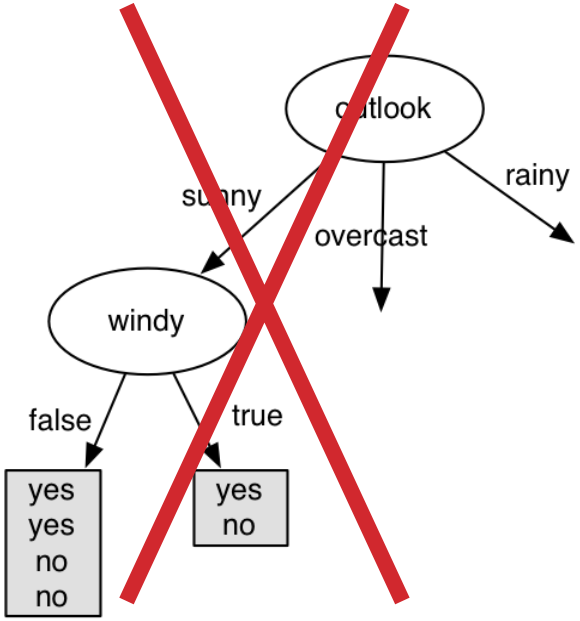

0.971

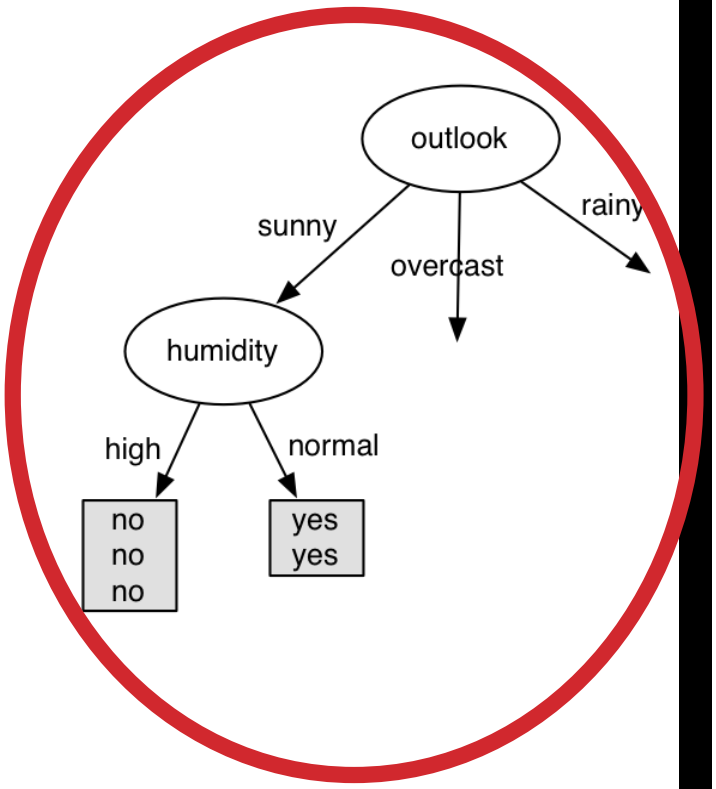

Iteracija 2: Ponavljamo postupak za svaku granu

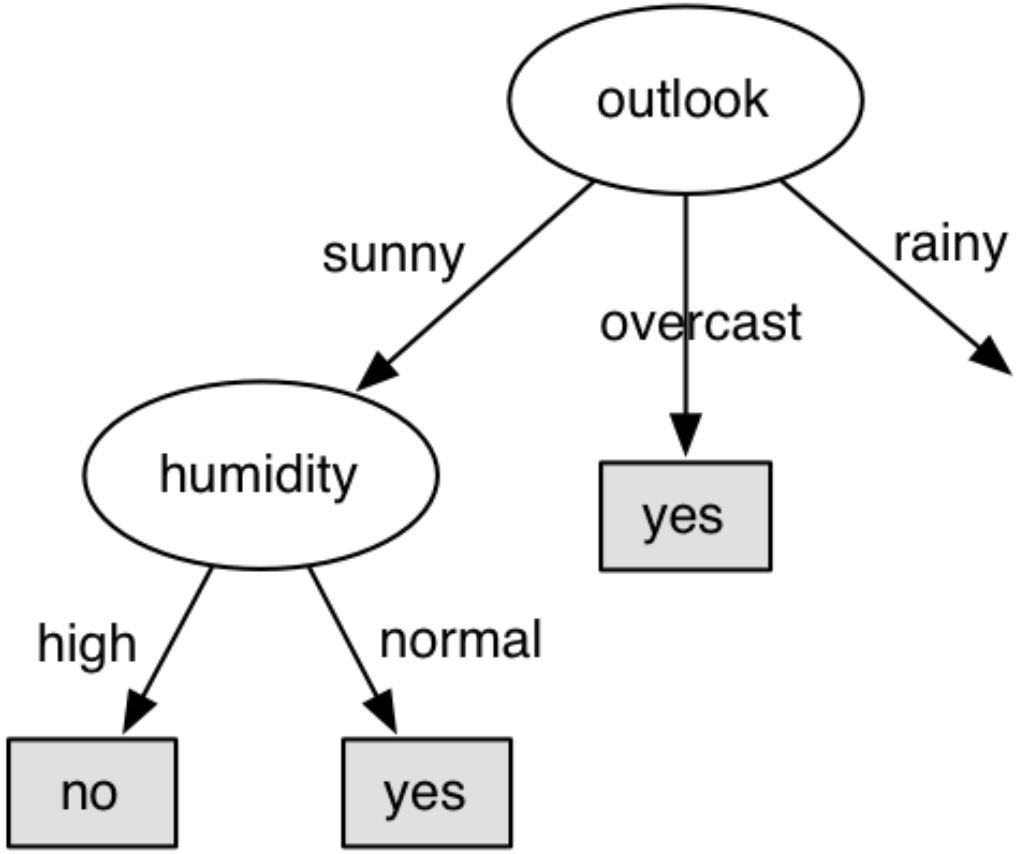

Iteracija 2: Ponavljamo postupak za svaku granu

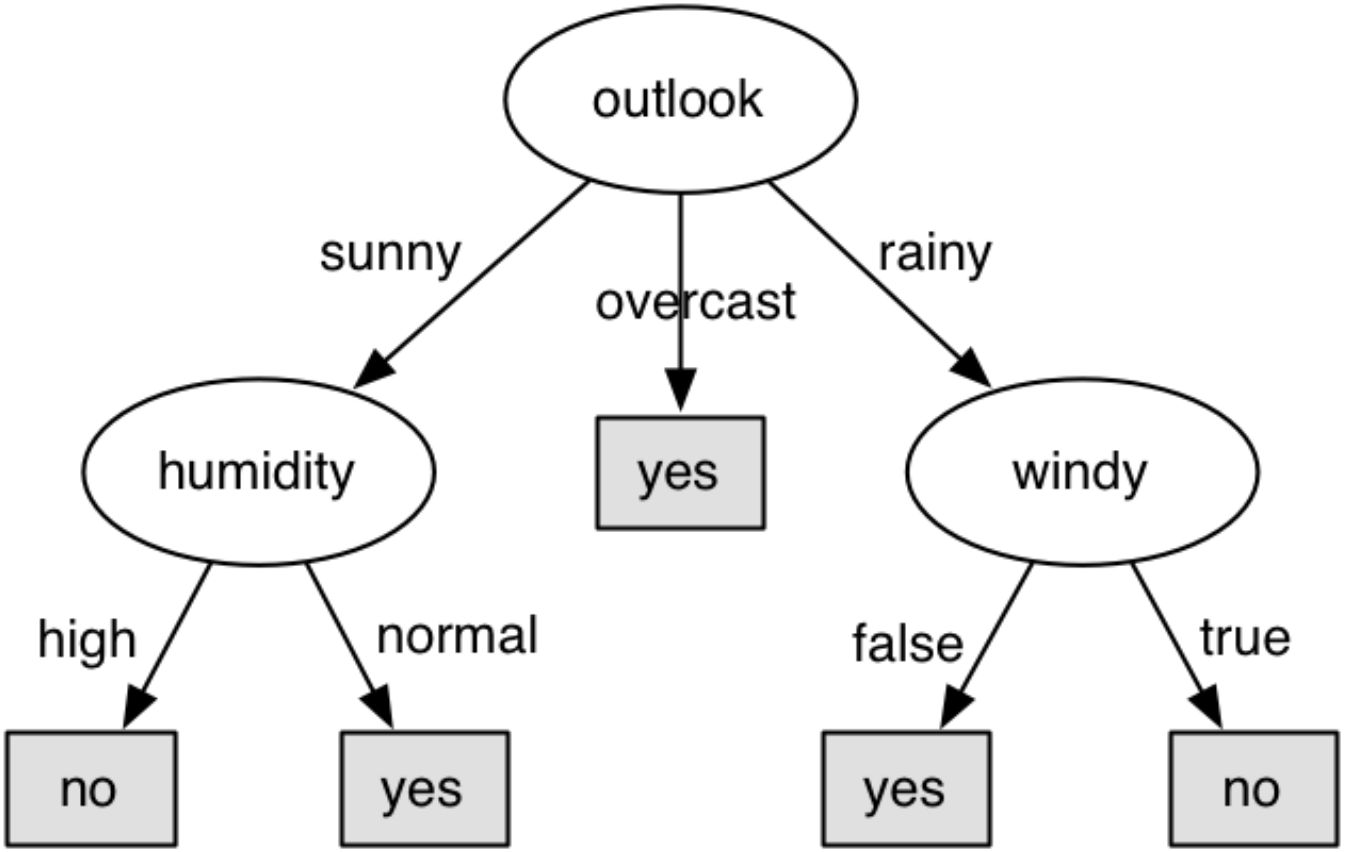

Weka

- Softver za mašinsko učenje i data mining u Javi
- Implementira veliki broj algoritama za mašinsko učenje i data mining
- Razvijen pri Univerzitetu Waikato, Novi Zeland
- Open-source
- Vebsajt: http://www.cs.waikato.ac.nz/ml/weka

ARFF fajl

- Attribute-Relation File Format – ARFF
- Tekstualni fajl

Atributi mogu biti:
- Numerički
- Nominalni

```
@relation TPONTPNom

@attribute Outlook {sunny, overcast, rainy}
@attribute Temp. {hot, mild, cool}
@attribute Humidity {high, normal}
@attribute Windy {false, true}
@attribute Play {no, yes}

@data
sunny, hot, high, false, no
sunny, hot, high, true, no
overcast, hot, high, false, yes
...
```

Skupovi podataka korišćeni na vežbama

Skupovi podataka raspoloživi na sajtu Technology Forge:

