

Machine learning – ML. Introducere


Ruxandra Stoean

rstoean@inf.ucv.ro



<http://inf.ucv.ro/~rstoean>

Masini inteligente

- Masini care pot fi programate sa actioneze ca oamenii



- Masina care pot fi instruite sa invete ca oamenii



Definitie

- Conform Wikipedia:
 - “ML este o disciplina stiintifica care exploreaza constructia si studiul algoritmilor care invata din date [1].
 - Astfel de algoritmi opereaza prin constructia unui model care se bazeaza pe date de intrare si il foloseste pentru a face mai degraba predictii sau decizii decat a urmari instructiuni programate explicit [2].”

[1] Ron Kohavi; Foster Provost (1998). "Glossary of terms". Machine Learning 30: 271–274.

[2] C. M. Bishop (2006). Pattern Recognition and Machine Learning. Springer.

Definitie

- Conform cursului de Machine Learning sustinut de Prof. Andrew Ng la Universitatea Stanford [3]:
 - “Disciplina de studiu care le da calculatoarelor abilitatea de a invata fara a fi programati in mod explicit.” - Arthur Samuel (1959)
 - “Un program de calculator se spune ca invata din experienta E vis-à-vis de o anumita clasa de sarcini T si o masura de performanta P daca performanta sa cu privire la sarcinile din T, masurate prin P, se imbunateste cu experienta E.” – Tom Michel (1999)

[3] <http://www.holehouse.org/mlclass/index.html>

Aplicatii ML

- Masini care se conduc singure
 - <https://www.youtube.com/watch?v=lL16AQItG1g>
- Elicopterul autonom de la Stanford
 - <https://www.youtube.com/watch?v=0JL04JJjocc>
- Recunoasterea scrisului de mana
 - <https://www.youtube.com/watch?v=xGVZsQxUv5w>
- Minerit in baze de date: Google, Amazon, diagnoza medicala
 - <https://www.youtube.com/watch?v=mgiUoSKrgbI>

Bibliografie

- Cursul de Machine Learning sustinut de Prof. Andrew Ng la Universitatea Stanford:
<http://www.holehouse.org/mlclass/index.html>
- Trevor Hastie, Robert Tibshirani, Jerome Friedman, The Elements of Statistical Learning, Springer, 2009
- Dianne Cook, Deborah F. Swayne, Graphics for Data Analysis. Interactive and Dynamic With R and Ggobi, Springer, 2007
- Andrew Webb, Keith Copsey, Statistical Pattern Recognition, Wiley, 2011

Bibliografie

- Nathalie Japkowicz, Mohak Shah, Evaluating Learning Algorithms, Cambridge, 2011
- Florin Gorunescu, Data Mining: Concepts, Models And Techniques, Springer, 2011
- Catalin Stoean, Ruxandra Stoean, Support Vector Machines and Evolutionary Algorithms for Classification: Single or Together, Springer, 2014.

Despre curs si examen

- Curs: notiuni teoretice, modele, explicatii, discutii
- Laborator: implementari modele in limbajul R [1], [2]
 - W. N. Venables, D. M. Smith and the R Core Team, An Introduction to R, 2014
- Nota finala: nota examen + puncte laborator, proiecte

[1] <http://www.r-project.org/>

[2] <http://www.rstudio.com/>


Tipuri de invatare computationala

- Invatare supervizata:
 - Date de intrare cu iesiri puse la dispozitie
 - De invatat modul de asociere intrare-iesire
 - Predictie asupra iesirii unor date noi
- Invatare nesupervizata:
 - Date de intrare fara iesiri
 - De invatat/descoperit structura, caracteristici date


Tipuri de invatare computationala

- Invatare supervizata:
 - Clasificare
 - Iesiri grupate in doua sau mai multe **clase calitative** [1]
 - Predictie asupra clasei unor noi date
 - Regresie
 - Iesiri **cantitative** [1]
 - Predictie asupra valorii de iesire pentru intrari noi
- Invatare nesupervizata:
 - Clustering
 - Impartirea datelor in grupuri
- Colateral:
 - Selectia variabilelor si reducerea dimensionalitatii
 - Evaluarea si selectia modelelor de invatare

[1] Trevor Hastie, Robert Tibshirani, Jerome Friedman, *The Elements of Statistical Learning*, Springer, 2009



Clasificare, regresie



Date de antrenament

Clustering

Exemple

- Clasificare
 - Etichetare e-mail-uri ca **spam**/**non-spam**
 - Diagnosticare tumora pacient ca **beningna**/**maligna**
- Regresie
 - Estimare pret apartament pe baza dotarilor
 - Estimare pret masina pe baza caracteristicilor
- Clustering
 - Recomandari produse similare Amazon, Elefant etc.
 - Gruparea stirilor pe site-urile specializate

