



FIȘA DISCIPLINEI

1. Date despre program

1.1 Instituția de învățământ superior	Universitatea “Alexandru Ioan Cuza” din Iași
1.2 Facultatea	Facultatea de Informatica
1.3 Departamentul	Departmentul de Informatica
1.4 Domeniul de studii	Informatica
1.5 Ciclul de studii	Master
1.6 Programul de studii / Calificarea	Master de Optimizari Computaționale, Master de Sisteme Distribuite, Master de Ingineria Sistemelor Software

2. Date despre disciplină

2.1 Denumirea disciplinei	Capitole speciale de Invatare Automata						
2.2 Titularul activităților de curs	Conf. Dr. LVIU CIORTUZ						
2.3 Titularul activităților de seminar	Conf. Dr. LVIU CIORTUZ						
2.4 An de studiu	II	2.5 Semestru	1	2.6 Tip de evaluare	P	2.7 Regimul disciplinei*	OB

* OB - Obligatoriu / OP - Opțional

3. Timpul total estimat (ore pe semestru și activități didactice)

3.1 Număr de ore pe săptămână	4	din care: 3.2 curs	2	3.3 seminar/laborator	2
3.4 Total ore din planul de învățământ	56	din care: 3.5 curs	28	3.6 seminar/laborator	28
Distribuția fondului de timp					ore
Studiu după manual, suport de curs, bibliografie și altele					28
Documentare suplimentară în bibliotecă, pe platformele electronice de specialitate și pe teren					14
Pregătire seminarii/laboratoare, teme, referate, portofolii și eseuri					14
Tutoriat					-
Examinări					4
Alte activități					-
3.7 Total ore studiu individual					56
3.8 Total ore pe semestru					116
3.9 Număr de credite					6

4. Precondiții (dacă este cazul)

4.1 De curriculum	
4.2 De competențe	

5. Condiții (dacă este cazul)



5.1 De desfășurare a cursului	Prezența la curs este obligatorie.
5.2 De desfășurare a seminarului/ laboratorului	Prezența la seminar este obligatorie.

6. Competențe specifice acumulate

transversale	C1. Capacitatea de a înțelege, a implementa și utiliza algoritmi avansați din domeniul învățării automate.
Competențe profesionale	CT1. Abilitatea de utilizare a instrumentelor matematice (analiză matematică, probabilități și statistică) pentru proiectarea și analiza algoritmilor din învățarea automată. CT2. Capacitatea de a lucra în paradigma „data-driven programming”: explorarea datelor, crearea automată de modele, evaluarea modelelor.

7. Obiectivele disciplinei (din grila competențelor specifice acumulate)

obiectivul general	Înțelegerea și folosirea unor algoritmi mai sofisticăți din domeniul învățării automate.
obiective specifice	O1. Înțelegerea unor algoritmi din Învățarea automată: EM, regresia liniară, regresia logistică, HMM, Bayes Naiv gaussian, SVM. Aplicarea acestor algoritmi pe diferite seturi de date.



8. Continut

8.1		Metoda de predare	Observatii (ore)
1.	Recapitularea notiunilor fundamentale de probabilitati si statistica.	Expunere	2
2.	Distributii discrete: Bernoulli, categoriala, Poisson. Estimarea parametrilor, în sens MLE și MAP. Algoritmul EM pentru invatarea mixturilor de distributii Bernoulli / categoriale / Poisson.	Expunere	2
3.	Schema algoritmica EM. Convergenta - demonstratie.	Expunere	2
4.	Distributia gaussian uni-variata: estimarea parametrilor, în sens MLE și MAP. Algoritmul EM pentru invatarea unei mixturi de distributii gaussiene uni-variate. Similar pentru distributia Gamma.	Expunere	2
5.	Distributia gaussian multi-variata: estimarea parametrilor în sens MLE. Algoritmul EM pentru invatarea unei mixturi de distributii gaussiene multi-variate. Aplicații la clusterizare.	Expunere	2
6.	Familia de distributii exponentiale; estimarea parametrilor lor, în sens MLE. Algoritmul EM pentru invatarea unei distributii gaussiene bi-variate din date la care o parte din componente lipsesc. Algoritmul EM pentru invatarea parametrilor a doua variabile care urmează distributii exponentiale, pornind de la date generate de suma acestor distributii.	Expunere	2
7.	Modele Markov ascunse: algoritmi Forward, Backward, Viterbi si Forward-Backward.	Expunere	2
8.	Recapitulare.	Examen partial	2
9.	Regresia liniara și regularizare; aplicații.	Expunere	2
10.	Regresia liniara și regularizare; aplicații.	Expunere	2
11.	Clasificare bayesiana cu variabile gaussiene.	Expunere	2
12.	Mașini cu vectori-suport. Forma primala a problemei SVM; forma duala. Metode de rezolvare.	Expunere	2
13.	Algoritmul SMO. Funcții nucleu; proprietăți principale.	Expunere	2
14.	Aplicatii ale mașinilor cu vectori-suport.	Expunere	2

