

Proiecte Data Mining (2019-2020)

Temele sunt grupate în 2 categorii:

- Proiecte orientate către algoritmi
- Proiecte orientate către seturi de date

A. Proiecte orientate către algoritmi

Proiectele de tip A constau în:

- Un raport care în care sunt descrise particularitățile problemei abordate, este prezentat cel puțin un algoritm de rezolvare (folosind bibliografia de start și eventual alte lucrări) și sunt prezentate rezultatele obținute aplicând algoritmul implementat (pentru seturi simple de date).
- Implementarea unui algoritm (limbajul de programare este la alegere – R, Python, Java).

Tematici pentru proiecte de tip A:

1. Algoritmi pentru selecția atributelor (implementarea algoritmului Relief sau a unui algoritm greedy de tip forward). Biblio: [FeatureSelection](#) folder
2. Algoritmi pentru discretizarea atributelor (implementarea algoritmului Holte 1R). Biblio: [FeatureDiscretization](#) folder
3. Algoritmi pentru construirea arborilor de decizie (implementarea algoritmului ID3 - <http://www.cise.ufl.edu/~ddd/cap6635/Fall-97/Short-papers/2.htm>). Biblio: [DecisionTree](#) folder
4. Algoritmi de acoperire cu reguli (implementarea algoritmului PRISM). Biblio: [CoveringAlgorithms](#) folder
5. K-Nearest Neighbor (implementarea algoritmului kNN bazat pe distanța euclidiană). Biblio: [kNN](#) folder
6. Clasificator Naïve Bayes (implementarea unui algoritm pentru date cu atribute discrete). Biblio: [NaiveBayes](#) folder
7. Perceptron multinivel antrenat cu Backpropagation (implementarea unei rețele neuronale feedforward, cu un nivel ascuns și antrenată cu backpropagation – testare pentru o problemă de clasificare). Biblio: [MLP+BP](#) folder
8. Rețea neuronală de tip RBF – Radial Basis Function (implementarea unei rețele RBF și un algoritm de învățare – testare pentru o problemă de regresie neliniară). Biblio: <http://mccormickml.com/2013/08/15/radial-basis-function-network-rbfn-tutorial/> + [RBF](#) folder
9. Fuzzy c-means (e.g. implementarea variantei standard propusă de Bezdek). Biblio: [FuzzyCMeans](#) folder
10. Algoritmi aglomerativi de grupare (e.g. implementarea variantei single-linkage variant). Biblio: [HierarchicalAlgorithms](#) folder
11. DBSCAN (e.g. implementarea unei variante a algoritmului DBSCAN). Biblio: [DBSCAN](#) folder

12. DENCLUE (e.g. implementarea unei variante de algoritm de grupare bazat pe funcții de densitate). Biblio: [DENCLUE](#) folder
13. Algoritmi de clustering bazați pe descompunerea matricii de similaritate (implementarea unui algoritm pentru spectral clustering). Biblio: [SpectralClustering](#) folder
14. Algoritmul Apriori (e.g. implementarea unei variante simple a algoritmului Apriori). Biblio: [Apriori](#) folder
15. [Bioinfo – proiect de echipă – 2-5 studenți] Studiu comparativ al algoritmilor de biclustering și ilustrare rezultate pentru date de tip microarray (analiza expresiei genice). Variante de algoritmi: Church&Cheng, Murali&Kasif, Bimax, Plaid Model, Spectral Biclustering. Biblio: [Biclustering](#) folder.

B. Proiecte orientate inspre date

- [seturi de date de la UCI Machine Learning Repository](#)
- [seturi de date de la https://www.kaggle.com](#)

Proiectele de tip B constau în:

- Un raport în care este descris setul de date, problema care urmează a fi rezolvată, metoda/metodele utilizate (pe baza lucrărilor menționate în descrierea setului din UCI Machine Learning Repository sau pe baza descrierii și/sau a kernel-urilor de la Kaggle)
- Descrierea fluxului de prelucrări (etapele de prelucrare aplicate asupra setului de date), valorile parametrilor și rezultatele obținute aplicând un instrument de data mining (la alegere – poate fi R, Scikit-learn, Weka sau altă platformă). Alegerea modelelor/metodelor/etapelor de pre-procesare trebuie argumentată.