Exemplu 1 – Clasificare Iris

Fisher's Iris Data

Sepal length	Sepal width	Petal length	Petal width	Species
5.1	3.5	1.4	0.1	<i>I. setosa</i>
4.9	3.0	1.4	0.2	<i>I. setosa</i>
4.7	3.2	1.3	0.2	<i>I. setosa</i>
4.6	3.1	1.5	0.2	<i>I. setosa</i>
5.0	3.6	1.4	0.2	<i>I. setosa</i>
5.4	3.9	1.7	0.4	<i>I. setosa</i>
4.6	3.4	1.4	0.3	<i>I. setosa</i>
5.0	3.4	1.5	0.2	<i>I. setosa</i>
4.4	2.9	1.4	0.2	<i>I. setosa</i>
4.9	3.1	1.5	0.1	<i>I. setosa</i>
5.4	3.7	1.5	0.2	<i>I. setosa</i>
4.8	3.4	1.6	0.2	<i>I. setosa</i>
4.8	3.0	1.4	0.1	<i>I. setosa</i>
4.3	3.0	1.1	0.1	<i>I. setosa</i>
5.8	4.0	1.2	0.2	<i>I. setosa</i>

7.0	3.2	4.7	1.4	<i>I. versicolor</i>
6.4	3.2	4.5	1.5	<i>I. versicolor</i>
6.9	3.1	4.9	1.5	<i>I. versicolor</i>
5.5	2.3	4.0	1.3	<i>I. versicolor</i>
6.5	2.8	4.6	1.5	<i>I. versicolor</i>
5.7	2.8	4.5	1.3	<i>I. versicolor</i>
6.3	3.3	4.7	1.6	<i>I. versicolor</i>
4.9	2.4	3.3	1.0	<i>I. versicolor</i>
6.6	2.9	4.6	1.3	<i>I. versicolor</i>
5.2	2.7	3.9	1.4	<i>I. versicolor</i>
5.0	2.0	3.5	1.0	<i>I. versicolor</i>
5.9	3.0	4.2	1.5	<i>I. versicolor</i>
6.0	2.2	4.0	1.0	<i>I. versicolor</i>
6.1	2.9	4.7	1.4	<i>I. versicolor</i>
5.6	2.9	3.6	1.3	<i>I. versicolor</i>
6.7	3.1	4.4	1.4	<i>I. versicolor</i>

- Recunoașterea tipului unei plante noi după caracteristici



Exemplu 2 – Regresie in sport

- Pentru a forma echipe cat mai competitive.

The image shows a screenshot of the IMDb website for the movie "Moneyball". The top navigation bar includes the IMDb logo, a search bar, and links for "Movies, TV & Showtimes", "Celebs, Events & Photos", "News & Community", and "Watchlist (9)". A "Top 5000" badge is visible on the right. The main content area features a large image of Brad Pitt as Billy Beane in a baseball stadium. Below the image, the title "Moneyball: Arta de a învinge" (2011) is displayed, along with the original title "Moneyball". The movie's rating is PG-13, it is 133 minutes long, and it falls under Biography, Drama, and Sport genres. It was released on 9 December 2011 in Romania. A yellow star rating of 7,6 is shown, with a note that 7,6/10 is from 218,433 users, and Metascore is 87/100. Ratings, reviews, and other credits are also listed. The plot summary describes the movie as an attempt by Oakland A's general manager Billy Beane to assemble a baseball team on a lean budget using computer-generated analysis.

Find Movies, TV shows, Celebrities and more... All

Movies, TV & Showtimes Celebs, Events & Photos News & Community Watchlist (9)

Moneyball: Arta de a învinge (2011)
"Moneyball" (original title)

PG-13 133 min - Biography | Drama | Sport -
9 December 2011 (Romania)

Your rating: ★★★★★★★★★★★ 7,6 /10
Ratings: 7,6/10 from 218.433 users Metascore: 87/100
Reviews: 287 user | 403 critic | 42 from Metacritic.com

Oakland A's general manager Billy Beane's successful attempt to assemble a baseball team on a lean budget by employing computer-generated analysis to acquire new players.

Director: Bennett Miller

Writers: Steven Zaillian (screenplay), Aaron Sorkin (screenplay), 2 more credits »

Stars: Brad Pitt, Robin Wright, Jonah Hill | See full cast and crew »

Exemplu 3 - Clustere de galaxii

- https://www.youtube.com/watch?v=rENyyRwxpHo&list=PLQQa5REN2h_W-W4lPSt_IUx-B_JxcOZi4

Abordari invatare supervizata

- Modele liniare
- k-Nearest Neighbors (kNN)
- Masini cu suport vectorial
- Retele neuronale
- Arbori de decizie
- Metode ansamblu (Ensemble methods)
 - Bagging
 - Boosting
 - Random Forests

Abordari invatare supervizata

- Selectia si evaluarea modelelor obtinute:
 - Verificarea potrivirii cu datele / Diagnoza modelului
 - Masuri de performanta
 - Estimarea erorii
 - Comparatie intre mai multe modele. Testarea semnificatiei statistice
 - Selectia problemelor de test (benchmarking)

