

Curso de Especialização em **Aprendizagem de Máquina em Inteligência Artificial****Estrutura Curricular – componente curricular/carga horária.**

MÓDULO 1 – Bases Tecnológicas da Indústria 4.0	
Computação em Nuvem	32 h/a
<i>Big Data</i> e Visualização de Dados	32 h/a
Internet das Coisas	32 h/a
Aprendizagem de Máquina	32 h/a
Carga horária total do módulo	128 horas-aulas
MÓDULO 2 – Aprendizagem de Máquina em Inteligência Artificial	
Visualização de Dados	32 h/a
Classificação	32 h/a
Aprendizagem não supervisionada	32 h/a
<i>Deep Learning</i>	32 h/a
Carga horária total do módulo	128 horas-aulas
MÓDULO 3 – Tópicos Avançados em Aprendizagem de Máquina	
Análise Descritiva de Dados	32 h/a
Regressão e Previsão de Séries Temporais	32 h/a
Aplicações de Aprendizagem de Máquina em <i>Big Data</i>	32 h/a
Aplicações de <i>Deep Learning</i>	32 h/a
Carga horária total do módulo	128 horas-aulas
Módulo 4 - Metodologia do Trabalho Científico	48 horas-aulas à distância
Total da carga horária do curso	432 horas-aulas



IDENTIFICAÇÃO DA DISCIPLINA (01)

1. Nome da Disciplina: **Computação em Nuvem**
2. Carga Horária: 32h
3. Ementa: Tecnologias e padrões de indústria de Cloud Computing, etapas do ciclo de vida, arquiteturas lógicas e modelos distribuídos, High Performance Computing, Multitenancy, Integração e QoS para Cloud Computing, Escalabilidade, Balanceamento de carga. Tendências e a visão dos analistas de mercado.
4. Objetivo: Apresentar ao participante todos os fundamentos, tecnologias e padrões de Computação em Nuvem necessários para tomada de decisão seja com relação a modelos de negócios ou arquiteturas de TI; Aborda aspectos práticos e temas fundamentais como Multitenancy, Integração, Escalabilidade, Segurança com a aplicação de estudos de caso.
5. Conteúdo Programático: Tecnologia de Cloud Computing; O ciclo de vida de Cloud; Modelos de Referência para Cloud; Padrões da Indústria de Cloud; Arquitetura Lógica de Cloud; Modelo de Deployment; High Performance Computing; Multitenancy; Integração e QoS para Cloud Computing; Escalabilidade, Balanceamento de carga; Monitoramento; Segurança e Privacidade; Visão dos analistas de mercado (Gartner, IDC); Estudos de Caso.
6. Bibliografia:
 - a. Básica:

KAVIS, Michael J..**Architecting the Cloud: Design Decisions for Cloud Computing Service Models (SaaS, PaaS, and IaaS)**. Wiley, 2014. 224 p. ISBN 1118617614.

WANG, Lizhe; RANJAN, Raji; CHEN, Jinju; BENATALLAH, Boualem, **Cloud Computing: Methodology, Systems, and Applications**. CRC Press, 2011. 844 p. ISBN 978-1-4398-5641.
 - b. Complementar:

VELTE, Anthony T., VELTE, Toby J., ELSENPETER, Robert. **Cloud Computing - computação em nuvem uma abordagem prática**. Alta books,



2011. 352 p. ISBN 9788576085362.

IDENTIFICAÇÃO DA DISCIPLINA (02)

