

## II CiDWeek

Programação das apresentações dos alunos

27 e 30 de Abril

<b>Terça 27 de Abril</b>	
13:55	Rogério Otavio Mainardes da Silva
14:20	Victor Gabriel Souza Barbosa
14:45	Antonio Edimar de Melo Junior
15:10	Leonardo Lima Dionizio
15:35	Intervalo
15:50	Leonardo Marçal
16:15	Dennis Gonçalves Lemes
16:40	Fillipe Rafael Bianek Pierin

<b>Sexta 30 de Abril</b>	
10:30	João Victor da Silva
10:55	Talia Correia Schulz
11:20	Lucas de Barros Teixeira

# Sumário

## Resumos

Método do Gradiente Estocástico para Otimização de Funções Separáveis em Aprendizagem de Máquina	
<i>Rogério Otavio Mainardes da Silva</i> . . . . .	3
Redes de Convolução para classificação de imagens	
<i>Victor Gabriel Souza Barbosa</i> . . . . .	4
Sincronização de Redes Neurais Celulares	
<i>Antonio Edimar de Melo Junior</i> . . . . .	5
Reconhecimento da qualidade de Biópsia Mamária usando Deep Learning	
<i>Leonardo Lima Dionizio</i> . . . . .	6
Analisando dados públicos: um estudo sobre as compras de diárias e passagens no contexto pandêmico	
<i>Leonardo Marçal</i> . . . . .	7
NEAT plays: Redes neurais e jogos virtuais	
<i>Dennis Gonçalves Lemes</i> . . . . .	8
Otimização de Carteiras de Ações	
<i>Fillipe Rafael Bianek Pierin</i> . . . . .	9
Estratégias baseadas em Gradient Boosting para problemas de Regressão	
<i>João Victor da Silva</i> . . . . .	10
Um estudo sobre métodos baseados em árvores de decisão	
<i>Talia Correia Schulz</i> . . . . .	11
Transparência Algorítmica em soluções de IA - Inteligência Artificial	
<i>Lucas de Barros Teixeira</i> . . . . .	12

Observação: os resumos estão em ordem de apresentação.

# Método do Gradiente Estocástico para Otimização de Funções Separáveis em Aprendizagem de Máquina

**Aluno:** Rogério Otavio Mainardes da Silva  
Graduação em Matemática, Universidade Federal do Paraná  
r.otavioms@gmail.com

**Orientador:** Abel Soares Siqueira  
Departamento de Matemática, Universidade Federal do Paraná  
abel.s.siqueira@gmail.com

## Resumo:

Neste trabalho estudamos e implementamos os algoritmos do Gradiente Descendente e Gradiente Estocástico com mini-batch, algoritmos clássicos do contexto da Aprendizagem de Máquina implementados aqui em um pacote de linguagem Julia para a resolução de problemas de Regressão Linear e Logística. Apresentamos os conceitos e definições básicas da Aprendizagem de Máquina e a formulação dos problemas de Regressão Linear e Logística. Para a resolução destes problemas, são introduzidos conceitos de otimização e a construção dos algoritmos com seus devidos embasamentos teóricos. Além disso, com os algoritmos bem definidos, é construída uma simples rede neural para resolução de problemas de classificação binária. Finalmente, são apresentados teste comparativos de consistência e velocidade de funcionamento entre o pacote aqui implementado e o pacote scikit-learn em linguagem Python.

**Palavras-chave:** aprendizagem de máquina, gradiente descendente, gradiente estocástico, regressão linear, regressão logística.

## Referências Bibliográficas:

- [1] BEZANSON, J., EDELMAN, A., KARPINSKI, S. e SHAH, B. Julia: A Fresh Approach to Numerical Computing. SIAM Review 59, 1 (Jan 2017), 65 - 98.
  
- [2] BOTTOU, L. Stochastic Gradient Tricks. In Neural Networks, Tricks of the Trade, Reloaded, G. Montavon, G. B. Orr, e K-R. Müller, Eds., Lecture Notes in Computer Science (LNCS 7700). Springer, 2012, pp. 430 - 445.
  
- [3] GARETH, J., WITTEN, D., HASTIE, T. e TIBSHIRANI, R. An Introduction to Statistical Learning. Springer New York, 2013.