**Bibliografie****Baza:**

Tom Mitchell. Machine Learning. McGraw Hill. 1997.

Liviu Ciortuz, Alina Munteanu, Elena Bădărău. Exerciții de învățare automată. Editura Universității “Al.I.Cuza”, Iași, 2015.

Christopher Manning, Heinrich Schütze. Foundations of Statistical Natural Language Processing, MIT Press, 2000.

Suplimentar:

Trevor Hastie, Robert Tibshirani, Jerome Friedman. The Elements of Statistical Learning. Springer. 2009

8.2	Seminar	Metoda	Observatii (ore)
1.	Exerciții recapitulative de probabilități și statistică.	Lucru la tabla, lucru individual, metode interactive, programe demonstrative, teste.	2
2.	Distributiile Bernoulli / categoriala / Poisson: exerciții pentru estimare MLE, MAP și algoritmul EM.	Idem	2
3.	Distributia gaussiană uni-variata: exerciții.	Idem	2
4.	Distributia gaussiană uni-variata și distributia Gamma: exerciții pentru estimare MLE, MAP și algoritmul EM.	Idem	2
5.	Distributia gaussiană multi-variata: exerciții pentru estimare MLE, MAP și algoritmul EM.	Idem	2
6.	Familia de distributii exponentiale: exerciții pentru estimarea parametrilor lor în sens MLE, algoritmul EM.	Idem	2
7.	HMM: exercitii.	Idem	2
8.	Recapitulare.	Examen partial	2
9.	Regresia liniara și regularizare: exercitii.	Idem	2
10.	Regresia logistica și regularizare: exercitii.	Idem	2
11.	Algoritmul Bayes Naiv cu variabile gaussiene: exercitii.	Idem	2
12.	Forma primala si forma duala a problemei SVM: exercitii.	Idem	2
13.	Funcții nucleu: exercitii.	Idem	2
14.	Implementari; demo-uri.	Idem	2

**Bibliography:**

Liviu Ciortuz, Alina Munteanu, Elena Bădărău. Exerciții de învățare automată. Editura Universității “Al.I.Cuza”, Iași, 2015.

9. Coroborarea conținutului disciplinei cu așteptările reprezentanților comunității, asociațiilor profesionale și angajatorilor reprezentativi din domeniul aferent programului

Conținutul disciplinei este coroborat cu tematica concursurilor pentru ocuparea posturilor în companiile IT.

10. Evaluare

Tip activitate	10.1 Criterii de evaluare	10.2 Metode de evaluare	10.3 Pondere în nota finală (%)
10.4 Curs	<ul style="list-style-type: none">- aplicare corectă a algoritmilor de învățare automată predați, în funcție de diverse cerințe specifice;- demonstrarea unor proprietăți teoretice legate de chestiunile de mai sus;- calitatea formulării răspunsurilor	2 examene scrise (sapt. 7, resp. 15-16)	60% (3 puncte la fiecare din cele două examene parțiale).
10.5 Seminar	<ul style="list-style-type: none">- aplicarea concretă a algoritmilor EM pentru diverse mixturi, regresia liniară, regresia logistică, HMM, SVM, pe dataset-uri didactice;- demonstrarea unor proprietăți teoretice.	Răspunsuri la tablă, implementări mini-proiecte, eventual teste scrise.	30% (1.5 puncte pentru fiecare jumătate de semestru)

10.6 Standard minim de performanță:

Total: 1 (baza) + examene parțiale + seminar – penalizările pentru absențe la seminar. Absențele la seminar se penalizează cu câte 0,1 puncte începând de la a doua absență încolo. Notele se stabilesc conform cu criteriile ECTS.

Data completării
28 februarie 2018

Titular de curs
Conf.univ.dr. Liviu Ciortuz

Titular de seminar
Conf.univ.dr. Liviu Ciortuz



Data avizării în departament

Director de departament