1. Nome da Disciplina: **Big Data e Visualização de dados**
2. Carga Horária: 32h/aula.
3. Ementa: Conceitos de *Big Data*, manipulação de dados não relacionados, interação com redes sociais, ciclo de vida da informação, tecnologias Hadoop e MongoDB, comparação com sistemas de banco de dados relacionais, ferramentas simples de visualização de dados (Excel, R, Python, Tableau); gráficos em 2D e 3D; o valor de um bom processo de visualização.
4. Objetivo: Proporcionar aos alunos introdução aos conceitos de *big data*, incluindo considerações técnicas (tecnologias, modelagem de dados, etc) assim como impactos e benefícios às organizações e à sociedade. Consolidar o conhecimento de trabalhar com grandes volumes de dados estruturados e não estruturados. Apresentar aos alunos os conceitos de um bom processo de visualização de dados; apresentar aos alunos ferramentas que permitam visualizar dados; orientar os alunos para uma forma mais efetiva de apresentar os dados.
5. Conteúdo Programático:
 - a. Histórico e Conceitos de *big data*.
 - b. Os 3Vs (volume, variedade e velocidade) do *big data*.
 - c. Formas de aplicação.
 - d. Impulsionadores e tecnologias de *big data*.
 - e. Introdução a análise e aspectos legais.
 - f. O que é visualização de dados e qual a sua importância.
 - g. Ferramentas simples de visualização: Excel e Tableau.
 - h. Programando um sistema de visualização: Python e R.
 - i. Análise de informação e da forma de apresentar esta informação.
6. Bibliografia:
 - a. Básica:

CAIRO, Alberto. **The Functional Art: An Introduction to Information Graphics and Visualization**. New Riders, 1st ed., 2012.



COLLINS, Robert. **Data Visualization: Introduction to Data Visualization with Python, R and Tableau**, ebook, 2018.

MAYER-SCHÖNBERGER, Viktor; CUKIER, Kenneth. **BIG DATA: Como extrair volume, variedade, velocidade e valor da avalanche de informação cotidiana**. Rio de Janeiro: Campus, 2013.

PROVOST, Foster; FAWCETT, Tom. **Data Science for Business: What you need to know about data mining and data-analytic thinking**,. O'Reilly Media, 2013.

b. Complementar:

AMAZON, WebService. **Getting Started Guide: Analyzing Big Data with AWS**. AWS, 2013.

CAIRO, Alberto. **The Truthful Art: Data, Charts, and Maps for Communication**. New Riders, 1 edition. 2016.

KNAFLIC, Cole Nussbaumer. **Storytelling with Data: A Data Visualization Guide for Business Professionals**. Wiley, 1 ed., 2015.

TUFTE, Edward R.. **The Visual Display of Quantitative Information**. Graphics Press, 2 ed., 2001.

TAURION, Cesar. **Big Data**. Brasport, 2013.

IDENTIFICAÇÃO DA DISCIPLINA (03)

1. Nome do Componente Curricular: **Internet das Coisas**
2. Carga Horária: 32 h/a
3. Ementa: Conceitos, definições e história de Internet das Coisas e M2M. Objetos inteligentes. Plataformas de IoT e tecnologias envolvidas. Discutir as evoluções de IoT no Brasil e no mundo. Aplicabilidade de internet das coisas nos negócios e seu impacto na sociedade. Desafios éticos, segurança e privacidade. Desafios de implementação de IoT no Brasil na visão do BNDES / MCTIC.
4. Objetivo: Mostrar os fundamentos básicos sobre internet das coisas em relação aos



conceitos, histórico, aplicabilidade nos negócios por meio de estudos de casos e desafios de implementação no Brasil.

5. Conteúdo Programático:

- Conceitos e Definições de IoT e M2M
- Histórico sobre internet das coisas
- Objetos: sensores, atuadores, leitores e etiquetas RFID, Smartphone
- Plataformas para IoT: Arduino, Raspberry Pi, Beaboard, entre outros, e tecnologias envolvidas
- Visão de IoT no Brasil e no mundo
- Estudos de casos com exemplos práticos de IoT nos segmentos de negócios, tais como: Automação de escritório e casa, Saúde, Logística, Indústria automotiva, Cidades Inteligentes, drones, Agronegócio, Educação, Transporte, Uso militar, Energia, entre outros
- Desafios éticos, segurança e privacidade
- Desafios para implementação de internet das Coisas no Brasil: Uma visão do Plano de Ação de IoT do BNDES / MCTIC.

6. Bibliografia:

a. Básica:

ATZORI, L.; IERA, A.; MORABITO, G. The internet of things: a survey. **Computer Networks**, v. 54, n. 15, p. 2787-2805, 2010. ISSN 1389-1286.