# Redes de Convolução para classificação de imagens

**Aluna:** Victor Gabriel Souza Barbosa  
Graduando em Ciência da Computação, Universidade Federal do Paraná  
victorgsbarbosa@gmail.com

**Orientador:** Lucas Pedroso  
Departamento de Matemática, Universidade Federal do Paraná  
lucaspedroso@ufpr.br

## Resumo:

O trabalho consiste em uma aplicação de redes convolucionais para classificar 6 tipos de terrenos nas seguintes categorias:

1. Buildings
2. Forest
3. Glacier
4. Mountain
5. Sea
6. Street

O objetivo será mostrar como as redes de convolucionais podem ser úteis para a classificação de imagens e assim mostrar alguns exemplos de redes que são formidáveis para a tarefa.

O dataset é disponibilizado pela Intel e foi proposto em um desafio no Kaggle [1] e disponibilizado aos participantes e usuários da plataforma.

**Palavras-chave:** convolução, redes, classificação, redes neurais

## Referências Bibliográficas:

[1] INTEL. Intel Image Classification. Disponível em:  
<https://www.kaggle.com/puneet6060/intel-image-classification>. Acesso em: 05 abr. 2021.

# Sincronização em Redes Neurais Celulares

**Aluno:** Antonio Edimar de Melo Junior

Mestrado em Matemática Pura e Aplicada, Universidade Federal de São Paulo  
aemjunior@gmail.com

**Orientador:** Fernando Martins Antoneli Junior

Departamento de Informática em Saúde, Universidade Federal de São Paulo  
fernando.antoneli@unifesp.br

## Resumo:

Muitos sistemas físicos e biológicos podem ser modelados por redes de sistemas dinâmicos acoplados. Tais redes recebem a estrutura adicional do comportamento dinâmico de componentes individuais. Esse comportamento pode ser comparado, revelando propriedades como sincronia ou, em soluções periódicas, relações de fase específicas. Stewart e colaboradores [1,3] formalizaram o conceito de uma rede de células acopladas, onde uma célula é um sistema de equações diferenciais ordinárias (EDOs) e um sistema de células acopladas consiste em células cujas equações são acopladas. Tal arquitetura é representada por um grafo que indica quais células têm o mesmo espaço de fase, quais estão acopladas a quais e quais acoplamentos são iguais. Um sistema dinâmico reticulado (SDL) é um sistema infinito de EDOs, indexado por pontos em uma malha. Estudos feitos em SDLs geralmente focam em equilíbrios ou ondas viajantes. Tais propriedades podem formar padrões regularmente ordenados por um lado e também exibir formas espacialmente desordenadas (caos espacial) por outro. SDLs surgem em muitas aplicações. Por exemplo, no campo da teoria de circuitos elétricos, particularmente em estudos de redes neurais celulares (RNC). Uma RNC é um SDL no qual cada célula se conecta apenas às células vizinhas que estão dentro de um raio finito. RNCs podem ser vistas em chips usadas para resolver problemas de processamento de imagem e reconhecimento de padrões, por exemplo. Nesta apresentação trataremos dos detalhes do formalismo empregado e discutiremos aplicações práticas em certos modelos e tecnologias [2].

**Palavras-chave:** células acopladas, subespaço de sincronia, redes neurais.

## Referências Bibliográficas:

- [1] ANTONELI, F., DIAS, A.P.S., GOLUBTSKY, M., WANG, Y. Synchrony in lattice differential equations. In: Some Topics In Industrial and Applied Mathematics. (R. Jeltsch, T. Li, and I. Sloan, eds.) Contemporary Applied Mathematics Series 8 World Scientific Publ. Co., 2007.
- [2] MELO, A. Redes de sistemas dinâmicos acoplados com estrutura gradiente ou hamiltoniana. Dissertação de Mestrado, Instituto de Ciência e Tecnologia, Universidade Federal de São Paulo, São José dos Campos, SP, 2020.
- [3] STEWART, I., GOLUBTSKY, M., PIVATO, M. Symmetry groupoids and patterns of synchrony in coupled cell networks. SIAM Journal of Applied Dynamical Systems 2 (4), 2003.

# Reconhecimento da qualidade de Biópsia Mamária usando Deep Learning

**Aluno:** Leonardo Lima Dionizio

Graduando em Bacharelado em Ciência da Computação, Universidade Federal do  
Paraná

leo.l.dionizio@gmail.com

**Orientador:** Lucas Pedroso

Departamento de Matemática, Universidade Federal do Paraná

pedroso.lgp@gmail.com

## Resumo:

Foi realizado um trabalho de reconhecimento da qualidade imagens de biópsia de mama em cima de por volta de 780 imagens de 5 pacientes utilizando a técnica Deep Learning, ou seja, redes neurais, especificamente falando redes convolucionais. Além das técnicas diretas sobre Deep Learning, o trabalho contempla técnicas de pré-processamento de imagens e dados, além de ensembling/stacking utilizando métodos de Machine Learning fora da aprendizagem profunda.

