

Strojno učenje

Vježbe 1: RapidMiner osnove

Prvo korištenje

- Demo:
 - <http://rapid-i.com/content/view/26/84/lang,en/>
 - Pokrenite Rapidminer
 - Tri perspektive prikaza:
 - Početna je *Welcome* perspektiva
 - Za početak rada prebacite se na *Design*
 - Stvorite lokalni repozitorij: VjezbaRM
 - Repozitorij je središnje mjesto za sve vaše **podatke** i procese za **analizu**



Podaci

- Rapidminer: Primjeri učitanih podataka
 - Repositories: Samples > data





Prikaz podataka

- Dvaklik na učitanu tablicu podataka u repozitoriju prikazuje podatke unutar perspektive *Results*
- Podaci se mogu prikazati na četiri različita načina:

Role	Name	Type	Statistics	Range	Missing
id	id	nominal	mode = id_1 (1), least = id_1 (1), id_10 0		0
label	label	nominal	mode = Iris-setosa (50)	Iris-setosa (50)	0
regular	a1	real	avg = 5.843 +/- 0.828	[4.300 ; 7.900]	0
regular	a2	real	avg = 3.054 +/- 0.434	[2.000 ; 4.400]	0
regular	a3	real	avg = 3.759 +/- 1.764	[1.000 ; 6.900]	0
regular	a4	real	avg = 1.199 +/- 0.763	[0.100 ; 2.500]	0

Row No.	id	label	a1	a2	a3	a4
1	id_1	Iris-setosa	5.100	3.500	1.400	0.200
2	id_2	Iris-setosa	4.900	3	1.400	0.200
3	id_3	Iris-setosa	4.700	3.200	1.300	0.200
4	id_4	Iris-setosa	4.600	3.100	1.500	0.200
5	id_5	Iris-setosa	5	3.600	1.400	0.200
6	id_6	Iris-setosa	5.400	3.900	1.700	0.400
7	id_7	Iris-setosa	4.600	3.400	1.400	0.300
8	id_8	Iris-setosa	5	3.400	1.500	0.200
9	id_9	Iris-setosa	4.600	3.000	1.400	0.200




Podaci

ExampleSet (150 examples, 2 special attributes, 4 regular attributes)						
Role	Name	Type	Statistics	Range	Missings	
id	id	nominal	mode = id_1 (1)	id_1 (1), id_10	0	
label	label	nominal	mode = Iris-setosa	Iris-setosa (50)	0	
regular	a1	real	avg = 5.843 +/-	[4.300 ; 7.900]	0	
regular	a2	real	avg = 3.054 +/-	[2.000 ; 4.400]	0	
regular	a3	real	avg = 3.759 +/-	[1.000 ; 6.900]	0	
regular	a4	real	avg = 1.199 +/-	[0.100 ; 2.500]	0	


- Uloge atributa (*Role*)
 - **id**: jasno identificira cijeli uzorak
 - **label**: vrijednosti ovog stupca predviđaju se na temelju vrijednosti ostalih stupaca
 - **regular**: atributi koji nemaju neku posebnu ulogu, često ih zovemo: atributi, variable ,deskriptori, značajke
- Tipovi vrijednosti atributa (*Value Type*)
 - Kategoričke vrijednosti (nominal)
 - Numeričke vrijednosti (numeric):
 - Cijeli brojevi (integer)
 - Realni brojevi (real)
 - Tekst (text)
 - date, date_time, time

Podaci

- UCI: <http://kdd.ics.uci.edu/>
 - <http://archive.ics.uci.edu/ml/datasets.html>
 - Lenses: <http://www.cs.bme.hu/~kiskat/adatb/contact-lenses.arff>
 - Učitavanje podataka u *RapidMiner* repozitorij




Procesi za analizu



- Odvlačeći skup podataka u prostor za oblikovanje procesa (*Process View*) automatski se stvara ulazni **operator**
- Procesi se definiraju povezivanjem ulaznih/izlaznih operatora
- Konačni rezultat se dovodi do izlaza glavnog procesa

Procesi za analizu

- Rapidminer: Primjeri procesa za analizu
 - Repositories: Samples > processes





Primjeri za učenje modela

Primjeri za evaluaciju
modela

Operatori

- Operatori su osnovni gradivni blokovi RM procesa za analizu
- Svaki operator
 - Ima ulazna i izlazna vrata
 - Definira neku akciju
 - Ovise o postavkama parametara operatora
- Boja operatora određuje njegov tip i boja vrata operatora određuje očekivani ulaz i izlaz
- Operatori različitog tipa se mogu lagano pronaći u prozoru *Operators*