SINCLER, B. **IoT: como usar a "internet das coisas" para alavancar seus negócios**. São Paulo: Editora Autêntica Business, 2018.

BNDES. **Relatório 8 - Relatório Plano de Ação**. Disponível em: <<https://www.bndes.gov.br/wps/wcm/connect/site/269bc780-8cdb-4b9b-a297-53955103d4c5/relatorio-final-plano-de-acao-produto-8-alterado.pdf?MOD=AJPERES&CVID=m0jDUok>>

b. Complementar:

MANCINI, M. Internet das Coisas: história, conceitos, aplicações e desafios. **Revista Mundo PM**, Jan/Fev. 2017.



MEDAGLIA, C.M. ; SERBANATI, A. An overview of privacy and security issues in the internet of things, in: **Proceedings of TIWDC 2009**, Pula, Italy, September 2009

MUKHOPADHYAY, S.C. **Internet of Things: challenges and opportunities**. Springer Science & Business Media, 2014, 269 p.

RIFKIN, Jeremy. The zero marginal cost society: the internet of things, the collaborative commons, and the eclipse of capitalism. New York: St. Martin's Press, 2014

Bases de dados: PROQUEST e EBSCO.

IDENTIFICAÇÃO DA DISCIPLINA (04)

1. Nome da Disciplina: **Aprendizagem de Máquina**
2. Carga Horária: 32 h/a
3. Ementa: Conceito de Aprendizagem de Máquina. Conceitos de conjunto de treinamento, generalização, *overfitting* e validação. Tipos de aprendizagem. Principais tarefas de Aprendizagem de Máquina. Exemplos de Aplicações. O ecossistema Python para Aprendizagem de Máquina. Algoritmos fundamentais.
4. Objetivo: Entender os conceitos de Aprendizagem de Máquina, generalização e *overfitting*. Entender os principais tipos de aprendizagem. Conhecer as principais tarefas que podem ser realizadas com Aprendizagem de Máquina. Travar contato com uma série de aplicações paradigmáticas de Aprendizagem de Máquina. Conhecer os principais algoritmos de Aprendizagem de Máquina e o conceito de *Deep Learning*.
5. Conteúdo Programático:
 - Conceitos de Aprendizagem de Máquina, conjunto de treinamento, generalização, *overfitting* e validação.
 - Aprendizagem não supervisionada, supervisionada e por reforço.
 - Principais tarefas: associação, agrupamento, classificação, regressão e previsão de séries temporais.
 - Exemplos do estado da arte em Aprendizagem de Máquina.
 - O ecossistema Python para Aprendizagem de Máquina: scikit-learn.



- Principais algoritmos de Aprendizagem de Máquina: *a priori*, *k-means*, regressão linear e logística, árvore de decisão e *support vector machine*; conceito de *deep learning*.

6. Bibliografia:

a. Básica:

GÉRON, Aurélien. **Hands-On Machine Learning with Scikit-Learn and TensorFlow**. Sebastopol: O'Reilly, 2017.

KELLEHER, John D.; MAC NAMEE, Brian; D'ARCY, Aoife. **Fundamentals of Machine Learning for Predictive Data Analytics: Algorithms, Worked Examples, and Case Studies**. Cambridge: MIT Press, 2015.

TAN, Pang-Ning; STEINBACH, Michael; KARPATNE, Anuj; KUMAR, Vipin. **Introduction to Data Mining**. 2 ed. New York: Pearson, 2019.

b. Complementar:

CASTRO, Leandro de; FERRARI, Daniel G. **Introdução à Mineração de Dados: Conceitos Básicos, Algoritmos e Aplicações**. São Paulo: Saraiva, 2018.

SILVA, Leandro Augusto da; PERES, Sarajane Marques; BOSCARIOLI, Clodis. **Introdução à Mineração de Dados**. Rio de Janeiro: Elsevier, 2016.

VANDERPLAS, Jake. **Python Data Science Handbook**. Sebastopol: O'Reilly, 2017.

