
Ano Letivo 2018-19

Unidade Curricular APRENDIZAGEM MÁQUINA

Cursos ENGENHARIA ELETRÓNICA E TELECOMUNICAÇÕES (Mestrado Integrado) (*)
ENGENHARIA INFORMÁTICA (2.º ciclo) (*)

(*) Curso onde a unidade curricular é opcional

Unidade Orgânica Faculdade de Ciências e Tecnologia

Código da Unidade Curricular 14741052

Área Científica CIÊNCIA DE COMPUTADORES

Sigla

Línguas de Aprendizagem English - EN

Modalidade de ensino Presencial nocturno

Docente Responsável José Luís Valente de Oliveira

DOCENTE	TIPO DE AULA	TURMAS	TOTAL HORAS DE CONTACTO (*)
---------	--------------	--------	-----------------------------

* Para turmas lecionadas conjuntamente, apenas é contabilizada a carga horária de uma delas.

ANO	PERÍODO DE FUNCIONAMENTO*	HORAS DE CONTACTO	HORAS TOTAIS DE TRABALHO	ECTS
1º,5º	S1,S2	30T; 30PL	168	6

* A-Anual;S-Semestral;Q-Quadrimestral;T-Trimestral

Precedências

Sem precedências

Conhecimentos Prévios recomendados

Domínio de programação, de algoritmos e estruturas de dados, probabilidades, programação, álgebra linear e estatística.

Objetivos de aprendizagem (conhecimentos, aptidões e competências)

Em traços gerais, a Aprendizagem Máquina visa dotar programas com a capacidade de melhorar o seu desempenho através da sua experiência (e.g. pilotos autónomos, reconhecedores de faces, fala ou escrita, filtros de spam). A unidade curricular inclui teoria, algoritmos e aspetos práticos de implementação de Aprendizagem Máquina de acordo com várias perspetivas. A disciplina é claramente interdisciplinar e inclui tópicos como técnicas Bayesianas, máquinas de vetores de suporte, métodos de aprendizagem estatística, aprendizagem não supervisionada e por reforço.

No fim desta disciplina os estudantes deverão ser capazes de caracterizar Aprendizagem Máquina, assim como aplicar técnicas adequadas de Aprendizagem Máquina no desenvolvimento de programas capazes de encontrar soluções para instâncias de problemas de regressão, classificação e previsão.

Conteúdos programáticos

1. Introdução
2. Regressão Linear e Logística
3. Regularização
4. Abordagem conexionista
5. Máquinas de vetores de suporte (SVM)
6. Árvores de decisão
7. Métodos de *ensemble* : bagging, boosting, random forests
8. Aprendizagem não supervisionada e agrupamento
9. Redução de Dimensionalidade: PCA e deep autoencoders
10. Técnicas Bayesianas
11. Modelos gráficos probabilísticos

Metodologias de ensino (avaliação incluída)

Método clássico de ensino e aprendizagem para as disciplinas científico-tecnológicas.

As aulas teóricas são expositivas com recurso ao quadro e ao projector de vídeo.

Nas aulas práticas promove-se a resolução de problemas através do desenvolvimento de tutoriais de laboratório e de mini-projectos.

Nas aulas de tutoria os estudantes são incentivados a desenvolver a sua capacidade de análise e o seu espírito crítico.

Bibliografia principal

Christopher Bishop, *Pattern Recognition and Machine Learning*, Springer, 2006

(alternativamente)

Ethem Alpaydin, *Introduction to Machine Learning*. MIT Press, 2010

Papers selecionados e outros elementos de estudo estarão disponíveis em <http://w3.ualg.pt/~jvo/ml/>

Academic Year 2018-19

Course unit MACHINE LEARNING

Courses ELECTRONIC ENGINEERING AND TELECOMMUNICATIONS (Integrated Master's) (*)
INFORMATICS ENGINEERING (*)

(*) Optional course unit for this course

Faculty / School Faculdade de Ciências e Tecnologia

Main Scientific Area CIÊNCIA DE COMPUTADORES

Acronym

Language of instruction English - EN

Teaching/Learning modality Presential

Coordinating teacher José Luís Valente de Oliveira

Teaching staff	Type	Classes	Hours (*)
----------------	------	---------	-----------

* For classes taught jointly, it is only accounted the workload of one.

Contact hours

T	TP	PL	TC	S	E	OT	O	Total
30	0	30	0	0	0	0	0	168

T - Theoretical; TP - Theoretical and practical ; PL - Practical and laboratorial; TC - Field Work; S - Seminar; E - Training; OT - Tutorial; O - Other

Pre-requisites

no pre-requisites

Prior knowledge and skills

Working (undergraduate) knowledge of algorithms, data structures, probability, programming, linear algebra, and statistics.

The students intended learning outcomes (knowledge, skills and competences)

Roughly speaking, Machine Learning aims at endowing computer programs with the ability to improve their performance using their experience (e.g., autonomous pilots, human face/voice/signature recognizers, spam filters). This subject covers theory, algorithms, and practical issues of Machine Learning from a variety of perspectives. The course is interdisciplinary and includes topics such as Bayesian techniques, Support Vector Machines, statistical learning methods, unsupervised learning and reinforcement learning.

At the end of this course, students should be able to characterize Machine Learning, as well as to apply suitable Machine Learning techniques in the development of program for solving regression, classification, and forecast tasks.

Syllabus

1. Introduction
2. Linear and Logistic Regression
3. Regularization
4. The connectionist approach: Neural Networks
5. Support Vector Machines (SVM)
6. Decision trees
7. Ensemble Methods: bagging, boosting, random forests
8. Unsupervised learning and clustering
9. Dimensionality reduction: PCA and deep autoencoders
10. Bayesian techniques
11. Probabilistic Graphical Models

Teaching methodologies (including evaluation)

1. Final grade

Final Grade = 0,6 Written exam + 0,4 Lab Assessment

Only final grade will be rounded off.

2. Admission to the exams

2.1. All ordinary students properly registered in the course will be admitted to the exams if and only if the following conditions are met (*):

2.1.1. 2/3 lab presences minimum

2.1.2. Lab Assessment $\geq 7,5$ values (in a 0-20 scale)

? Exams

All exams are written. Students are allowed to bring to the exams up to (25) twenty five A4 pages written with a font size not less than nine (9) .

Lab assessment

Registration in a working group is mandatory

Lab works are developed in group

Group lab assessment is given by a weighted sum of the assessment of each work?.

The group lab assessment is converted into individual lab assessment in the moment of the individual discussion.

Main Bibliography

(textbook)

Christopher Bishop, *Pattern Recognition and Machine Learning* , Springer, 2006

(alternative textbook)

Ethem Alpaydin, *Introduction to Machine Learning* . MIT Press, 2010

Selected papers and other resources will be available from <http://w3.ualg.pt/~jvo/ml/>