
Ano Letivo 2022-23

Unidade Curricular REDES NEURONAIS E APRENDIZAGEM PROFUNDA

Cursos ENGENHARIA INFORMÁTICA (2.º ciclo)

CIBERSEGURANÇA (*)

(*) Curso onde a unidade curricular é opcional

Unidade Orgânica Faculdade de Ciências e Tecnologia

Código da Unidade Curricular 14741066

Área Científica CIÊNCIA DE COMPUTADORES

Sigla

Código CNAEF (3 dígitos) 481

**Contributo para os Objetivos de
Desenvolvimento Sustentável - 4 8 10
ODS (Indicar até 3 objetivos)**

Línguas de Aprendizagem

Português-PT ou Inglês-EN

Modalidade de ensino

Presencial

Docente Responsável

António Eduardo de Barros Ruano

DOCENTE	TIPO DE AULA	TURMAS	TOTAL HORAS DE CONTACTO (*)
António Eduardo de Barros Ruano	T; TP	T1; TP1	28T; 28TP

* 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	S2	28T; 28TP	156	6

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

Precedências

Sem precedências

Conhecimentos Prévios recomendados

Programação Básica e Álgebra Básica

Objetivos de aprendizagem (conhecimentos, aptidões e competências)

O aluno, no final da disciplina, deverá ser capaz de:

- Compreender a inspiração biológica das redes neuronais, suas principais características e aplicações;
- Conhecer as redes multicamadas, de função de base radial e as técnicas mais comuns de treino e de adaptação supervisionados; saber utilizá-las no contexto de aproximação de sistemas e de classificação;
- Conhecer os métodos mais comuns de treino não-supervisionado, baseados nas regras de Hebb e em competição, e as redes de Kohonen; saber utilizá-las em problemas de agrupamento de dados e classificação.
- Conhecer as principais redes neuronais recorrentes, e seus algoritmos de treino; saber utilizá-las em aplicações práticas;
- Conhecer os principais mecanismos de aprendizagem profunda; saber utilizar redes de confiança profunda e convolucionais em aplicações práticas;

Conteúdos programáticos

1. Introdução às Redes Neuronais Artificiais
2. Aprendizagem supervisionada para redes neuronais diretas
 1. Modelos
 2. Algoritmos de Aprendizagem
 1. Topologia fixa
 2. Algoritmos Construtivos
 3. Aplicações para aproximação de funções e reconhecimento de padrões
3. Aprendizagem não supervisionada
 1. Aprendizagem Não Competitiva
 1. Regras do tipo Hebbian
 2. Memórias Associativas Lineares
 2. Aprendizagem Competitiva
 1. Mapas auto-organizados
 2. Classificadores de redes competitivas
4. Redes Neuronais Recorrentes
 1. Introdução aos sistemas dinâmicos não lineares
 2. Modelos
 3. Treino e Operação
 4. Aplicações de Redes Neuronais Recorrentes
5. Aprendizagem Profunda
 1. Revisitando os algoritmos de descida de gradiente
 2. Máquinas restritas da Boltzmann e redes de confiança profunda
 3. Redes Neuronais Convolucionais

Metodologias de ensino (avaliação incluída)

As aulas serão distribuídas por componentes Teórica (T) e Prática Laboratorial (PL). Nas aulas T será exposta a teoria, e apresentados exemplos de aplicação. Nas aulas PL os estudantes implementarão programas em Matlab ou Python, utilizando os módulos disponíveis em cada uma destas linguagens.

Nesta disciplina haverá um mini-projeto, a desenvolver em grupo, com um peso de 50% da nota, e um trabalho individual, com um peso de 50%, realizados e avaliados durante as aulas. Se a nota final for igual ou superior a 10, e ambas as componentes forem classificadas com uma nota superior a 8, o aluno passa.

Bibliografia principal

Apontamentos on-line

Ruano, A. E. (Ed.). Intelligent Control using Intelligent Computational Techniques. 2005: The Institution of Electrical Engineers.