IDENTIFICAÇÃO DA DISCIPLINA (05)

1. Nome da Disciplina: **Visualização de Dados**
2. Carga Horária: 32h/aula.
3. Ementa: Exploração de diversas formas de visualização e estudo de como os humanos percebem informação; visualização de dados numéricos; visualização de dados não numéricos; o processo de criação e interpretação de visualização de dados; aplicação de técnicas de projeto de interface com usuários na criação de sistemas de visualização.
4. Objetivo: Apresentar ao aluno formas diferentes e efetivas de representar dados numéricos e não numéricos. Dar ao aluno condições de escolher a forma mais apropriada para apresentar informações de forma visual. Apresentar ao aluno ferramentas que facilitem o processo de visualização de dados.



5. Conteúdo Programático:

- a. Gráficos em 2D e em 3D.
- b. Fotorrealismo.
- c. O ser humano: memória, a retina, raciocínio.
- d. Percepção em 2D e em perspectiva.
- e. Dados, mapeamento e cartas.
- f. Coordenadas paralelas e empilhamento de gráficos.
- g. Usando cores e as regras de Tufte.
- h. Gráficos e redes e suas visualizações, sistemas geo-localizados.
- i. Árvores de mapas e escalas multidimensionais.
- j. Sistemas de visualização.
- k. Visualização de informação e de bases de dados.
- l. Projeto de sistemas de visualização.

6. Bibliografia:

a. Básica:

CAIRO, Alberto. **The Functional Art: An Introduction to Information Graphics and Visualization**. New Riders, 1st ed., 2012.

COLLINS, Robert, **Data Visualization: Introduction to Data Visualization with Python, R and Tableau**, ebook, 2018.

YAU, Nathan. **Data Points: Visualization That Means Something**, Wiley, 2013.

b. Complementar:

CAIRO, Alberto. **The Truthful Art: Data, Charts, and Maps for Communication**. New Riders, 2016.

KNAFLIC, Cole Nussbaumer. **Storytelling with Data: A Data Visualization Guide for Business Professionals**. Wiley, 2015.

TUFTE, Edward R.. **The Visual Display of Quantitative Information**. Graphics Press, 2001.



IDENTIFICAÇÃO DA DISCIPLINA (06)

1. Nome da Disciplina: **Classificação**
2. Carga Horária: 32 h/a
3. Ementa: Estudo dos principais algoritmos de Aprendizagem de Máquina para Classificação. Regressão logística: classificação binária. Árvore de decisão. Ensemble methods. Random Forests. Gradient Boosting. Classificação Bayesiana. Support Vector Machine.
4. Objetivo: Conhecer e saber implementar os principais algoritmos de Aprendizagem de Máquina para a tarefa de classificação. Travar contato com uma série de aplicações paradigmáticas de Classificação.
5. Conteúdo Programático:
 - a. Regressão logística.
 - b. Árvore de decisão.
 - c. Ensemble methods. Random Forests.
 - d. Gradient Boosting.
 - e. Classificação Bayesiana.
 - f. Support Vector Machine.
 - g. Exemplos do estado da arte em Classificação.
 - h. Bibliotecas scikit-learn e XGBoost.
6. Bibliografia:
 - a. Básica:

GÉRON, Aurélien. **Hands-On Machine Learning with Scikit-Learn and TensorFlow**. Sebastopol: O'Reilly, 2017.

KELLEHER, John D.; MAC NAMEE, Brian; D'ARCY, Aoife. **Fundamentals of Machine Learning for Predictive Data Analytics: Algorithms, Worked Examples, and Case Studies**. Cambridge: MIT Press, 2015.

TAN, Pang-Ning; STEINBACH, Michael; KARPATNE, Anuj; KUMAR, Vipin. **Introduction to Data Mining**. 2 ed. New York: Pearson, 2019.
 - b. Complementar:

HASTIE, Trevor; TIBSHIRANI, Robert. **The Elements of Statistical Learning: Data Mining, Inference, and Prediction**. 2 ed. Berlin: Springer, 2016.