http://www.technologyforge.net/Datasets

Učitavanje fajla sa podacima

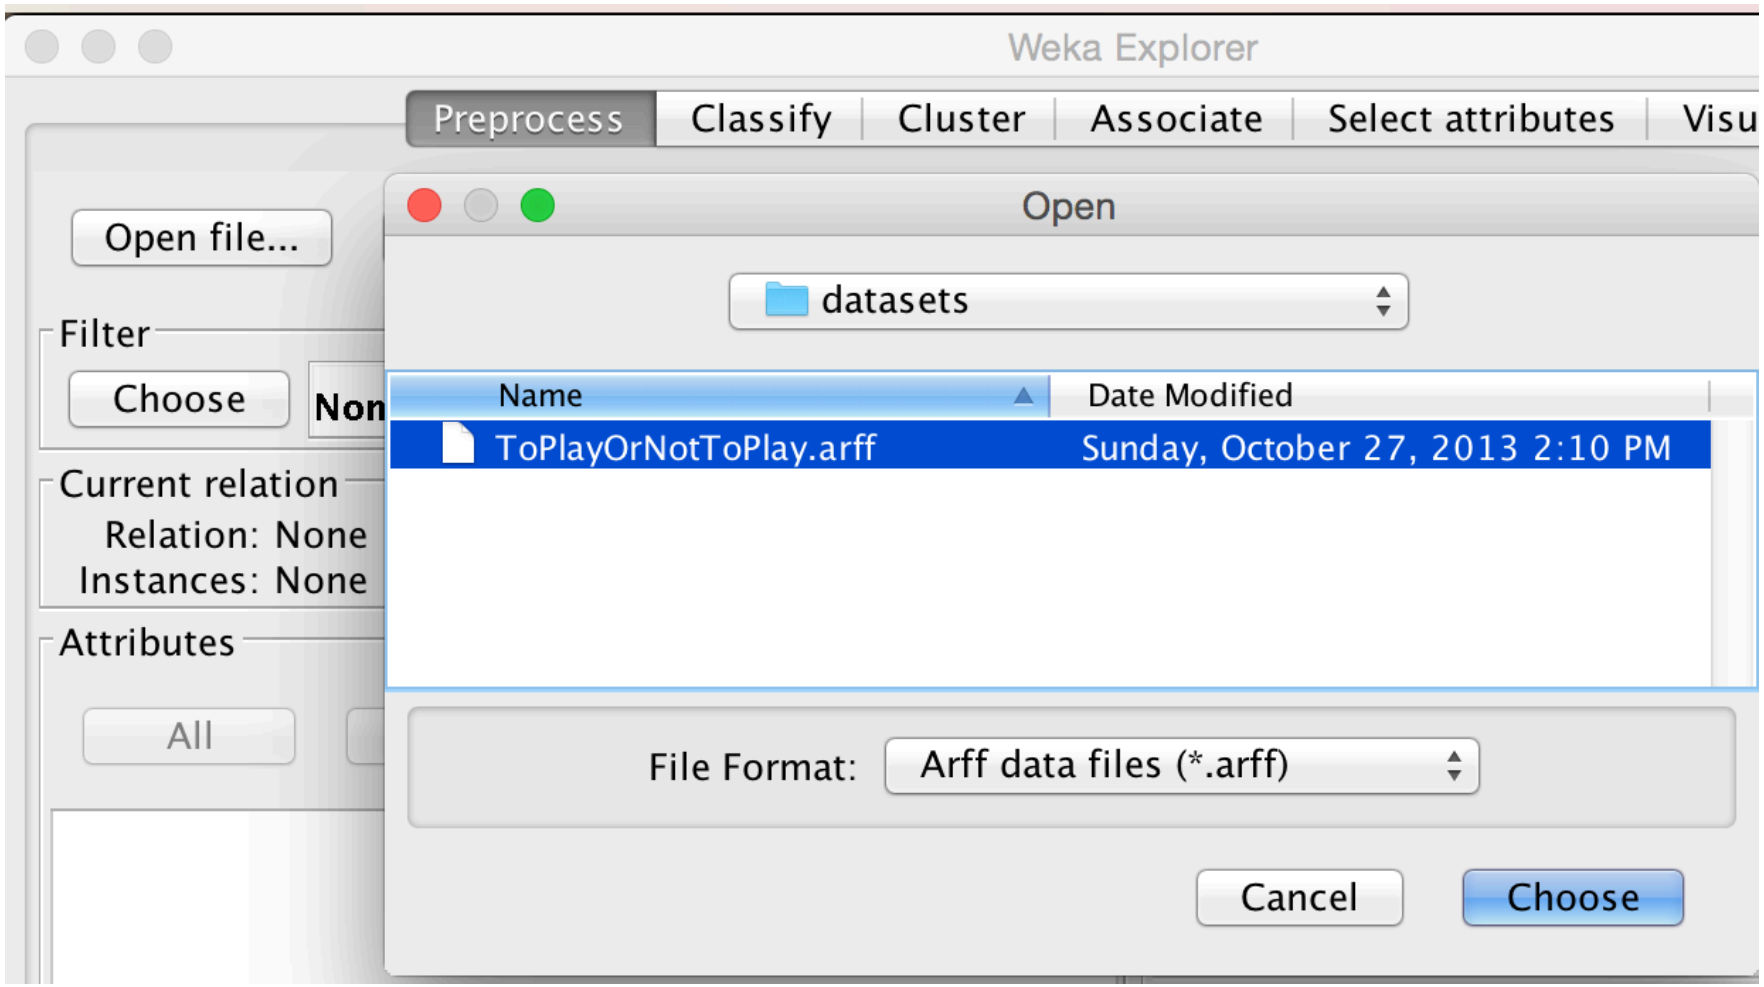

Pregled dataset-a

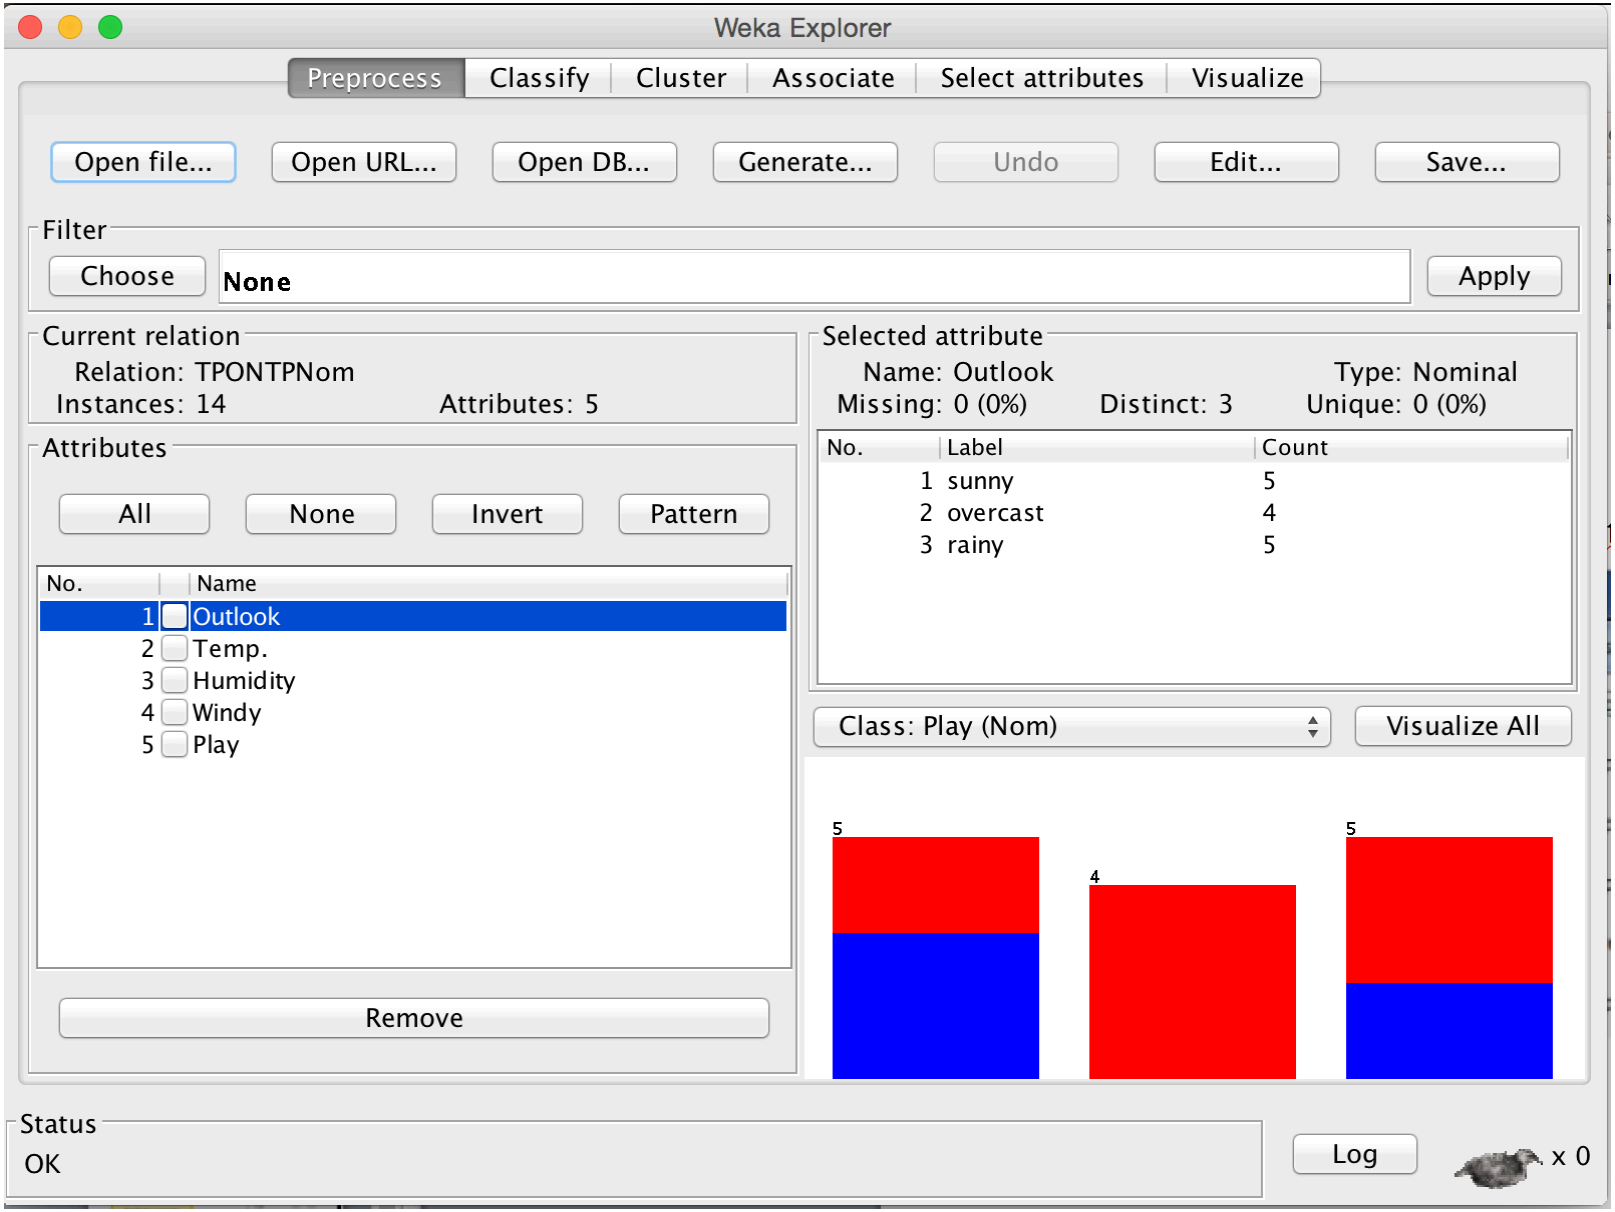

J48 klasa

- Implementacija C4.5 algoritma za kreiranje stabla odlučivanja
- C4.5 algoritam je proširenje ID3 algoritma
- Poboljšanja u odnosu na ID3 algoritam:
  - radi sa kontinualnim i diskretnim atributima
  - podržava nedostajuće vrednosti atributa (ne uzima u obzir instance sa nedostajućim vrednostima pri računanju entropije i informacione dobiti)
  - vrši orezivanje stabla nakon kreiranja
- Ross Quinlan (1993). C4.5: Programs for Machine Learning. Morgan Kaufmann Publishers, San Mateo, CA.

