
1. Caracterização da Unidade Curricular

1.1 Designação

[4314] Aprendizagem Automática / Machine Learning

1.2 Sigla da área científica em que se insere

EB

1.3 Duração

Unidade Curricular Semestral

1.4 Horas de trabalho

45h 00m

1.5 Horas de contacto

Total: 45h 00m das quais T: 30h 00m | TP: 15h 00m

1.6 ECTS

6

1.7 Observações

Unidade Curricular Obrigatória

2. Docente responsável

[9908] Sérgio Rafael Reis Figueiredo

3. Docentes e respetivas cargas letivas na unidade curricular

[9908] Sérgio Rafael Reis Figueiredo | Horas Previstas: 45 horas

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

Após a aprovação na unidade curricular, o aluno deverá possuir a capacidade de:

- Compreender os conceitos e técnicas fundamentais de Machine Learning.
- Representar e modelar sinais e dados biomédicos.
- Conhecer os métodos de estimação, extração e seleção de características.
- Aplicar técnicas de reconhecimento de padrões e teoria da decisão à classificação automática de dados e imagens médicas.
- Desenvolver competências práticas para implementação de algoritmos de Machine Learning e avaliar o seu desempenho em problemas biomédicos reais.



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

After the approval in the curricular unit, the student will have to possess the capacity of:

- Understand the fundamental concepts and techniques of Machine Learning.
- Represent and model biomedical signals and data.
- Know the methods of feature estimation, extraction and selection.
- Apply techniques of pattern recognition and decision theory in automatic classification of data and medical images.
- Develop practical skills for implementing Machine Learning algorithms and evaluating their performance applied to real biomedical problems.

5. Conteúdos programáticos

1. Introdução aos conceitos da *Machine Learning* aplicada à engenharia biomédica.
2. Dos dados aos achados às decisões.
3. Conceitos fundamentais de engenharia de características para *Machine Learning*.
4. Técnicas de análise da qualidade e preparação de dados: avaliação e generalização em conjunto de treino, teste e validação.
5. Avaliação do processo de aprendizagem, métricas de desempenho e avaliação do erro.
6. Métodos e técnicas de aprendizagem supervisionada
7. Métodos e técnicas de aprendizagem não-supervisionada
8. Modelação preditiva
9. Introdução a redes neuronais, *Deep Learning* e modelos generativos.
10. Realização de trabalhos laboratoriais usando a linguagem de programação Python e as bibliotecas apropriadas para aplicação em cada problema.

5. Syllabus

1. Introduction to machine learning applied to biomedical engineering
2. From data to insights to decisions
3. Fundamental concepts of feature engineering for Machine Learning.
4. Quality analysis and data preparation techniques: evaluation and generalization in training, testing and validation sets
5. Learning evaluation, performance metrics and error evaluation
6. Methods and techniques of supervised learning
7. Methods and techniques of unsupervised learning
8. Prediction Modelling
9. Introduction to Neural Networks, Deep Learning and generative models.
10. Carrying out laboratory working tasks using the Python programming language and the appropriate libraries applied to each problem.

6. Demonstração da coerência dos conteúdos programáticos com os objetivos de aprendizagem da unidade curricular

A abordagem integrada e progressiva do programa da UC permitirá que os estudantes assimilem os fundamentos teóricos e desenvolvam competências práticas face aos objetivos propostos. Garante-se, assim, o conhecimento e a articulação com técnicas do reconhecimento de padrões no âmbito das estratégias clássicas de apoio à decisão. Por outro lado, assegura-se a integração dos conteúdos teóricos, em articulação com o desenvolvimento de competências práticas para implementação de algoritmos de Machine Learning aplicados em contexto biomédico real. Deste modo, o estudante ficará apto para identificar qual a melhor estratégia, de acordo com o problema apresentado, procurando otimizar os outcomes de um determinado sistema biomédico.

6. Evidence of the syllabus coherence with the curricular unit's intended learning outcomes

The integrated and progressive approach of the UC program will allow students to assimilate the theoretical fundamentals and develop practical skills related to the proposed objectives. This approach allows the articulation of concepts related to all methods and techniques of pattern recognition applied to decision aided. Similarly, the integration of theoretical content is ensured, in conjunction with the development of practical skills for implementing Machine Learning algorithms applied in a real biomedical context. Overall, the student will be able to identify the best strategy, based on a given problem, in order to optimize the outcomes of a specific biomedical system.