Gori, M., Machine Learning. A Constraint-based Approach. 2018: Morgan Kaufmann.

Haykin, S.O., Neural Networks and Learning Machines. 3 ed. 2008: Prentice Hall.

Aggarwal, C.C., Neural Networks and Deep Learning. A Textbook. 2018: Springer.

Buduma, N. and N. Locascio, Fundamentals of Deep Learning: Designing Next-Generation Machine Intelligence Algorithms. 2017: O'Reilly Media.

Skansi, S., Introduction to Deep Learning: From Logical Calculus to Artificial Intelligence. 2018: Springer International Publishing.

Academic Year 2022-23

Course unit NEURAL NETWORKS AND DEEP LEARNING

Courses INFORMATICS ENGINEERING
Common Branch
(*)

(*) Optional course unit for this course

Faculty / School FACULTY OF SCIENCES AND TECHNOLOGY

Main Scientific Area

Acronym

CNAEF code (3 digits) 481

**Contribution to Sustainable
Development Goals - SGD** 4 8 10
(Designate up to 3 objectives)

Language of instruction Portuguese-PT or English-EN

Teaching/Learning modality

Presential

Coordinating teacher

António Eduardo de Barros Ruano

Teaching staff	Type	Classes	Hours (*)
António Eduardo de Barros Ruano	T; TP	T1; TP1	28T; 28TP

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

Contact hours

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

Basic Programming and basic Algebra

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

At the end of this lecture course the student should:

- Understand the biological inspiration of neural networks, their main characteristics and applications;
- To know the multi-layer perceptrons and radial base function networks, as well as the most common techniques of supervised training and adaptation; know how to use them in the context of systems approximation and classification;
- To know the most common unsupervised training methods, based on Hebbian rules and on competition, and the Kohonen networks; know how to use them in data clustering and classification problems.
- To know the main recurrent neural networks, and their training algorithms; know how to use them in practical applications;
- To know the main mechanisms of deep learning; know how to use deep belief and convolutional networks in practical applications;

Syllabus

1. Introduction to Artificial Neural Networks
2. Supervised Learning for Feedforward Neural Networks
 1. Models
 2. Learning Algorithms
 3. Applications to function approximation and pattern recognition
3. Unsupervised Learning
 1. Non-Competitive Learning
 2. Competitive Learning
4. Recurrent Neural Networks
 1. Introduction to nonlinear dynamic systems
 2. Models
 3. Training and Operation
 4. Applications of Recurrent Neural Networks
5. Deep Learning
 1. Revisiting Gradient Descent Algorithms
 2. Restricted Boltzmann Machines and Deep Belief Networks
 3. Convolutional Neural Networks

Teaching methodologies (including evaluation)

Classes will be distributed by Theoretical (T) and Laboratory Practice (PL) components. In lectures T the theory will be exposed, and examples of application will be presented. In PL classes students will implement programs in Matlab or Python, using the available modules in each of these languages.

In this discipline there will be a group mini-project, with a weight of 50% of the grade, and an individual project, contributing also with 50% to the final grade. These will be done and assessed during the classes. If the final grade is equal to or higher than 10, and both components are graded with a mark higher than 8, the student passes.

Main Bibliography

Apontamentos on-line

Ruano, A. E. (Ed.). Intelligent Control using Intelligent Computational Techniques. 2005: The Institution of Electrical Engineers.
Gori, M., Machine Learning. A Constraint-based Approach. 2018: Morgan Kaufmann.
Haykin, S.O., Neural Networks and Learning Machines. 3 ed. 2008: Prentice Hall.
Aggarwal, C.C., Neural Networks and Deep Learning. A Textbook. 2018: Springer.
Buduma, N. and N. Locascio, Fundamentals of Deep Learning: Designing Next-Generation Machine Intelligence Algorithms. 2017: O'Reilly Media.
Skansi, S., Introduction to Deep Learning: From Logical Calculus to Artificial Intelligence. 2018: Springer International Publishing.