Odabir klasifikatora J48

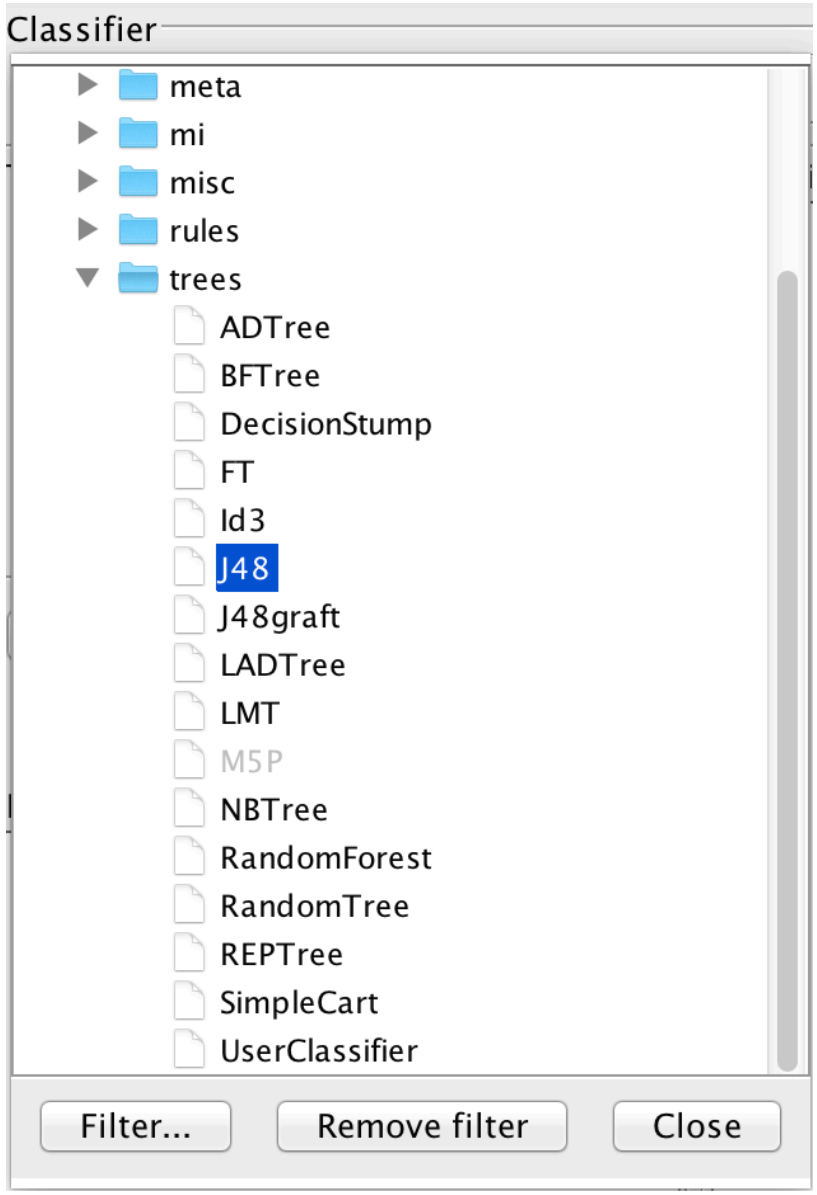

Treniranje klasifikatora

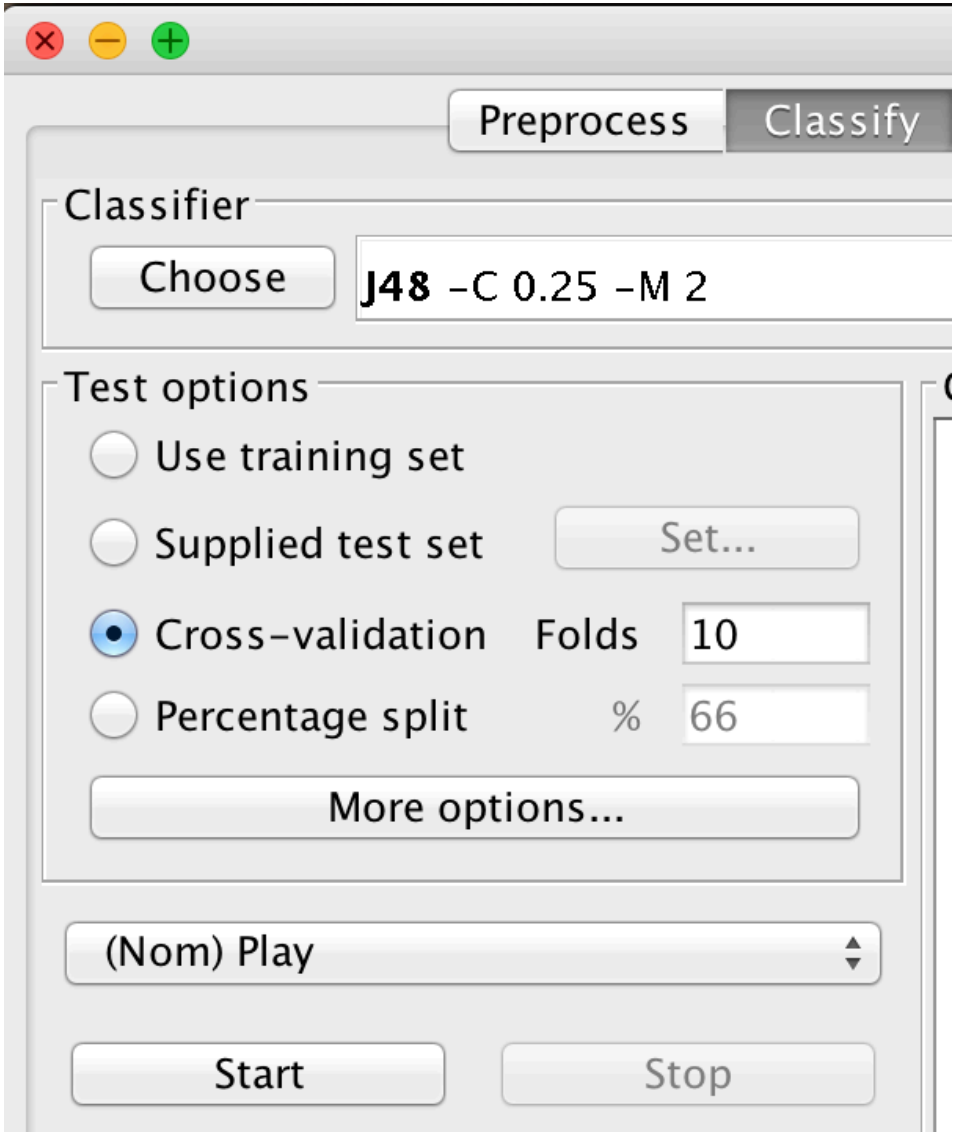

Pregled rezultata klasifikacije

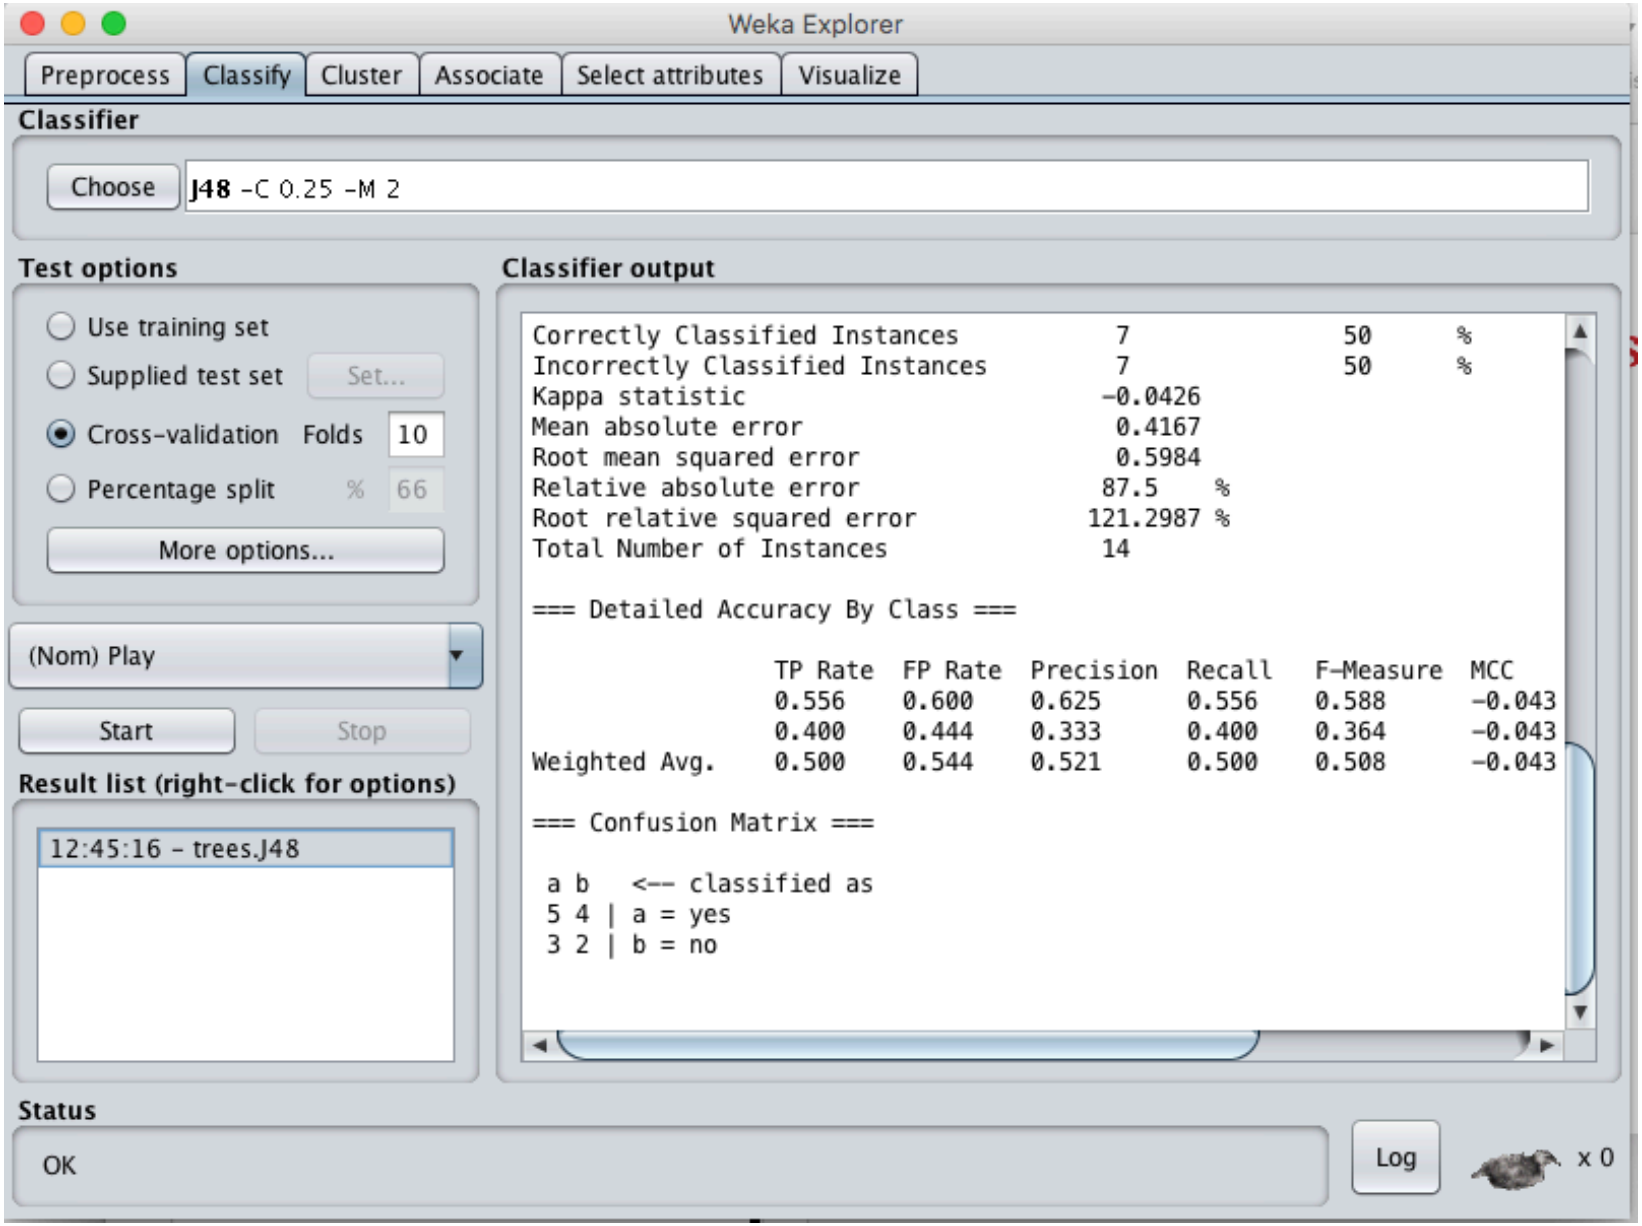

Matrica zabune (Confusion Matrix)

		Predicted Class	
		Yes	No
Actual Class	Yes	TP	FN
	No	FP	TN

TP = True Positive

FP = False Positive

TN = True Negative

FN = False Negative

```
=== Confusion Matrix ===

 a b   <-- classified as
 5 4 | a = yes
 3 2 | b = no
```

Precision, Recall i F mera

```
=== Detailed Accuracy By Class ===

                 TP Rate  FP Rate  Precision  Recall   F-Measure  ROC Area  Class
                 0.556    0.600    0.625      0.556    0.588      0.633     yes
                 0.400    0.444    0.333      0.400    0.364      0.633     no
Weighted Avg.    0.500    0.544    0.521      0.500    0.508      0.633
```

$$\text{Precision} = \frac{TP}{(TP + FP)}$$

$$\text{TP Rate (Recall)} = \frac{TP}{(TP + FN)}$$

$$\text{FP Rate} = \frac{FP}{(FP + TN)}$$

$$\text{Recall (TP Rate)} = \frac{TP}{(TP + FN)}$$

$$\text{F measure} = \frac{2 * \text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}}$$

```
=== Confusion Matrix ===

 a b   <-- classified as
 5 4 | a = yes
 3 2 | b = no
```