RASCHKA, Sebastian; MIRJALILI, Vahid. **Python Machine Learning**. 2 ed. Birmingham: Packt, 2017.

VANDERPLAS, Jake. **Python Data Science Handbook**. Sebastopol: O'Reilly, 2017.

IDENTIFICAÇÃO DA DISCIPLINA (07)

1. Nome da Disciplina: **Aprendizagem não supervisionada**
2. Carga Horária: 32h/aula.
3. Ementa: o conceito de bias e variância, regularização de dados (L2, *dropout*, normalização de dados, *batch-norm*), técnicas de agrupamento (K-médias, K-vizinhos mais próximos, análise de componentes principais e independentes, regras de associação).
4. Objetivo: mostrar aos alunos a importância de preparar os dados corretamente e evitar problemas de super-ajustes. Apresentar técnicas de aprendizado não supervisionado e suas aplicações.
5. Conteúdo Programático:
 - a. Bias e variância em aprendizado de máquina.
 - b. Normalização de dados e sua importância.
 - c. Regularização L1 e L2.
 - d. *Dropout* e *batch-norm*
 - e. Aprendizado não supervisionado de máquina – aplicações.
 - f. K-means
 - g. PCA e ICA
 - h. KNN
 - i. Regras de associação.
6. Bibliografia:
 - a. Básica:

GÉRON, Aurélien. **Hands-On Machine Learning with Scikit-Learn and TensorFlow**. Sebastopol: O'Reilly, 2017.



KELLEHER, John D.; MAC NAMEE, Brian; D'ARCY, Aoife. **Fundamentals of Machine Learning for Predictive Data Analytics: Algorithms, Worked Examples, and Case Studies**. Cambridge: MIT Press, 2015.

TAN, Pang-Ning; STEINBACH, Michael; KARPATNE, Anuj; KUMAR, Vipin. **Introduction to Data Mining**. 2 ed. New York: Pearson, 2019.

b. Complementar:

CASTRO, Leandro de; FERRARI, Daniel G. **Introdução à Mineração de Dados: Conceitos Básicos, Algoritmos e Aplicações**. São Paulo: Saraiva, 2018.

SILVA, Leandro Augusto da; PERES, Sarajane Marques; BOSCARIOLI, Clodis. **Introdução à Mineração de Dados**. Rio de Janeiro: Elsevier, 2016.

VANDERPLAS, Jake. **Python Data Science Handbook**. Sebastopol: O'Reilly, 2017.

IDENTIFICAÇÃO DA DISCIPLINA (08)

1. Nome da Disciplina: **Deep Learning**
2. Carga Horária: 32 h/a
3. Ementa: Estudo dos conceitos fundamentais de *Deep Learning*. Conceitos de Redes Neurais Artificiais e *Deep Learning*. Minimização de erro. *Backpropagation*. Hiperparâmetros. Regularização. Ambientes computacionais para *Deep Learning*.
4. Objetivo: Entender os principais conceitos de Redes Neurais Artificiais e *Deep Learning*. Conhecer as principais arquiteturas, em particular a *Feed-forward* e a *Autoencoder*. Entender o algoritmo *backpropagation*. Entender as principais técnicas de treinamento de redes *deep learning*. Conhecer os principais ambientes de desenvolvimento para *Deep Learning*. Ser capaz de implementar soluções baseadas em *deep learning* em ambiente de *cloud computing*.
5. Conteúdo Programático:
 - Conceitos básicos de Rede Neural Artificial e *Deep Learning*: unidades computacionais, pesos e *biases*, camadas, redes profundas.
 - Redes *Feed-forward* e *Autoencoder*.



- Minimização de erro via descida ao longo do gradiente. *Backpropagation*.
- Escolha de hiperparâmetros.
- Escolha de otimizador.
- Técnicas de regularização: regularização L2, parada antecipada, *dropout*.
- Exemplos do estado da arte em *Deep Learning*.
- Ambientes computacionais para *Deep Learning*: TensorFlow, Keras, PyTorch, Amazon Web Services, Google Cloud Platform, Google Colaboratory.
- Implementação de Redes *Deep Learning* em ambiente de *cloud computing*.