**Palavras-chave:** deep learning, biópsia de mama, aprendizagem profunda.

## Referências Bibliográficas:

[1] CHOLLET, F. Deep Learning with Python. Manning Publications Co., 2018.

[2] PRAJIT, R., ZOPH, B., V. LE., QUOC. Swish: a Self-gated Activation Function. arXiv:1710.05941, 2017.

# Analizando dados públicos: um estudo sobre as compras de diárias e passagens no contexto pandêmico

**Aluno:** Leonardo Marçal

Graduando em Biblioteconomia, Universidade Federal de Pernambuco. Aluno Especial do Programa de Pós-Graduação de Ciência da Computação, Universidade Estadual de Campinas. leonardo.marcal@ufpe.br

## Resumo:

A pergunta de pesquisa que envolve este trabalho de análise busca levantar a problemática à respeito do uso de diárias e passagens concedidas no ano de 2020 ao servidores público, levando em consideração o contexto pandêmico vivenciado e realizando um parâmetro com o ano de 2019. Desta forma buscamos identificar qual o valor gasto por cada órgão, valores gastos por cidade e a quantidade de viagens realizadas por mês. De forma metodológica utilizaremos o modelo *KDD – Knowledge Discovery in Databases (KDDM)* é um processo de Descoberta de Conhecimento em Banco de Dados é utilizado na criação de projetos de ciência de dados. A hipótese levantada é que, com o crescimento da pandemia e a impossibilidade de viagens e aberturas de órgãos públicos em algumas regiões do país, é possível que houve economia a respeito, porém o fato necessita ser avaliado da melhor forma possível. Logo, justifica-se a realização da pesquisa em uma curiosidade acadêmica sobre o trabalho com dados no setor público e suas aplicações com dados verídicos e de confiança.

**Palavras-chave:** análise de dados. ciência de dados. dados abertos.

## Referências Bibliográficas:

- [1] BARRETO, A. d. A. A condição da informação. São Paulo em Perspectiva, SciELO-Brasil, v. 16, n. 3, p. 67–74, 2002.
- [2] DESCOBERTA de conhecimento e mineração de dados. In: PROCEDIMENTOS da oitava conferência internacional ACM SIGKDD sobre descoberta de conhecimento e mineração de dados, 23-26 de julho de 2002, Edmonton, Alberta, Canadá. [S.l.: s.n.].
- [3] MACGARRY, K.O contexto dinâmico da informação. [S.l.]: Brasília: Briquet de Lemos, 1999.
- [3] OLIVEIRA, A. C. S. de; SILVA, E. M. da. Ciência aberta: dimensões para um novo fazer científico. Informação Informação, v. 21, n. 2, p. 5–39, 2016.

# NEAT plays: Redes neurais e jogos virtuais

**Aluno:** Dennis Gonçalves Lemes

Graduação em Matemática Industrial, Universidade Federal do Paraná  
dennis.lemes@gmail.com

**Orientador:** Lucas Pedroso

Departamento de Matemática, Universidade Federal do Paraná  
lucaspedroso@ufpr.br

## Resumo:

NEAT (Neural Networks through Augmented Topologies) é um algoritmo evolucionário que cria redes neurais artificiais inspiradas nas modificações genéticas presentes no processo de evolução, tentando com isso emular o processo de aprendizado do cérebro humano. Nele é possível escolher alguns parâmetros que ditam as regras de evolução, fornecendo uma simulação que permite a resolução do problema proposto. Este trabalho tenta responder a seguinte pergunta: o que acontece se tentarmos usar o NEAT para ensinar o computador a jogar videogames, levando em conta que cada jogo tem suas próprias regras, objetivos e obstáculos à frente? O desafio está no fato de que o agente deverá aprender como ser bem sucedido nesse ambiente sem que o usuário forneça informações sobre as particularidades do jogo, e o NEAT é uma das ferramentas possíveis de se utilizar neste contexto.

**Palavras-chave:** Videogames, Redes neurais, Algoritmos evolutivos.

## Referências Bibliográficas:

[1] Stanley, K. O. e Miikkulainen, R.. Efficient Evolution of Neural Network Topologies. *Evolutionary Computation* 10, vol. 2, pp 99-127, 2002.