Vježba 1.1: Podaci

- Napravite proces i pohranite ga u svoj repozitorij. Nazovite ga 01_UI_Podaci.
- Preuzmite datoteku contact-lenses.arff
- Iskoristite operator „Read ARFF” za učitavanje skupa podataka iz preuzete datoteke
- Iskoristite operator „Set Role” kako bi postavili atribut „contact-lenses” učitanog skupa podataka na **label**
- Povežite operatore „Read ARFF” i „Set Role” i povežite rezultirani skup podataka s prvim ulazom za rezultate glavnog procesa. Uvjerite se da operatori imaju žutu oznaku (ili zelenu ako je proces već pokrenut).
- Pohranite i pokrenite proces (operator ima dobiva zelenu oznaku)
- Pogledajte prikaz tablice podataka (Data View) učitanog skupa podataka (rezultata pokrenutog procesa)
 - Koliko učitani skup podataka ima primjera?
 - Koliko ima specijalnih, a koliko regularnih atributa?
- Analizirajte prikaz meta podataka učitanog skupa podataka
 - Koliko koje tipovi vrijednosti imaju atributi?
 - Koje osnovne statistike za pojedine atrubute možete iščitati iz prikaza?

Vjezba 1.2: Vizualizacija podataka

- Napravite proces i pohranite ga u svoj repozitorij. Nazovite ga `01_UI_PodaciViz`.
- Učitajte iz repozitorija primjera RMa skup podataka „Iris”. Povežite njegov izlaz na ulaz rezultata glavnog procesa.
- U prikazu rezultata za vizualizaciju:
 - Nacrtajte „Scatter Plot” u kojem je na apscisi atributi `a3`, a na ordinati atribut `a1`, za „Color Column” postavite atribut koji je **label**
 - Vizualno procjenite je li moguće u prostoru koji razapinju ta dva atributa odrediti pravac koji sigurno razdvaja klasu Iris-setosa od ostale dvije klase
 - Nacrtajte „Scatter Plot” `a1-a1`. Primjetite karakteristiku takvoga grafa.
 - Sada iskoristite „Scatter Matrix” i pogledajte koja dva atributa su najsličnija daju gaf karakteristike najsličnije gornjem grafu? Dakle, korelacija je najveća između ta dva atributa.
 - Iskoristite „3D Scatter Plot Color” i vizualizirajte prostor `a1-a2-a3+label`, te nakon toga vizualizirajte prostor `a1-a2-a4+label`. Jesu li kvalitativno isti?
 - Korištenjem vizualizacije uspjeli samo dobro shvatiti kvalitativnu strukturu podataka. To nam je pomoglo da prostor od 4 atributa svedemo na 3 atributa uz mali gubitak informacija.

Modeliranje – Učenje modela

- RM nam omogućuje da različite modele za učenje koristimo kao crne kutije korištenjem operatora
- Predikcija (nadzirano učenje iz označenih primjera za treniranje):
 - Klasifikacija (učenje grupa)
 - Regresija (učenje funkcija)
- Klasteriranje (nenadzirano grupiranje neoznačenih primjera)

Vježba 2: Stabla odluke

- Otvorite proces 01_UI_Podaci (iz prethdne vježbe) i pohranite kao 02_1_UI_Model_DecisionTree.
- Dodajte operator za učenje „Stablo odlučivanja“ (engl. *Decision Tree*)
- Povežite izlaz operatora za učenje s prvim ulazom za rezultate glavnog procesa. Pokrenite proces.
- Analizirajte rezultat procesa
 - Koji atribut se nalazi na krojenu stabla
 - Odredite najpovoljniji tip pomoću dobivenog stabla odluke leće za mladog pacijenta koji normalno stvara suze i koji nema astigmatizam

Korištenje istreniranog modela

- Dosada smo vidjeli tek kako se modeli generiraju iz danih podataka
- Vidjeli samo da sami opis modela može biti koristan za bolje uočavanje strukture podataka
- No, sada ćemo primijeniti naučene modele na „novim“ podacima → taj proces nazivamo prognozom ili predikcijom
- Jedan od najvažnijih operatora u RMu je operator „**Apply Model**“
- Taj operator uzima ulazni <Skup podataka> i <Model> i primjenjuje model na taj skup podataka
- Rezultat će biti dani skup podataka, no sada će se najmanje jedan novi stupac dodati u tablicu tog skupa podataka
- Taj novi stupac sadrži određene klase (ili numeričke vrijednosti u slučaju regresije) i zato se zove prognoza(engl. *prediction*)

Primjena modela

- Dodatno uz predikciju, **klasifikacijski modeli** će također generirati stupce pouzdanosti (engl. confidence)
- Pouzdanost kvantificira vjerojatnost da, s obzirom na model, određena vrijednost bude predviđena za dani primjer
- Vrijednosti pouzdanosti određene su za sve moguće **klase**
- Pouzdanosti se sumiraju u 1
- Pouzdanosti nisu nužno jednake vjerojatnosti te vrijednosti za dani primjer

