



Curso de Especialização em: Inteligência Artificial (EAD)

1. Estrutura Curricular – componente curricular/carga horária

<b>MÓDULO 1 – Drivers e Enablers da Inteligência Artificial</b>	
Conceitos de <i>Big Data</i> e <i>Cloud Computing</i>	32 h/a
Inteligência Artificial e Ruptura Digital	32 h/a
Análise de Dados	32 h/a
<b>Carga horária total do módulo</b>	<b>96 horas-aulas</b>
<b>MÓDULO 2 – Aprendizagem de Máquina em Inteligência Artificial</b>	
Introdução à Aprendizagem de Máquinas	32 h/a
Classificação	32 h/a
Visualização de Dados para Tomada de Decisão	32 h/a
<b>Carga horária total do módulo</b>	<b>96 horas-aulas</b>
<b>MÓDULO 3 – Tópicos Avançados em Aprendizagem de Máquina</b>	
Aprendizagem Não Supervisionada e Detecção de Anomalia	32 h/a
Associação e Regressão	32 h/a
<i>Deep Learning</i>	32 h/a
<b>Carga horária total do módulo</b>	<b>96 horas-aulas</b>
<b>MÓDULO 4 -</b>	
Aplicações de Aprendizagem de Máquina em Big Data	32 h/a
Introdução a Previsão de Séries Temporais e a Aprendizagem por Reforço	32 h/a
<i>Deep Learning</i> para Processamento de Linguagem e Visão	32 h/a
<b>Carga horária total do módulo</b>	<b>96 horas-aulas</b>
<b>Módulo 5 – Aplicação de Conhecimento</b>	
	<b>48 horas-aulas à distância</b>
<b>Total da carga horária do curso</b>	<b>432 horas-aulas</b>



IDENTIFICAÇÃO DA DISCIPLINA (01)

1. Nome da Disciplina: **Conceitos de *Big Data* e *Cloud Computing***
2. Carga Horária: 32h/aula.
3. Ementa: Conceitos de *Big Data*. Manipulação de dados não estruturados, interação com redes sociais, ciclo de vida da informação. Tecnologias Hadoop e MongoDB, comparação com sistemas de banco de dados relacionais. Conceitos e terminologias de *Cloud Computing*. As diferentes tecnologias envolvidas em *data centres* na nuvem. Modelos de Nuvem Pública, Privada e Híbrida; suas ofertas de serviço como IaaS, PaaS, SaaS, DaaS e a forma como eles se integram no cenário atual através estudo de casos.
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 relacionado a trabalhar com grandes volumes de dados estruturados e não estruturados. Fornecer ao participante a base para compreensão da evolução das arquiteturas para os modelos atuais de nuvem e suas diferentes ofertas, bem como a mudança e os impactos na área de TI e de negócios.
5. Conteúdo Programático: Histórico e Conceitos de *Big Data*. Os 3Vs (volume, variedade e velocidade) do *Big Data*. Impulsionadores e tecnologias de *Big Data*. Relação entre *Big Data* e *Cloud Computing*. Introdução a *Cloud Computing*. Conceitos básicos e terminologias. Tipos de *Cloud*. Arquitetura em Nuvem: princípios, modelos e sua integração. Cases de sucesso envolvendo *Big Data* e *Cloud Computing*.
6. Bibliografia:
  - a. Básica:

ERL, Thomas, PUTTINI, Ricardo, MAHMOOD, Zaigham. **Cloud Computing: Concepts, Technology & Architecture**. Prentice Hall, 2013. 528 p. ISBN 0133387526.

MARR, Bernard. **Big Data in Practice: How 45 Successful Companies Used Big Data Analytics to Deliver Extraordinary Results**. Wiley, 2016.

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

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

BAHGA, Arshdeep; MADISETTI, Vijay. **Big Data Science & Analytics: A Hands-On Approach**. VPT, 2016.



**UNIVERSIDADE PRESBITERIANA MACKENZIE**

**PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO**

*Coordenadoria de Educação Continuada*



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

**7.** Professor (Responsável pedagógico): Prof. Dr. Charles Boulhosa Rodamilans.



**IDENTIFICAÇÃO DA DISCIPLINA (02)**

1. Nome do Componente Curricular: **Inteligência Artificial e Ruptura Digital**
2. Carga Horária: 32 h/a
3. Ementa: Conceito e exemplos de Ruptura Digital. As principais tecnologias responsáveis pela Ruptura Digital. Oportunidades e Desafios da Ruptura Digital. Inteligência Artificial e Aprendizagem de Máquina como fonte de Ruptura Digital.
4. Objetivo: Apresentar ao aluno o conceito de Ruptura Digital, e as principais tecnologias que a causam. Fazer o aluno entender as oportunidades e os desafios trazidos pela Ruptura Digital. Entender por que e de que forma a Inteligência Artificial e a Aprendizagem de Máquina atuam como fonte extremamente importante de Ruptura Digital.
5. Conteúdo Programático: Conceitos de Ruptura Digital. Principais tecnologias responsáveis pela Ruptura Digital. Oportunidades e Desafios da Ruptura Digital. Inteligência Artificial e Aprendizagem de Máquina como fonte de Ruptura Digital. Estudos de caso. Apresentação do ambiente de desenvolvimento em Inteligência Artificial e Aprendizagem de Máquina.
6. Bibliografia:
  - a. Básica:

