

Ficha de Unidade Curricular – (Versão A3ES 2018-2023)

1. Caracterização da Unidade Curricular.

- 1.1. Designação da unidade curricular (1.000 carateres).**
Aprendizagem Automática Avançada/Advanced Machine Learning
- 1.2. Sigla da área científica em que se insere (100 carateres).**
INF
- 1.3. Duração¹ (100 carateres).**
Semestral
- 1.4. Horas de trabalho² (100 carateres).**
160 horas
- 1.5. Horas de contacto³ (100 carateres).**
22.5 horas T + 33 horas TP + 12 horas PL
- 1.6. ECTS (100 carateres).**
6
- 1.7. Observações⁴ (1.000 carateres).**

É recomendado a quem frequentar a disciplina, ter boas bases teóricas em probabilidade e estatística e em álgebra linear. Adicionalmente, a disciplina tem uma forte componente prática, recorrendo à linguagem de programação Python e a bibliotecas apropriadas (numpy, scipy, scikit-learn, tensor-flow entre outras), e é por isso aconselhável ter um bom domínio da linguagem Python. Obrigatória

1.7. Remarks (1.000 carateres).

It is recommended to those who attend the discipline, to have good theoretical bases in probability and statistics and in linear algebra. In addition, the discipline has a strong practical component using the Python programming language and appropriate libraries (numpy, scipy, scikit-learn, tensor flow, among others), and it is therefore advisable to have a good command of the Python language. Mandatory

2. Docente responsável e respetiva carga letiva na Unidade Curricular (preencher o nome completo) (1.000 carateres).
Gonçalo Caetano Marques, 67.5 horas de contacto.

3. Outros docentes e respetivas cargas letivas na unidade curricular (1.000 carateres).

4. Objetivos de aprendizagem (conhecimentos, aptidões e competências a desenvolver pelos estudantes). (1.000 carateres).

1. Conhecer os fundamentos teóricos de métodos supervisionada classificação e regressão de saber aplicar os mesmos a problemas reais
2. Identificar e compreender as noções essenciais subjacentes à aprendizagem profunda, bem como os principais tipos de modelos, arquiteturas, e técnicas de otimização.
3. Conhecer, saber treinar, e aplicar técnicas de classificação baseadas em redes neuronais profundas de convolução a problemas concretos.
4. Conhecer, saber treinar, e aplicar técnicas de modelação de sequências baseadas em redes neuronais profundas recursivas a problemas concretos.

4. Intended learning outcomes (knowledge, skills and competences to be developed by the students). (1.000 characters).

1. To know the foundations of supervised machine-learning techniques and to be able to apply them to concrete problems.
2. To identify and understand the main concepts of deep-learning methods, the different types of neural

models, architectures, and optimization techniques.

3. To understand, and be able to train and apply deep convolutional neural networks to complex problems.
4. To understand, and be able to train and apply deep recurrent neural networks to sequence modelling and other related problems.

5. Conteúdos programáticos (1.000 carateres).

1. Conceitos básicos de aprendizagem automática. Aprendizagem supervisionada, regressão e classificação, técnicas de otimização, sobre aprendizagem e capacidade de generalização, metodologias de teste, pré-processamento de dados, e métricas de desempenho.
2. Introdução a redes neuronais artificiais. Perceptrão multi-camada (MLP) e algoritmo de retro-propagação. Treino de redes MLP, arquiteturas, funções de ativação, e termos de regularização.
3. Redes neuronais artificiais profundas (DNN). Inicialização e treino de DNN, funções de ativação não-saturadas, normalizações e estratégias de otimização.
4. Redes neuronais profundas de convolução (DCNN). Camada de convolução e filtros utilizados. Camada de "pooling". Arquiteturas e implementações de redes DCNN.
5. Redes neuronais profundas recorrentes (DRNN). Unidades com memória e desdobramento temporal. Treino de redes DRNN, modelação de sequências de comprimento variável.

5. Syllabus (1.000 characters).

1. Fundamentals of machine learning: supervised learning, regression and classification, optimization techniques, learning and generalization capabilities, test methodologies, data pre-processing, and performance metrics.
2. Introduction to artificial neural networks. Multi-layer Perceptron (MLP) and back-propagation algorithm. Training MLP networks, architectures, activation functions, and regularization terms.
3. Artificial deep neural networks (DNN). DNN initialization and training, non-saturating activation functions, normalizations and optimization strategies.
4. Deep convolution neural networks (DCNN). Convolution layer and filters used. Pooling layer. DCNN network architectures and implementations.
5. Deep Recurrent Neural Networks (DRNN). Units with memory and temporal unfolding. DRNN network training, variable length sequence modeling.

6. Demonstração da coerência dos conteúdos programáticos com os objetivos de aprendizagem da unidade curricular (1.000 carateres).

Os conteúdos programáticos 1 concretiza o objetivo 1. Os conteúdos programáticos 2-5 concretizam os objetivos 2-4.

6. Evidence of the syllabus coherence with the curricular unit's intended learning outcomes (1.000 characters).

The syllabus topic 1 accomplishes the point 1 of the unit's intended outcomes. The syllabus topics 2-5 accomplish the unit's intended outcomes 2-4.

7. Metodologias de ensino (avaliação incluída) (1.000 carateres).

Metodologia de ensino teórico-prático suportada em projetos desenvolvidos ao longo do semestre. É adotada a abordagem problem-based learning, privilegiando secções interativas, incentivando a reflexão e discussão entre alunos, sobre temas e exemplos práticos de aplicação.

Os resultados da aprendizagem (1 a 4) são avaliados com base em trabalhos práticos, bem como uma discussão oral dos trabalhos realizados ao longo do semestre.

7. Teaching methodologies (including assessment) (1.000 characters).

The teaching methodology is supported by projects developed during the semester. It adopts the problem-based learning approach, privileging interactive sections, encouraging reflection and discussion among students, on topics and practical examples of application.

The learning outcomes (1 to 4) are evaluated based on practical assignments, as well as an oral discussion of the work assignments carried out during the semester.

8. Demonstração da coerência das metodologias de ensino com os objetivos de aprendizagem da unidade curricular (3.000 caracteres).

Os objetivos da unidade curricular são obtidos através de aulas teóricas e práticas, de material de apoio e respetiva bibliografia, da realização de exercícios práticos, e de casos de estudo selecionados pelo docente. A realização dos trabalhos práticos é acompanhada pelo docente durante as horas de contacto para assegurar o correto desenvolvimento dos conhecimentos e das competências dos estudantes.

8. Evidence of the teaching methodologies coherence with the curricular unit's intended learning outcomes (3.000 characters).

The objectives of the curricular unit are obtained through theoretical and practical classes, bibliographic and other resources, practical exercises and case studies selected by the teacher. The practical work is carried out by the teacher during the contact hours to ensure the correct development of the knowledge and skills acquired by the students.

9. Bibliografia de consulta/existência obrigatória (1.000 caracteres).

Ian Goodfellow, Yoshua Bengio, Aaron Courville, "Deep Learning", MIT press, 2016.
Aurélien Géron, "Hands-On Machine Learning with Scikit-Learn and TensorFlow", O'Reilly, 2017.

¹ Anual, semestral, trimestral, ...

² Número total de horas de trabalho.

³ Discriminadas por tipo de metodologia adotado (T - Ensino teórico; TP - Ensino teórico-prático; PL - Ensino prático e laboratorial; TC - Trabalho de campo; S - Seminário; E - Estágio; OT - Orientação tutorial; O - Outro).

⁴ Assinalar sempre que a unidade curricular seja optativa.