Vježba 3: Primjena modela

- Stvorite proces i nazovite ga `03_1_UI_Model_DecisionTree`.
- Preuzmite skup podataka Iris iz repozitorija primjera
- Dodajte operator za učenje „Stablo odlučivanja“ (engl. *Decision Tree*)
- Dodajte operator „Apply Model“ i povežite izlaze operatora za učenje s operatom za primjenjivanje modela
- Analizirajte rezultat procesa
 - Koji su stupci stvoren? Za što služe?
- Zamijenite model učenja u Naive Bayes i pospremite proces kao `03_02_UI_Model_NaiveByes`.
 - Kako su se rezultati predikcije promijenili?

Evaluacija modela

- Kako mjerimo kvalitetu modela - mjera za evaluaciju modela?
- Funkcija za izračunavanje greške koju model radi na skupu podataka za testiranje modela se zove mjera za evaluaciju modela (engl. *performance criterion*)
- Skup mjera za evaluaciju modela u RapidMineru se naziva vektor performanse (engl. *performance vector*)

Evaluacija modela za klasifikaciju

- Zadatak evaluacije klasifikacijskih modela je izmjeriti u kojem stupnju klasifikacija sugerirana izrađenim modelom odgovara stvarnoj klasifikaciji
- Ovisno o načinu promatranja performansi modela postoji više različitih mjera za evaluaciju modela
- Mjera za evaluaciju klasifikacijskih modela u RMu:
 - Točnost (engl. *Accuracy*)
 - Greška (engl. *Error*)
 - Kapa statistike
 - Spearman Rho
 - Kendall Tau
 - *Root Mean Squared Error*
- Za binarnu klasifikaciju:
 - Preciznost (engl. *Precision*)
 - Odziv (engl. *Recall*)
 - ROC, AUC (Area Under Curve)

Evaluacija modela za klasifikaciju

- Greška = pogrešna klasifikacija primjera
- Evaluacija klasifikatora: koliko je klasifikator za promatrani skup primjera napravio grešaka?

$$Točnost = \frac{\text{broj ispravno klasificiranih primjera}}{\text{ukupan broj primjera}}$$

- Dva su osnovna nedostatka *točnosti* kao mjere za evaluaciju
 - Zanemaruju se razlike između tipova grešaka
 - Zavisna je o distribuciji klasa u skupu podataka, a ne o karakteristikama primjera
- U većini primjena je važno razlikovati tipove greške: npr. sustav za detekciju neželjene pošte (Spam) može pogrešno označiti željenu poruku (Ham) kao Spam, a Spam kao Ham, u tome slučaju greška označavanja Spama kao Hama ima puno manju težinu nego greška označavanja Hama kao Spama
- Razlikovanje više tipova greške:
 - rezultat klasifikacije => MATRICE GREŠKE

Evaluacija modela za klasifikaciju

Matrica grešaka za klasifikacijski problem s dvije klase

<i>Contingency Table; Confusion Matrix</i>	Pozitivni primjeri klase C	Negativni primjeri klase C
Pozitivna prognoza klase C	Stvarno pozitivni (TP)	Lažno pozitivni (FP)
Negativna prognoza klase C	Lažno negativni (FN)	Stvarno negativni (TN)

Četiri različita rezultata prognoze: TP, FP, FN, TN

$$Točnost = \frac{\text{broj ispravno klasificiranih primjera}}{? \quad \text{ukupan broj primjera}} = \frac{TP + TN}{TP + FP + FN + TN}$$
$$Greška = \frac{?}{}$$

$$Senzitivnost = \frac{TP}{TP + FN} \rightarrow \text{točnost u pozitivnim primjerima}$$

$$Specifičnost = \frac{TN}{TN + FP} \rightarrow \text{točnost u negativnim primjerima}$$

Evaluacija modela za klasifikaciju

Matrica grešaka za klasifikacijski problem s dvije klase

<i>Contingency Table; Confusion Matrix</i>	Pozitivni primjeri klase C	Negativni primjeri klase C
Pozitivna prognoza klase C	Stvarno pozitivni (TP)	Lažno pozitivni (FP)
Negativna prognoza klase C	Lažno negativni (FN)	Stvarno negativni (TN)

Četiri različita rezultata prognoze: TP, FP, FN, TN

Ako je $TP \ll TN$, onda češće koristimo mjere za evaluaciju modela:

$$Odziv = \frac{TP}{TP + FN} \rightarrow \text{točnost u pozitivnim primjerima (jednako kao Senzitivnost)}$$

$$Preciznost = \frac{TP}{TP + FP} \rightarrow \text{točnost u pozitivnoj prognozi ciljne klase}$$