IANSTITI, Marco; LAKHANI, Karim R. **Competing in the Age of AI: Strategy and Leadership When Algorithms and Networks Run the World**. Cambridge: Harvard Business Review Press, 2020.

MARR, Bernard. **The Intelligence Revolution: Transforming Your Business with AI**. London: Kogan Page, 2020.

SIEBEL, Tomas M. **Digital Transformation: Survive and Thrive in an Era of Mass Extinction**. New York: Rosetta Books, 2019.
  - b. Complementar:
  - c. KOLBJØRNSRUD, Vegard, AMICO, Richard and THOMAS, Robert J. How Artificial Intelligence Will Redefine Management. **Harvard Business Review**, November 02, 2016.



MAKRIDAKIS, Spyros. The forthcoming Artificial Intelligence (AI) revolution: Its impact on society and firms. **Futures**, vol. 90, June 2017, p. 46-60

SCHWAB, Klaus. **The Fourth Industrial Revolution**. Brisbane: Currency, 2017

**7.** Professor (Responsável pedagógico): Prof. Dr. Fábio Silva Lopes.



IDENTIFICAÇÃO DA DISCIPLINA (03)

1. Nome da Disciplina: **Introdução à 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, *underfitting*, *overfitting* e regularização. 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. Travar conhecimento com os principais algoritmos de Aprendizagem de Máquina e com o conceito de *Deep Learning*.
5. Conteúdo Programático: Conceitos de Aprendizagem de Máquina. generalização, *overfitting* e validação. Aprendizagem não supervisionada, supervisionada e por reforço. Principais tarefas: associação, agrupamento, classificação, regressão e previsão de séries temporais. Conjuntos de treinamento, validação e teste. Conceitos de *bias* e variância. Generalização, *underfitting* e *overfitting*. Regularização. Introdução aos principais algoritmos de Aprendizagem de Máquina: k-médias, regressão logística, árvore de decisão, *a priori* e regressão linear; introdução ao conceito de *deep learning*. Exemplos do estado da arte em Aprendizagem de Máquina. O ecossistema Python para Aprendizagem de Máquina: scikit-learn.
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.

7. Professor (Responsável pedagógico): Prof. Dr. Orlando Bisacchi Coelho.



### IDENTIFICAÇÃO DA DISCIPLINA (04)

1. Nome da Disciplina: **Análise de Dados**
2. Carga Horária: 32 h/a
3. Ementa: Principais etapas e ferramentas para Análise de Dados. Ecossistema 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 de Dados no processo de Aprendizagem de Máquina. Conhecer as principais técnicas de Estatística e Probabilidade necessárias para obter, descrever e entender conjuntos de dados. Conhecer as principais técnicas de limpeza e preparação de dados.
5. Conteúdo Programático: Amostragem. Pré-processamento de dados: técnicas paralimpeza 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. Teste de Hipóteses. O ecossistema Python para Análise de Dados: Python, Matplotlib, Pandas, NumPy e SciPy.
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.
7. Professor (Responsável pedagógico): Prof. Dr. Arnaldo Rabello de Aguiar Vallim Filho.





IDENTIFICAÇÃO DA DISCIPLINA (05)

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, árvore de decisão, *ensemble methods*, *random forests*, *gradient boosting*, classificação Bayesiana, *support vector machine*. Análise de Sentimentos.
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, entre as quais a Análise de Sentimento.
5. Conteúdo Programático: Regressão logística. Árvore de decisão. *Ensemble methods*. *Random Forests*. *Gradient Boosting*. Classificação Bayesiana. *Support Vector Machine*. Exemplos do estado da arte em Classificação. Bibliotecas *scikit-learn* e *XGBoost*. Aplicação: Análise de Sentimentos.
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.
7. Professor (Responsável pedagógico): Prof. Dr. Rogério de Oliveira.



## IDENTIFICAÇÃO DA DISCIPLINA (06)

1. Nome da Disciplina: **Associação e Regressão**

2. Carga Horária: 32h/aula.

3. Ementa: Associação e Algoritmo A Priori. Conceito de regressão e diferença entre regressão e classificação. Técnicas de regressão: regressão linear, árvores de regressão, redes neurais e *support vector regression*. Aplicações.