6. Bibliografia:

a. Básica:

CHOLLET, François. **Deep Learning with Python**. Shelter Island: Manning, 2018.

GIFT, Noah. **Pragmatic AI: An Introduction to Cloud-Based Machine Learning**. Boston: Addison-Wesley Professional, 2019.

GOODFELLOW, Ian; BENGIO, Yoshua, COURVILLE, Aaron. **Deep Learning**. Cambridge: MIT Press, 2016.

b. Complementar:

AGGARWAL, Charu C. **Neural Networks and Deep Learning: A textbook**. Berlin: Springer, 2018.

GÉRON, Aurélien. **Hands-On Machine Learning with Scikit-Learn and TensorFlow**. Sebastopol: O'Reilly, 2017.

RASCHKA, Sebastian; MIRJALILI, Vahid. **Python Machine Learning**. 2 ed. Birmingham: Packt, 2017.



IDENTIFICAÇÃO DA DISCIPLINA (09)

1. Nome da Disciplina: **Análise Descritiva de Dados**
2. Carga Horária: 32 h/a
3. Ementa: Principais etapas e ferramentas para análise descritiva de dados. Ecosistema Python para Análise de Dados. Pré-processamento e limpeza de dados. Estatística Descritiva. Probabilidade. Amostragem. Teste de Hipóteses.
4. Objetivo: Entender a importância da Análise Exploratória no processo de Aprendizagem de Máquina. Conhecer as principais técnicas de Probabilidade e Estatística necessárias para descrever e entender conjuntos de dados. Conhecer as principais técnicas de limpeza e preparação de dados.
5. Conteúdo Programático:
 - O ecossistema Python para Análise de Dados: Python, Matplotlib, Pandas, NumPy e SciPy.
 - Pré-processamento de dados: técnicas para limpeza e preparação de dados. Técnicas para lidar com dados faltantes, inconsistentes e ruidosos.
 - Estatística Descritiva: Gráficos, Medidas de Posição e Dispersão, *Box plot* e detecção de *outliers*, Correlação.
 - Probabilidade, Probabilidade Acumulada, Probabilidade Condicional, Independência.
 - Distribuições de Probabilidade.
 - Amostragem.
 - Teste de Hipóteses.
6. Bibliografia:
 - a. Básica:

BUSSAB, Wilton O.; MORETTIN, Pedro A. **Estatística básica**. 8 ed.

DOWNEY, Allen B. Think Stats: **Exploratory data analysis**. 2 ed. Sebastopol: O'Reilly, 2015.

MOORE, David S.; NOTZ, William I.; FLINGER, Michael A. **A Estatística Básica e sua Prática**. 7 ed. Rio de Janeiro: LTC, 2017.



b. Complementar:

KELLEHER, John D.; MAC NAMEE, Brian; D'ARCY, Aoife. **Fundamentals of Machine Learning for Predictive Data Analytics: Algorithms, Worked Examples, and Case Studies**. Cambridge: MIT Press, 2015.

PHUONG, Vo. T.H.; CZYGAN, Martin. **Getting Started with Python Data Analysis**. Birmingham: Packt Publishing, 2015.

VANDERPLAS, Jake. **Python Data Science Handbook**. Sebastopol: O'Reilly, 2017.

IDENTIFICAÇÃO DA DISCIPLINA (10)

1. Nome da Disciplina: **Regressão e Previsão de Séries Temporais**
2. Carga Horária: 32h/aula.
3. Ementa: definição de regressão e diferença entre regressão e classificação; aplicações; regressão como previsão de séries temporais; técnicas de regressão: Regressão Linear, Regressão logística, Support Vector Regression, Análise de discriminante linear (LDA), árvores de regressão, aplicações.
4. Objetivo: apresentar aos alunos os conceitos de regressão e suas aplicações; apresentar técnicas de regressão e aplicar estas técnicas em problemas práticos; dar ao aluno ferramentas para a escolha da técnica mais adequada a um problema.
5. Conteúdo Programático:
 - a. O que é regressão, um problema de regressão, aplicações.
 - b. Técnicas de aprendizado de máquina para regressão: regressão linear.
 - c. Regressão logística.
 - d. Redes neurais e SVR.
 - e. Análise de discriminante linear.
 - f. Árvores de regressão.
6. Bibliografia:
 - a. Básica:



GÉRON, Aurélien. **Hands-On Machine Learning with Scikit-Learn and TensorFlow**. Sebastopol: O'Reilly, 2017.