Vizualizacija stabla odlučivanja

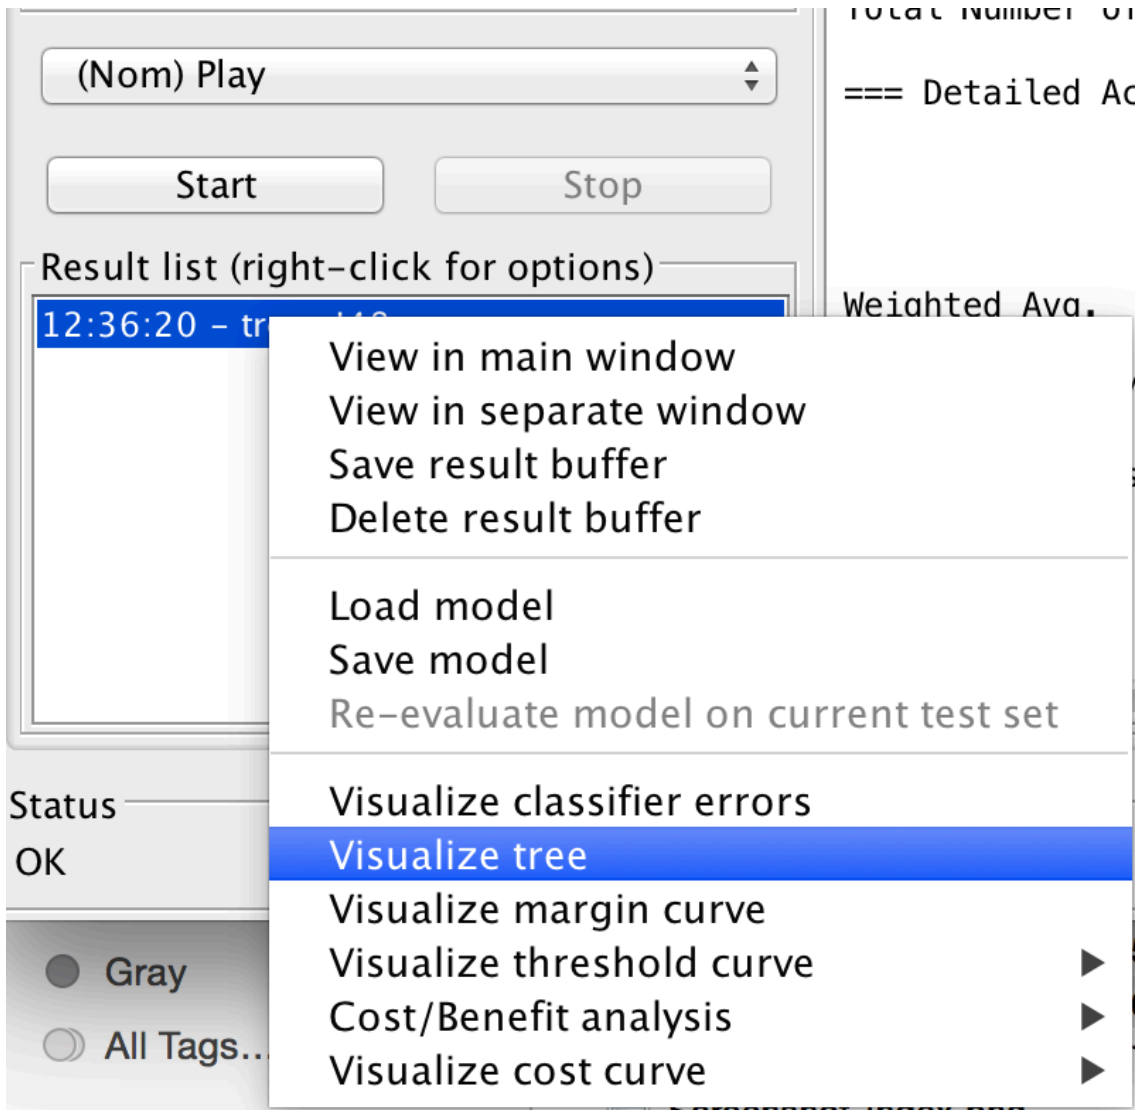

Vizualizacija stabla odlučivanja

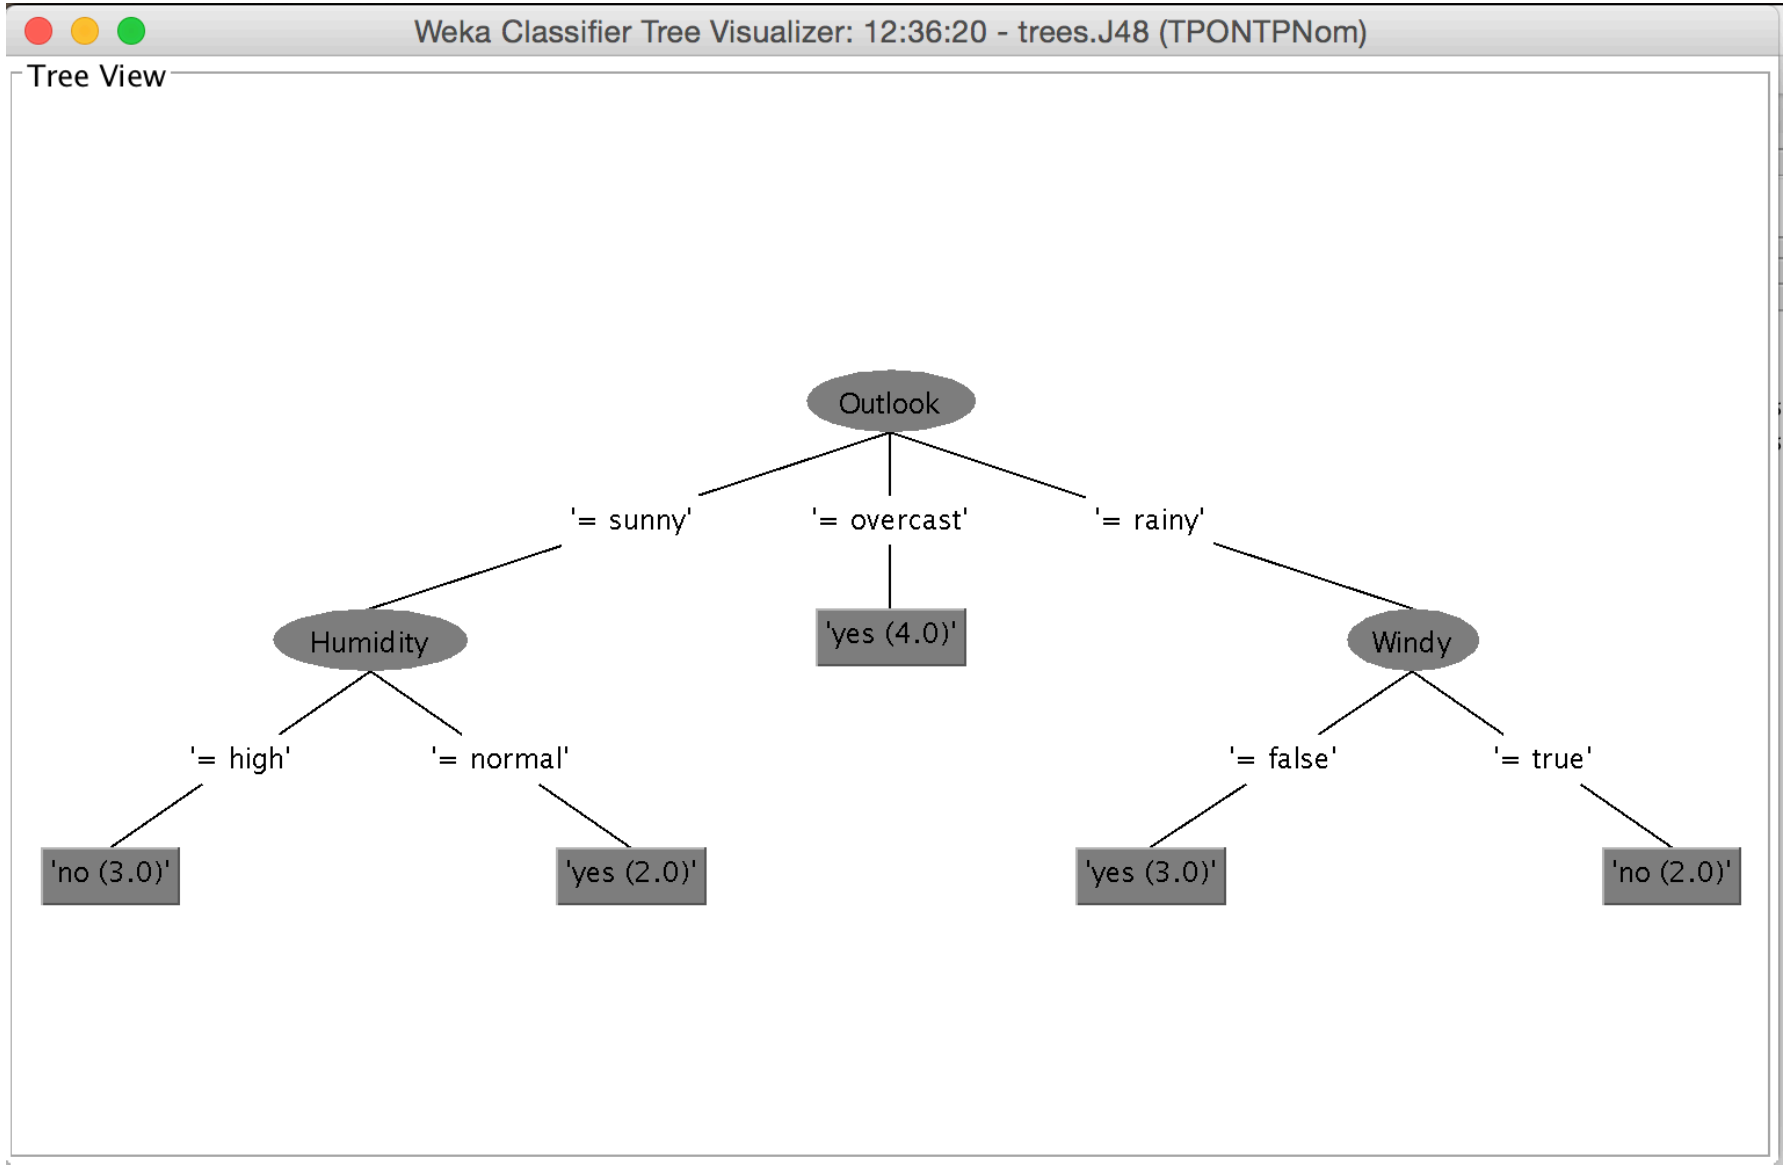

Orezivanje stabla

Orezivanje stabla

- Proces smanjivanja stabla odlučivanja odstranjivanjem delova stabla (podstabala), kako bi se:
  - povećala tačnost klasifikacije na novim/nepoznatim podacima, odnosno,
  - otklonilo preveliko podudaranje modela sa trening podacima (over-fitting)

- Podstablo čija je greška pri klasifikovanju novih instanci (tj instanci koje nisu korišćene pri treningu) veća od greške koju bi doneo neki od listova (terminalnih čvorova) tog podstabla se uklanja i na njegovo mesto se stavlja čvor-list sa min. greškom

Primer 2 – Skup podataka “Dijabetes”

- Skup podataka “Pima Indians Diabetes Database” sadrži podatke o ženama koje pripadaju grupi Pima Indijanaca koje imaju najmanje 21 godinu i testirane su na dijabetes
- Dataset je kreiran pri Johns Hopkins University, Maryland, SAD.