4. Objetivo: Apresentar aos alunos os conceitos de Associação, Regressão e suas aplicações. Apresentar as técnicas de regressão e aplicar estas técnicas em problemas práticos. Fornecer ao aluno ferramentas para a escolha da técnica mais adequada a um dado problema.

5. Conteúdo Programático: Associação e Algoritmo A Priori. O que é regressão. Regressão linear. Árvores de regressão. Redes Neurais. *Support Vector Regression*. Aplicações.

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.



**UNIVERSIDADE PRESBITERIANA MACKENZIE**

**PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO**

*Coordenadoria de Educação Continuada*



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

**7.** Professor (Responsável pedagógico): Prof. Dr. Mario Olimpio Menezes.



IDENTIFICAÇÃO DA DISCIPLINA (07)

1. Nome da Disciplina: **Visualização de Dados para Tomada de Decisão**
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, de forma a facilitar a obtenção de *insight* e a tomada de decisão. Apresentar ao aluno ferramentas que facilitem o processo de visualização de dados.
5. Conteúdo Programático: Gráficos em 2D e em 3D. Fotorrealismo. O ser humano: memória, a retina, raciocínio. Percepção em 2D e em perspectiva. Dados, mapeamento e cartas. Coordenadas paralelas e empilhamento de gráficos. Usando cores e as regras de Tufte. Gráficos e redes e suas visualizações, sistemas geo-localizados. Árvores de mapas e escalas multidimensionais. Sistemas de visualização. Visualização de informação e de bases de dados. 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, and Tableau**, e-book, 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.
7. Professor (Responsável pedagógico): Prof. Dr. Maurício Marengoni



### 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*. Arquiteturas *Feed-forward* e *Autoencoder*. 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. Arquiteturas *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, Google Colaboratory, Amazon Web Services e GoogleCloud Platform. 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.

7. Professor (Responsável pedagógico): Prof. Dr. Orlando Bisacchi Coelho.



IDENTIFICAÇÃO DA DISCIPLINA (09)

1. Nome da Disciplina: **Aprendizagem Não Supervisionada e Detecção de Anomalia**
2. Carga Horária: 32h/aula.
3. Ementa: Redução de Dimensionalidade e Algoritmo PCA. Principais algoritmos para Agrupamento: k-médias, agrupamento hierárquico e DBSCAN. Detecção de Anomalia.
4. Objetivo: Apresentar técnicas de aprendizado não supervisionado e suas aplicações.
5. Conteúdo Programático: Redução de Dimensionalidade e Algoritmo PCA. k-médias, Agrupamento Hierárquico e DBSCAN. Detecção de Anomalia.
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.
7. Professor (Responsável pedagógico): Prof. Dr. Leandro Nunes de Castro Silva.



## IDENTIFICAÇÃO DA DISCIPLINA (10)

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. Agrupamento, classificação e regressão em larga escala. Uso de aprendizado de máquina em bases textuais. 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 casos relevantes de aplicação de aprendizado de máquina em bases de dados muito grandes, inclusive sistemas de recomendação.
5. Conteúdo Programático: O uso de aprendizado de máquina em conjuntos grandes de dados, cuidados e gerenciamento. O processo de extração de características e preparação dos dados. Agrupamento, classificação e regressão em larga escala. Aplicações de aprendizado de máquina em textos. Aprendizagem de Máquina em *streams* de dados. Aplicação: Sistemas de recomendação.
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.
7. Professor (Responsável pedagógico): Prof. Dr. Leandro Augusto da Silva.





IDENTIFICAÇÃO DA DISCIPLINA (11)

1. Nome da Disciplina: **Introdução a Previsão de Séries Temporais e a Aprendizagem por Reforço**
2. Carga Horária: 32h/aula.
3. Ementa: Introdução a Séries Temporais e suas técnicas de previsão. Introdução a Aprendizagem por Reforço. Aplicações.
4. Objetivo: Apresentar ao aluno os principais conceitos de Séries Temporais e as principais técnicas de Previsão de Séries Temporais. Apresentar ao aluno os principais conceitos e técnicas de Aprendizagem por Reforço. Fazer o aluno conhecer um conjunto relevante de aplicações de Previsão de Séries Temporais e Aprendizagem por Reforço.
5. Conteúdo Programático: Séries temporais: principais conceitos e técnicas de previsão. Tendência e sazonalidade. Médias móveis. Regressão para séries temporais. Suavização. Aprendizagem por Reforço: principais conceitos e algoritmos. O problema da Aprendizagem por Reforço. Programação Dinâmica. *Q-Learning*. Introdução a *Deep Learning* para Aprendizagem por Reforço.
6. Bibliografia:
  - a. Básica:

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

MONTGOMERY, Douglas C.; JENNINGS, Cheryl L.; KULAHCI, Murat. **Introduction to Time Series Analysis and Forecasting**, 2 ed. Wiley, 2015.