Evaluacija modela za klasifikaciju

Matrica grešaka za klasifikacijski problem s dvije klase

<i>Contingency Table; Confusion Matrix</i>	Pozitivni primjeri klase C	Negativni primjeri klase C
Pozitivna prognoza klase C	Stvarno pozitivni (TP)	Lažno pozitivni (FP)
Negativna prognoza klase C	Lažno negativni (FN)	Stvarno negativni (TN)

Četiri različita rezultata prognoze: TP, FP, FN, TN

Mjere za evaluaciju klasifikacijskih modela zasnovanih na principima preciznosti:

$$\text{Pozitivna prediktivna vrijednost} = \frac{TP}{TP + FP} \rightarrow \text{Preciznost u pozitivnim primjerima}$$

$$\text{Negativna prediktivna vrijednost} = \frac{TN}{TN + FN} \rightarrow \text{Preciznost u negativnim primjerima}$$

Evaluacija modela za klasifikaciju

Matrica grešaka za klasifikacijski problem s dvije klase

<i>Contingency Table; Confusion Matrix</i>	Pozitivni primjeri klase C	Negativni primjeri klase C
Pozitivna prognoza klase C	Stvarno pozitivni (TP)	Lažno pozitivni (FP)
Negativna prognoza klase C	Lažno negativni (FN)	Stvarno negativni (TN)

Četiri različita rezultata prognoze: TP, FP, FN, TN

- Prije navedeni parovi mjera evaluacije modela (Senzitivnost/Specifičnost;...) pokazuju specifičnu točnost klasifikacijskog modela s komplementarnih pogleda
- Često kvalitetu želimo izraziti jednim brojem => fiksiramo vrijednost jedne mjere i uz taj uvjet promatra se vrijednost samo druge mjere ili češće usrednjavanjem jedne od mjera po više fiksiranih vrijednosti druge mjere (npr. preciznost uz fiksiranu vrijednost odaziva od 20%, 50% i 80% - srednja preciznost u 3 točke)
- Primjer mjere koja se ne zasniva na fiksiranju jedne komponente para mjera:


$$F - mjera = \frac{2 \times odaziv \times preciznost}{odaziv + preciznost} = \frac{2TP}{2TP + FP + FN}$$

ROC analiza

- Želimo opisati obuhvatnije opisati međusobne ovisnosti različitih mjera i/ili parametara
- ROC = *Receiver Operating Characteristic*
 - Obuhvatna, grafički orientirana mjera kvalitete klasifikacijskog modela

Vježba 4.1. Evaluacija modela klasifikacije


- Napravite novi proces i nazovite ga 04_UI_Evaluacija_TestTrain
- Iz repozitorija primjera RM uzmite skup podatka „Golf”, operatore „Naive Bayes”, „Apply Model” i „Performanse (Classification)” i spojite ih u proces prikazan na slici



- Pokretanjem procesa dobili smo koliko dobro istrenirani model klasificira skup podatka na kojima je učio.
- Uzmite iz repozitorija primjera RM skup podataka „Golf testset” i spojite ga na ulaz unl operadora Apply Model (umjesto izlaza exa operadora Naive Bayes)
- Pokretanjem procesa dobili smo koliko dobro istrenirani model klasificira neviđeni skup podatka odnosno podatke na kojima nije učio. Uočite razliku u greškama.

Vježba 4.2: Evaluacija modela klasifikacije


- Napravite novi proces i nazovite ga 04_UI_Evaluacija_SplitValidation
- Iz repozitorija primjera RM uzmite skup podatka „Labor-Negotiations” i operator „Split Validation”
- „Split Validation” je operator koji ugnježđuje druge operatore podijeljen u dva procesa, realizirajte ga kao na slici:



- Validacijom modela procijenili smo grešku klasifikacije na neviđenim podacima (kvalitetu generalizacije)
- Primijetite rezultat operadora SplitValidation

Vježba 4.3: Evaluacija modela klasifikacije

- Napravite novi proces i nazovite ga 04_UI_Evaluacija_XValidation
- Iz repozitorija primjera RM uzmite skup podatka „Labor-Negotiations” i operator „XValidation”
- „XValidation” je operator koji ugnježđuje druge operatore podijeljen u dva procesa, realizirajte ga kao na slici:



- Validacijom modela procijenili smo grešku klasifikacije na neviđenim podacima (kvalitetu generalizacije)
- Usporedite rezultat operatora XValidation s rezultatima SplitValidation operatora iz prošlog primjera
- Što mislite, koja je procjena bolja?