7. Metodologias de ensino (avaliação incluída)

As aulas serão de: Componente Teórica: método expositivo, exemplos aplicados e sessões com preletores convidados especialistas na área da aprendizagem automática; Componente Teórico-Prática: sessões práticas baseadas em estudos-caso, com implementação baseada em guiões de programação, para resolução de problemas associados às temáticas da UC.

Nesse sentido, a UC tem avaliação distribuída com exame final (E).

A avaliação distribuída é constituída por uma componente prática (NP), constituída por três trabalhos laboratoriais (TL), sendo $NP=30\%TL1+30\%TL2+40\%TL3$.

A classificação final, $CF=60\%NP+40\%E$.

A aprovação implica $CF \geq 9.50$ e $E \geq 9.50$ e $NP \geq 9.50$ e $TL1 \geq 8.00$ e $TL2 \geq 8.00$ e $TL3 \geq 8.00$.



**7. Teaching methodologies
(including assessment)**

This course consists of: Theoretical teaching: lectures and special sessions with invited speakers in the specific area of automatic learning; Practical and Skills Lab: practical sessions based on case studies, with implementation based on programming scripts, to solve problems associated with the UC main themes.

In this sense, the UC has distributed assessment with a final exam (E).

The distributed assessment consists of a practical component (NP), contained by three laboratory works (TL), with $NP=30\%TL1+30\%TL2+40\%TL3$.

The final classification, $CF=60\%NP+40\%E$.

Approval implies $CF \geq 9.50$ and $E \geq 9.50$ and $NP \geq 9.50$ and $TL1 \geq 8.00$ and $TL2 \geq 8.00$ and $TL3 \geq 8.00$.

**8. Demonstração da coerência
das metodologias de ensino
com os objetivos de
aprendizagem da unidade
curricular**

O desenvolvimento das aulas decorrerá harmonizando as metodologias de ensino com os objetivos fundamentais da UC. Esta será uma UC de aplicação, onde os estudantes aprenderão não só o porquê, mas também como executar, avaliar e decidir.

A aquisição de informação e de conhecimentos científicos e técnicos previstos nos objetivos será desenvolvida no início de cada tópico previsto, nas aulas teóricas, onde será estabelecida a relação com outras matérias já tratadas em aulas anteriores ou noutras UC's.

Tentar-se-á estimular um processo de diálogo em que todos participem, através da sua própria experiência e saber. Assim, partilhar-se-á conhecimento, dúvidas e questões, de modo a beneficiar a aprendizagem dos estudantes e a provocar maior motivação dos mesmos.

A avaliação dos estudantes servirá para a aferição da eficácia das metodologias de ensino desenvolvidas na observância dos objetivos da UC e, se necessário, no futuro poder-se-á realizar algumas adaptações nas metodologias de ensino.

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

During the lectures the methodologies will be harmonized to ensure the achievement of the objectives of the course. With this course the students can learn not only why, but also how to perform, evaluate and decide. The acquisition of information, scientific and technical knowledge that are explained in the objectives will be developed at the beginning of each topic during the theoretical lectures where the relationship will be established with other matters already addressed in previous lectures or other courses.

Discussion will be promoted to everyone participate, through their own experience and knowledge. Thus, knowledge, questions and doubts can be shared in order to benefit the learning and motivation of the student. The evaluation of students allows the measure the effectiveness of teaching methodologies developed in compliance with the course objectives and, if necessary, in the future it will be possible to carry out some changes in teaching methodologies.

9. Bibliografia de consulta/existência obrigatória

Géron A. 2019. Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems. O'Reilly Media.

Zheng A, Casari A. 2018. Feature Engineering for Machine Learning: Principles and Techniques for Data Scientists, O'Reilly Media.

Ozdemir S, Susarla D. 2018. Feature Engineering Made Easy, Packt Pub.

Kelleher J et al. 2015. Fundamentals of Machine Learning for Predictive Data Analytics: Algorithms, Worked Examples and Case Studies, MIT Press.

Hastie T et al. 2009. The Elements of Statistical Learning. Springer New York Inc.

Theodoridis S & Koutroumbas K. 2008. Pattern Recognition, Fourth Edition, 4th ed. Academic Press.

Duda R, Hart P & Stork D. 2001. Pattern Classification, Wiley.

Jain AK, Duin RP & Mao J. 2000. Statistical pattern recognition: A review, IEEE Trans Pattern Anal Mach Intell, 22, 4?37.

Tuceryan M & Jain A. 1998. The Handbook of Pattern Recognition and ComputerVision (2Ed). World Scientific PublishingCo.

10. Data de aprovação em CTC 2024-07-17

11. Data de aprovação em CP 2024-06-26