KELLEHER, John D.; MAC NAMEE, Brian; D'ARCY, Aoife. **Fundamentals of Machine Learning for Predictive Data Analytics: Algorithms, Worked Examples, and Case Studies**. Cambridge: MIT Press, 2015.

TAN, Pang-Ning; STEINBACH, Michael; KARPATNE, Anuj; KUMAR, Vipin. **Introduction to Data Mining**. 2 ed. New York: Pearson, 2019.

b. Complementar:

HASTIE, Trevor; TIBSHIRANI, Robert. **The Elements of Statistical Learning: Data Mining, Inference, and Prediction**, 2 ed. Berlin: Springer, 2016.

RASCHKA, Sebastian; MIRJALILI, Vahid. **Python Machine Learning**. 2 ed. Birmingham: Packt, 2017.

VANDERPLAS, Jake. **Python Data Science Handbook**. Sebastopol: O'Reilly, 2017.

IDENTIFICAÇÃO DA DISCIPLINA (11)

1. Nome da Disciplina: **Aplicações de Aprendizagem de Máquina em Big Data**
2. Carga Horária: 32h/aula.
3. Ementa: O uso de aprendizado de máquina em larga escala, preparação de dados e extração de características, classificação e regressão em larga escala, uso de aprendizado de máquina em texto, sistemas de recomendação.
4. Objetivo: mostrar ao aluno as diferenças e semelhanças no uso de técnicas de aprendizado de máquina em conjuntos de dados muito grandes. Estudar alguns casos de aplicação de aprendizado de máquina em bases de dados muito grandes.
5. Conteúdo Programático:
 - a. O uso de aprendizado de máquina em conjuntos grandes de dados, cuidados e gerenciamento.
 - b. O processo de extração de características e preparação dos dados.



- c. Agrupamento, regressão e classificação em larga escala.
- d. Aplicações de aprendizado de máquina em textos.
- e. Aprendizado de Máquina em *streams* de dados.
- f. Sistemas de recomendação e agrupamento.

6. Bibliografia:

a. Básica:

BIFET, Albert; GAVALDÀ, Ricard; HOLMES, Geoffrey; PFAHRINGER, Bernhard.

Machine Learning for Data Streams: with Practical Examples in MOA.

Cambridge: MIT Press, 2018.

GIFT, Noah. **Pragmatic AI: An Introduction to Cloud-Based Machine Learning.**

Boston: Addison-Wesley Professional, 2019.

KELLEHER, John D.; MAC NAMEE, Brian; D'ARCY, Aoife. **Fundamentals of Machine**

Learning for Predictive Data Analytics: Algorithms, Worked Examples, and

Case Studies. Cambridge: MIT Press, 2015.

b. Complementar:

AGGARWAL, Charu C. **Neural Networks and Deep Learning: A textbook.** Berlin:

Springer, 2018.

AMAZON, **WebService. Getting Started Guide: Analyzing Big Data with AWS.** EUA:

AWS, 2013.

GEEWAX, J. J. **Google Cloud Platform in Action.** Shelter Island: Manning, 2018.

IDENTIFICAÇÃO DA DISCIPLINA (12)

1. Nome da Disciplina: **Aplicações de *Deep Learning***
2. Carga Horária: 32 h/a
3. Ementa: Redes Neurais Convolucionais. A camada convolucional. Principais tipos de rede convolucional. Aplicações em Visão. Redes Neurais Recorrentes. Nós LSTM e GRU. Aplicações em Linguagem e Previsão de Séries Temporais.
4. Objetivo: Conhecer os principais conceitos e arquiteturas de Redes Neurais Convolucionais. Travar contato com algumas de suas aplicações em Visão.



