
Ano Letivo 2020-21

Unidade Curricular APRENDIZAGEM MÁQUINA

Cursos ENGENHARIA INFORMÁTICA (2.º ciclo) (*)

ENGENHARIA ELETRÓNICA E TELECOMUNICAÇÕES (Mestrado Integrado) (*)

(*) 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 / Ensino à Distância com recurso a video conferência

Docente Responsável José Luís Valente de Oliveira

DOCENTE	TIPO DE AULA	TURMAS	TOTAL HORAS DE CONTACTO (*)
José Luís Valente de Oliveira	PL; T	T1; PL1	28T; 28PL

* 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	S1	28T; 28PL	156	6

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

Precedências

Sem precedências

Conhecimentos Prévios recomendados

Domínio de programação, algoritmos e estruturas de dados, probabilidades, 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

- Introdução
 - Motivação
 - Conceitos
- Aprendizagem Indutiva
 - O problema de aprendizagem indutiva
 - Hipótese de aprendizagem indutiva
 - Método de máxima verossimilhança
- Regressão
 - Regressão linear
 - Regressão Mutivariada
 - O dilema de variância-viés
 - Regularização
- Classificação: métodos clássicos
 - Regressão logística
 - Classificação bayesiana
 - Árvores de classificação
 - A regra do vizinho mais próximo
- Modelos de kernel e classificação máxima de margem
 - Máquinas de vetores de suporte
- Clustering
 - Agrupamento Particional
 - Agrupamento hierárquico
 - Agrupamento espectral
 - Agrupamento Difuso
 - Análise e validação de agrupamento
- Métodos Ensemble
 - Mixture models
 - O método de boosting
 - Florestas aleatórias
- Modelos gráficos probabilísticos
 - Redes Bayesianas
 - Campos de Markov
 - Inferência e aprendizagem em modelos gráficos
- Engenharia de características
 - Geração de características
 - Seleção de características

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

S. Theodoridis, Machine Learning: A Bayesian and Optimization Perspective, Academic Press, 2015 ISBN: 9780128015223

Papers selecionados e outros elementos de estudo estão disponíveis na tutoria eletrónica.

Academic Year 2020-21

Course unit MACHINE LEARNING

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

(*) Optional course unit for this course

Faculty / School FACULTY OF SCIENCES AND TECHNOLOGY

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 (*)
José Luís Valente de Oliveira	PL; T	T1; PL1	28T; 28PL

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

Contact hours

T	TP	PL	TC	S	E	OT	O	Total
28	0	28	0	0	0	0	0	156

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

- Introduction
 - Motivation
 - Concepts
- Inductive Learning
 - The inductive learning problem
 - The inductive learning hypothesis
 - Maximum Likelihood method
- Regression
 - Linear regression
 - Multivariate regression
 - The bias-variance dilemma
 - Regularization
- Classification: A tour of the classics
 - Logistic regression
 - Bayesian classification
 - Classification trees
 - The nearest neighbor rule
- Kernel models and maximum margin classification
 - Support vector machines
- Clustering
 - Partitional clustering
 - Hierarchical clustering
 - Spectral clustering
 - Fuzzy clustering
 - Clustering validity analysis
- Ensemble methods
 - Mixture models
 - The boosting method
 - Random forests
- Probabilistic graphical models
 - Bayesian networks
 - Markov random fields
 - Inference and learning in graphical models
- Feature engineering
 - Feature generation
 - Feature selection methods

Teaching methodologies (including evaluation)

1. Final grade

Final Grade = 0,4 Written exam + 0,6 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)

S. Theodoridis, Machine Learning: A Bayesian and Optimization Perspective, Academic Press, 2015 ISBN: 9780128015223

(Other resources)

Selected papers and other learning resources are available from ualg moodle.