Abordari invatare nesupervizata

- Clustering partitional sau bazat pe centroizi
- Clustering ierarhic
- Clustering bazat pe distributie
- Clustering bazat pe densitate
- Selectie si evaluare modele obtinute:
 - Validitatea clusterelor obtinute
 - Teste statistice
 - Alegerea numarului de clustere

Selectia modelului (Model selection)

- Din mai multe modele posibile, orice paradigma computationala bazata pe invatare va alege cel mai bun pentru problema considerata.
- Atentia la echilibrul dintre deplasare si dispersie (bias-variance)
 - Generalizare - underfitting (bias ridicat)
 - Specializare - overfitting (dispersie ridicata)

Imbunatatirea performantei

- Setarea parametrilor (Parameter tuning)
 - Manual
 - Automat
- Tratarea atributelor
 - Selectia trasaturilor (Feature selection)
 - Reducerea numarului de atribute la cele importante
 - Extragerea trasaturilor (Feature extraction)
 - Combinarea atributelor originale intr-o multime mai mica de noi caracteristici

Laborator – Introducere in R [1]

- Construiti vectorii x si y care sa contin numerele 7.4, 9.3, 5, 12 si -7.3, 2, 9, -4.9, respective.
- Calculati vectorul v care sa aiba elemente obtinute dupa formula $2x+3y+1$.
- Calculati pentru v lungimea, minimul, maximul, suma, produsul, media si deviatia standard ale elementelor sale.
- Sortati vectorii x si y.
- Generati un vector de tip secvential de la -10 la 10 care sa aiba elementele din 0.5 in 0.5.
- Generati un vector cu marci de masini.
- Fie $n = 10$, comparati secventele $1:n-1$ si $1:(n-1)$.

Exercitii (2)

- Generati un vector logic prin compararea elementelor din x cu 8.
- Folosind un vector index, selectati din y intr-un vector z numai elementele pozitive.
- Aflati elementul de pe pozitia 3 din vectorul v.
- Folosind un vector index, selectati din x intr-un vector z primele 3 elemente.
- Folosind un vector index, construiti din x un vector z excluzand primele 3 elemente ale sale.
- Inlocuiti elementele negative din y cu 0.
- Generati un vector de preturi pentru 4 tipuri de haine, atasati un vector cu hainele corespunzatoare si apoi scrieti o interogare prin care sa se calculeze pretul total pe care trebuie sa il plateasca un client pentru doua haine alese.

Exercitii (3)

- Definiti un vector de numere intregi x si schimbati-l intr-un vector caracter y care sa contine stringul asociat fiecaruia (fiecare numar intre ghilimele). Transformati-l apoi la loc in intregi dispusi intr-un vector z.
- Construiti un vector de 3 numere intregi. Apoi adaugati numarul 3 pe pozitia a 4-a. Scurtati-l ulterior la primele 2 pozitii.
- Avand un vector de tip caracter cu obiectele “unu”, “doi” si “trei”, creati un vector factor din acesta si afisati vectorul nou si nivelurile sale.

Exercitii - continuare

- La un concurs de informatica participa trei licee notate prin “unu”, “doi” si “trei”. De la fiecare liceu participa mai multi elevi care obtin note dupa urmatorii vectori:

```
elevi <- c("unu", "unu", "trei", "doi", "trei", "unu", "doi", "doi", "trei", "unu")
```

```
note <- c(7, 3, 9, 10, 9, 8, 5, 2, 7, 9)
```

Transformati vectorul elevi intr-unul factor si calculati media notelor elevilor de la fiecare liceu.

Exercitii (4)

- Creati o matrice 2×3 . Extrageți prima coloana și extrageți a doua linie. Extrageți elementul de pe pozitia $(2, 3)$. Inlocuiti primele doua elemente de pe linia a 2-a cu 0.
- Creati un vector de lungime 3 și o matrice 3×2 și uniti-le pe coloana. Idem cu un vector de lungime 2 și aceeași matrice cu unire pe linie.
- Uniti pe coloana două matrice de 2×3 și 2×4 .
- Uniti pe linie două matrice 2×2 și 3×2 .

Exercitii (5)

- Construiti doua liste cu urmatoarele componente: numele si prenumele cate unui student, anul nasterii si un vector cu doua componente - media notelor de studiu si nota de la licenta.
 - Adaugati ulterior la fiecare inca o componenta care sa specifica firma la care s-a angajat dupa alsolvire.
 - Concatenati apoi cele doua liste.
 - Calculati media finala (intre note studii si nota licenta) pentru fiecare dintre cei doi studenti.

Exercitii (6)

- Creati un fisier .data cu urmatorul cap de tabel
(marca, motor, combustibil, an, km, pret)
privind datele mai multor masini de la un parc auto.
- Creati apoi un data frame care sa importe in R datele din fisier.
- Gasiti apoi pretul minim si maxim si caracteristicile masinilor corespunzatoare.