Conhecer os principais conceitos e arquiteturas de Redes Neurais Recorrentes. Travar contato com algumas de suas aplicações em Linguagem e em Processamento de Séries Temporais. Implementar Redes Neurais Convolucionais e Recorrentes.

5. Conteúdo Programático:

- Redes Neurais Convolucionais.
- As camadas de convolução e de votação.
- Principais tipos de rede convolucional.
- Aplicações em Visão.
- Redes Neurais Recorrentes.
- Células LSTM e GRU.
- Aplicações em Linguagem e Previsão de Séries Temporais.
- Implementação de Redes Convolucionais e Recorrentes em ambiente de *cloud computing*.

6. Bibliografia:

a. Básica:

CHOLLET, François. **Deep Learning with Python**. Shelter Island: Manning, 2018.

GIFT, Noah. **Pragmatic AI: An Introduction to Cloud-Based Machine Learning**. Boston: Addison-Wesley Professional, 2019.

GOODFELLOW, Ian; BENGIO, Yoshua, COURVILLE, Aaron. **Deep Learning**. Cambridge: MIT Press, 2016.

b. Complementar:

AGGARWAL, Charu C. **Neural Networks and Deep Learning: A textbook**. Berlin: Springer, 2018.

GÉRON, Aurélien. **Hands-On Machine Learning with Scikit-Learn and TensorFlow**. Sebastopol: O'Reilly, 2017.

RASCHKA, Sebastian; MIRJALILI, Vahid. **Python Machine Learning**. 2 ed. Birmingham: Packt, 2017.



IDENTIFICAÇÃO DO COMPONENTE CURRICULAR (13)

1. Nome da Disciplina: **Metodologia do Trabalho Científico**
2. Carga Horária: 48 h
3. Ementa: Prática da documentação, documentação temática e bibliográfica e gerenciamento de documentos, diretrizes para elaboração de uma monografia/artigo científico, determinação do objeto de estudo, definição de fontes de pesquisa, metodologias de levantamento de dados, construção lógica do trabalho, redação do texto, aspectos técnicos da redação do texto, citações bibliográficas. Trabalhos temáticos. Construção da monografia/artigo.
4. Objetivo: Habilitar os alunos para a realização de pesquisas e redação de trabalhos científicos na área da Computação, com ênfase na preparação para a monografia/artigo a ser apresentada (o) no término do curso.
5. Conteúdo Programático:
 - Paradigmas em Ciência;
 - Conceito de Metodologia de Pesquisa;
 - Métodos e Conhecimento;
 - Problemas, Hipóteses e Avaliação de Projetos em Computação;
 - Normas para produção de documentos e de artigos científicos;
 - Normas ABNT;
 - Elaboração da monografia/artigo.
6. Bibliografia:
 - a. Básica:

GIL, A. C. Como elaborar projetos de pesquisa. São Paulo: Editora Atlas, 2017

GUSTAVII, B. Como escrever e ilustrar um artigo científico. São Paulo: Parábola, 2017

MEDEIROS, J.; TOMASI, C. Redação de artigos científicos: métodos de realização, seleção de periódicos, publicação. São Paulo: Editora Atlas, 2016



b. Complementar:

ABNT. Normas publicadas. Disponível em:

< <http://www.abnt.org.br/normalizacao/lista-de-publicacoes/abnt>>.

LAKATOS, E. M.; MARCONI, M.A. Fundamentos de metodologia científica. São Paulo: Editora Atlas, 2017.

LAKATOS, E. M.; MARCONI, M.A. Metodologia do trabalho científico. São Paulo: Editora Atlas, 2017.

LAKATOS, E. M.; MARCONI, M.A. Técnicas de pesquisa. São Paulo: Editora Atlas, 2017.

PEREIRA, M. Artigos científicos: como redigir, publicar e avaliar. São Paulo: Editora Guanabara Koogan, 2011.

YIN, R. K. Estudo de caso: planejamento e métodos. Porto Alegre: Bookmann, 2010.

Bases de dados: PROQUEST e EBSCO.