- Dataset sadrži 768 instanci opisanih sa 8 numeričkih atributa koji se odnose na karakteristike pacijenata, kao i binarnim (nominalnim) atributom koji ukazuje da li je osoba bila pozitivna ili negativna na dijabetes
- Naš cilj je da predvidimo da li je neispitani pacijent pozitivan na dijabetes ili ne

Primer 3 – Skup podataka “Rak dojke”

- Skup podataka “Breast cancer data” sadrži podatke o pacijentima obolelim od raka dojke sa Instituta za ongkologiju iz Ljubljane, Slovenija
- Postoji ukupno 286 instanci sa 9 atributa koji su dobijeni od pacijenata obolelih od raka dojke
- Naš cilj je da predvidimo da li će se tumor vratiti kod pacijenta.

Preporuke i zahvalnice

"Data Mining with Weka" and "More Data Mining with Weka": MOOCs from the University of Waikato. A self-paced session of "Data Mining with Weka" runs until 23 October June 2015.

- Link: https://www.youtube.com/user/WekaMOOC/

(Anonimni) upitnik za vaše kritike, komentare, predloge:

http://goo.gl/cqdp3l

Pitanja?

NIKOLA MILIKIĆ

EMAIL: nikola.milikic@fon.bg.ac.rs

URL: http://nikola.milikic.info