SUTTON, Richard S.; BARTO, Andrew G. **Reinforcement Learning**, 2 ed. Cambridge: The MIT Press, 2018.
  - b. Complementar:

BISGAARD, Søren; KULAHCI, Murat. **Time Series Analysis and Forecasting by Example**. Wiley, 2011.

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

GRAESSER, Laura; KENG, Wah Loon. **Foundations of Deep Reinforcement Learning: Theory and Practice in Python**. Boston: Addison-Wesley, 2019.

GOODFELLOW, Ian; BENGIO, Yoshua, COURVILLE, Aaron. **Deep Learning**. Cambridge: MIT Press, 2016.
7. Professor (Responsável pedagógico): Prof. Dr. Mário Olímpio Menezes.



IDENTIFICAÇÃO DA DISCIPLINA (12)

1. Nome da Disciplina: **Deep Learning para Processamento de Linguagem e Visão**
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.
7. Professor (Responsável pedagógico): Prof. Dr. Orlando Bisacchi Coelho.



### IDENTIFICAÇÃO DO COMPONENTE CURRICULAR (13)

1. Nome do Componente Curricular: **Aplicação de Conhecimento**
2. Carga Horária: **48 horas/aula** na modalidade EAD
3. Ementa: A disciplina promove o desenvolvimento do Trabalho de Aplicação de Conhecimento, com base no método prático e aplicado, o qual direciona o aluno para a resolução de um desafio ou problema real vivenciado em um contexto institucional/pessoal, utilizando os conceitos e práticas abordados ao longo do curso.
4. Objetivo: Capacitar o participante para investigar, analisar e compreender as causas e as implicações dos desafios em um contexto institucional/pessoal; e com base no diagnóstico e na pesquisa bibliográfica, propor soluções e ações detalhadas, visando à resolução de problemas ou oportunidades reais e pontuais enfrentadas nesse contexto institucional/pessoal.
5. Conteúdo Programático:
  - Definição do problema/oportunidade/desafio a ser resolvido;
  - Descrição das características gerais do contexto institucional/pessoal;
  - Diagnóstico das origens e implicações do desafio a ser resolvido;
  - Pesquisa bibliográfica sobre os temas relacionados com o desafio do contexto institucional/pessoal;
  - Proposição de soluções e ações detalhadas para a resolução do desafio.

### 6. Bibliografia

#### Básica:

MARCONI, Marina de Andrade. **Fundamentos de metodologia científica**. 8. Rio de Janeiro Atlas 2017 1 recurso online ISBN 9788597010770.

MARCONI, Marina de Andrade. **Técnicas de pesquisa**. 8. Rio de Janeiro Atlas 2017 1 recurso online ISBN 9788597013535.

YIN, Robert K. **Estudo de caso : planejamento e métodos**. 5. Porto Alegre Bookman 2015 1 recurso online ISBN 9788582602324.

GIL, Antonio Carlos. **Estudo de caso : fundamentação científica ; subsídios para coleta e análise de dados ; como redigir o relatório**. São Paulo Atlas 2009 1 recurso online ISBN 9788522464753.

#### Complementar:

GIL, Antonio Carlos. **Como elaborar projetos de pesquisa**. 6. Rio de Janeiro Atlas 2017 1 recurso online ISBN 9788597012934.

FLICK, Uwe. **Introdução à pesquisa qualitativa**. 3. Porto Alegre ArtMed 2008 1 recurso online ISBN 9788536318523.

MATTAR, João. **Metodologia científica na era digital**. 4. São Paulo Saraiva 2017 1 recurso online ISBN 9788547220334.

FACHIN, Odília. **Fundamentos de metodologia**. 6. São Paulo Saraiva 2017 1 recurso online ISBN 9788502636552.



SILVA, Anielson Barbosa da. **Pesquisa qualitativa em estudos organizacionais** : paradigmas, estratégias e métodos. 2. São Paulo Saraiva 2011 1 recurso online ISBN 9788502125018.

THIOLLENT, Michel. **Metodologia da pesquisa-ação**. 10. ed. São Paulo: Cortez, 2000. 108 p. ISBN 8524900296

SEVERINO, Antonio Joaquim. **Metodologia do trabalho científico**. 24. ed. rev. e atual. São Paulo: Cortez, 2017. 317 p. ISBN 9788524924484.

**7.** Professor (Responsável pedagógico): Prof Ms Dirceu Matheus Junior