Exemple de tematici pentru proiecte de tip B:

16. Microblog PCU data set (<http://archive.ics.uci.edu/ml/datasets/microblogPCU>). **Scop:** identificarea spammer-ilor (clasificare binară)
17. SMS Spam Collection (<http://archive.ics.uci.edu/ml/datasets/SMS+Spam+Collection>). **Scop:** clasificarea SMS-urilor în spam/ham (clasificare binară)
18. Energy efficiency data set (<http://archive.ics.uci.edu/ml/datasets/Energy+efficiency>). **Scop:** predicția consumului de energie într-o clădire pe baza altor caracteristici (regresie)
19. GPS trajectories (<http://archive.ics.uci.edu/ml/datasets/GPS+Trajectories>). **Scop:** identificarea grupurilor de traiectorii similare (clustering)
20. Blog feedback dataset (<http://archive.ics.uci.edu/ml/datasets/BlogFeedback>).
Scop: predicția numărului de comentarii în următoarele 24h (regresie)
21. Online news popularity (<http://archive.ics.uci.edu/ml/datasets/Online+News+Popularity>).
Scop: predicția numărului de partajări ale stirilor (regresie)
22. AAAI2013 Accepted Papers Dataset
(<http://archive.ics.uci.edu/ml/datasets/AAAI+2013+Accepted+Papers>) . **Scop:** clustering bazat pe cuvinte cheie

23. News aggregator dataset (<http://archive.ics.uci.edu/ml/datasets/News+Aggregator>). **Scop:** gruparea știrilor pe categorii (clustering)
24. Bioinfo: Genome wide peak detection problem (<http://archive.ics.uci.edu/ml/datasets/chipseq>). **Scop:** clasificare binară
25. House price prediction (<https://www.kaggle.com/c/house-prices-advanced-regression-techniques>). **Scop:** estimarea prețului casei pornind de la caracteristici (regresie)
26. Credit card fraud detection (<https://www.kaggle.com/dalpozz/creditcardfraud>). **Scop:** predicție fraudă pe baza caracteristicilor de utilizare (clasificare)
27. **Kaggle competition:** COVID-19 Open Research Dataset Challenge – procesare lucrări științifice – selectie lucrări care utilizează tehnici de data mining.
(<https://www.kaggle.com/allen-institute-for-ai/CORD-19-research-challenge>)
28. **Kaggle competition:** M5 forecasting <https://www.kaggle.com/c/m5-forecasting-accuracy> (modele de predictie in domeniul vânzărilor)
29. **Kaggle competition:** CERN particle tracking (<https://www.kaggle.com/c/trackml-particle-identification>)
30. **Kaggle competition:** Data Science for good: DonorsChoose
(<https://www.kaggle.com/donorschoose/io>)
31. **Kaggle competition:** Predict future sales (<https://www.kaggle.com/c/competitive-data-science-predict-future-sales>)
32. **Kaggle dataset:** COVID19 – containment and mitigation measures
(<https://www.kaggle.com/paultimothymooney/covid19-containment-and-mitigation-measures>)
33. **Kaggle dataset:** Births in Poland (<https://www.kaggle.com/mknorps/births/data>)
34. **Kaggle dataset:** Air pollution (<https://www.kaggle.com/prakaa/air-quality-data-earlwood-nsw-australia>)
35. **Kaggle dataset:** 80 cereals - regresie (<https://www.kaggle.com/crawford/80-cereals>)
36. **Kaggle dataset:** Cryptocurrency Historical Prices
(<https://www.kaggle.com/sudalairajkumar/cryptocurrencypricehistory>)
37. **Kaggle dataset:** Chocolate Bar Ratings (<https://www.kaggle.com/rtatman/chocolate-bar-ratings>)
38. **Bioinfo – Kaggle dataset:** mice protein expression (<https://www.kaggle.com/ruslank1/mice-protein-expression>)
39. **Bioinfo – Kaggle dataset:** genetic variant classification
(<https://www.kaggle.com/kevinarvai/clinvar-conflicting>)

Obs: poate fi utilizat orice alt set de date de la UCI Machine Learning, de la alte competiții Kaggle sau de la alte resurse.