
CURSO: Doutorado em Modelagem Matemática
DISCIPLINA: Análise Visual de Dados
PROFESSOR(ES): Jorge Poco
CARGA HORÁRIA: 60h
PRÉ-REQUISITO: Não possui

PLANO DE ENSINO

1. Ementa

Este curso é sobre tópicos relacionados à análise visual e aprendizado de máquina. A análise visual é uma área de visualização de dados preocupada em melhorar o processo analítico de um ser humano ou em como entender os dados de um determinado problema: entender, raciocinar e tomar decisões sobre um conjunto de dados fornecidos e um determinado domínio de problema. A análise visual, em particular, preocupa-se em combinar processos automatizados, com processos orientados e humanos, criados em torno da visualização de dados – representações visuais de dados e maneiras de interagir com os dados. Dado o rápido crescimento semelhante ao alavancar o aprendizado de máquina de várias maneiras. Este curso abordará tópicos que vivem na interface da análise visual e do aprendizado de máquina, expondo os conceitos básicos da análise visual, como o aprendizado de máquina pode ser usado para aprimorar a análise visual e como a análise visual pode ajudar o aprendizado de máquina.

2. Objetivos da disciplina

Espera-se que você aprenda o seguinte fazendo este curso:

- As pesquisas mais recentes no campo da análise visual, no que se refere ao aprendizado de máquina.
- A capacidade de criticar os designs de visualização, em termos de satisfazer os bons princípios de design de visualização e as necessidades analíticas do usuário.
- O que está envolvido no design de visualizações para criar sistemas de análise visual?
- Criação de visualizações usando tecnologias baseadas na Web.

3. Procedimentos de ensino (metodologia)

Apresentação dos tópicos em sala de aula. Na primeira parte da disciplina, serão realizadas tarefas de programação, além de um teste de programação no final desse período. Na segunda parte, a nota será dividida entre um projeto final a ser desenvolvido em grupo e a participação em classe. Os alunos terão de fazer apresentações de seus projetos finais.

4. Conteúdo programático detalhado

DATA	TOPICO	ACTIVITIES
março 7	Introdução ao Visual Analytics	Aula
março 9	Lab: Noções básicas de design de visualização	Lab
março 14	Design de visualizações	Aula
março 16	Lab: Projetando visualizações com o D3	Lab
março 21	Aprendizado interativo de máquina	Aula
março 23	Lab: Squares	Lab
março 28	Iniciativas Mistas de Exploração Visual, Parte. 1	Aula
março 30	Lab: iPCA	Lab
abril 4	Iniciativas Mistas de Exploração Visual, Parte. 2	Aula
abril 6	Feriado	
abril 11	Iniciativas Mistas de Exploração Visual, Parte. 3	Aula
abril 13	Lab: Dash + Jupyter UI	Lab
abril 18	Iniciativas Mistas de Exploração Visual, Parte. 4	Lecture
abril 20	Lab: Visualização de texto	Lab
abril 25	Visual Analytics para Compreensão do Modelo, Part. 1	Aula
abril 27	Apresentação do aluno	Apresentações
maio 2	Visual Analytics para Compreensão do Modelo, Part. 2	Aula
maio 4	Apresentação do aluno	Apresentações
maio 9	Visual Analytics para Compreensão do Modelo, Part. 3	Lecture
maio 11	Apresentações de propostas de projetos	Apresentações
maio 16	Visual Analytics para Compreensão do Modelo, Part. 4	Lecture
maio 18	Apresentação do aluno	Apresentações
maio 23	Visual Analytics para Treinamento de Modelo, Part. 1	Lecture
maio 25	Apresentação do aluno	Apresentações
maio 30	Visual Analytics para Treinamento de Modelo, Part. 2	Lecture
junho 1	Apresentação do aluno	Apresentações
junho 6	Visual Analytics para Treinamento de Modelo, Part. 3	Lecture
junho 8	Feriado	
junho 13	Visual Analytics para Treinamento de Modelo, Part. 4	Aula
junho 15	Apresentação do aluno	Apresentações
junho 20	Aprendendo para o Vis, Parte 1	Aula
junho 22	Apresentação do protótipo do projeto final	Apresentações
junho 27	Aprendendo para o Vis, Parte 2	Aula
junho 29	Apresentação do aluno	Apresentações
julho 4	Retrospectiva	Aula
julho 6	Apresentação do projeto final	Apresentações

5. Procedimentos de avaliação

- Trabalhos: 40%
 - Tarefa 1: 5%
 - Tarefa 2: 15%
 - Tarefa 3: 20%
- Participação em aula: 20%
 - Apresentação do trabalho de pesquisa: 15%
 - Discussão ativa em sala de aula: 5%
- Projeto: 40%

6. Bibliografia Obrigatória

Não há livro didático para o curso - todas as palestras serão baseadas nos artigos que listamos na seção de artigo do site. A seção de agendamento lista os documentos que serão abordados durante cada palestra. Espera-se que antes da palestra, você tenha lido os trabalhos correspondentes.

7. Bibliografia Complementar

1. Machine Learning: a Probabilistic Perspective, Kevin Patrick Murphy, MIT Press, 2012.
2. Interpretable Machine Learning: A Guide for Making Black Box Models Explainable, Christoph Molnar, <https://christophm.github.io/interpretable-ml-book/>
3. Visualization Analysis and Design, Tamara Munzner, A K Peters Visualization Series. CRC Press, 2014.
4. Deep Learning, Ian Goodfellow, Yoshua Bengio and Aaron Courville, MIT Press, 2016 <http://www.deeplearningbook.org/>

8. Minicurrículo do(s) Professor(s)

Jorge is an associate professor in the School of Applied Mathematics of Fundação Getúlio Vargas (FGV-EMAp). Previously he was an assistant professor in the Research and Innovation Center in Computer Science (RICS) at the San Pablo Catholic University (UCSP) and a research associate in the UW Interactive Data Lab (IDL) at the University of Washington. He obtained his Ph.D. from the NYU Polytechnic School of Engineering in 2015. Before going to NYU he spent a year in the Scientific Computing and Imaging Institute (SCI) at the University of Utah (UoU). He has an M.S. in Computer Science from the Instituto de Ciências Matemáticas e de Computação (ICMC) at the University of São Paulo (USP), Brasil-2010, and a B.E. in System Engineering from the National University of San Agustín (UNSA), Peru-2008. As part of his professional life, he worked at zAgile Inc as a software engineer on 2008. He has done internships at Google Inc. (2008 and 2010), Kitware Inc (2011), Oak Ridge National Laboratory (2012) and Xerox Research (2013).

His research has focused on data visualization. He has participated in projects on information visualization, scientific visualization, and visual analytics. He was also involved in interdisciplinary collaborations that focused on the development of novel visualization methods to enable both climate and urban data analysis.

9. Link para o Currículo Lattes

<http://lattes.cnpq.br/1565709349354834>