[2] Ruscica, T.. AI Plays Flappy Bird - NEAT Python. Disponível em [https://www.youtube.com/playlist?list=PLzMcbGfZo4-lwGZWXz5Qgta\\_YNX3\\_vLS2](https://www.youtube.com/playlist?list=PLzMcbGfZo4-lwGZWXz5Qgta_YNX3_vLS2). Acessado em setembro de 2020.

# Otimização de Carteiras de Ações

**Aluno:** Fillipe Rafael Bianek Pierin

Graduação em Matemática Industrial, Universidade Federal do Paraná  
bianekpierin@gmail.com

**Orientador:** Abel Soares Siqueira

Departamento de Matemática, Universidade Federal do Paraná  
abel.s.siqueira@gmail.com

## Resumo:

O problema de otimização de carteiras compreende na escolha das melhores ações, de forma a criar uma carteira na qual se equilibra o retorno e risco obtido, sendo fundamental fazer a diversificação dos ativos utilizados. O trabalho possui o foco de apresentar o modelo Fracionário (FR) que é um modelo com taxa de retorno sobre o risco. Este modelo minimiza o risco e maximiza o retorno simultaneamente. Além disso, usamos os modelos Markowitz e CVaR, considerando as restrições de limite superior de risco (LSR) e limite inferior de retorno esperado (LIRE), além do modelo multi-objetivo que é a combinação dos modelos com as restrições LSR e LIRE. Nas análises utilizamos os dados de seis bolsas de valores, a linguagem de programação Julia e a linguagem Python para obtenção dos dados através de Web Scrap. Analisamos a fração de retorno ( $\lambda$ ) do modelo FR e encontramos  $\lambda = 0.6$  na média. Usando esse valor nos outros modelos e comparando os resultados adquiridos, averiguamos que o modelo FR nem sempre se apresentou melhor que os outros modelos como desejamos verificar, pois pode se apresentar melhor ou pior dependendo dos dados. Apesar de não ser o melhor modelo, o modelo FR utiliza mais 90% e 70% a menos de tempo computacional e espaço em HD, respectivamente em relação aos outros modelos.

**Palavras-chave:** Otimização de Carteiras, Markowitz, Modelo Fracionário, Bolsa de Valores.

## Referências Bibliográficas:

- [1] Brar, J., Braun, J., Hare, W., & Wang, D. (2020). Portfolio optimization via a returns over risk ratio. <https://doi.org/10.13140/RG.2.2.16187.54563>.
- [2] Maffra, S. (2013). Risco e Seleção de Portfólios com a Medida CVaR e o Modelo GO-GARCH. Disponível em [https://impa.br/wp-content/uploads/2017/08/projetos\\_fim\\_curso\\_sergio\\_maffra.pdf](https://impa.br/wp-content/uploads/2017/08/projetos_fim_curso_sergio_maffra.pdf).
- [3] Markowitz, H. (1952). Portfolio selection. The journal of finance, Wiley Online Library, v. 7, n. 1, p. 77–91. <https://doi.org/10.1111/j.1540-6261.1952.tb01525.x>.

# Estratégias baseadas em Gradient Boosting para problemas de Regressão

**Alunos:** João Victor da Silva

Talia Correia Schulz

Graduandos em Bacharelado em Matemática, Universidade Federal do Paraná

josilva602@gmail.com

taliacschulz@gmail.com

**Orientador:** Lucas Gracia Pedroso

Departamento de Matemática, Universidade Federal do Paraná

lucaspedroso@ufpr.br

## Resumo:

Neste trabalho abordamos o *Gradient Boosting*, que consiste em uma técnica de aprendizagem de máquinas para problemas tanto de classificação como de regressão. Tal estratégia utiliza ideias provenientes do método do gradiente descendente com o intuito de minimizar uma função de perda associada ao problema. Tendo em vista a possível lentidão na convergência do método do gradiente descendente, estudamos artigos que propõem modificações do gradiente boosting baseadas em dois algoritmos conhecidos da área de Otimização: o *Momentum* e o método de aceleração de *Nesterov*. O intuito de tais modificações é tentar acelerar a convergência, ou seja, utilizar menos árvores, porém mantendo o bom desempenho do gradient boosting e sem aumentar a variância. Uma implementação computacional dessas propostas foi feita e os resultados obtidos serão apresentados.

**Palavras-chave:** gradient boosting, aceleração de Nesterov, momentum.

## Referências Bibliográficas:

- [1] FENG, Z.; XU, C.; TAO, D. **Historical Gradient Boosting Machine**. EPiC Series Incomputing. 2018. p(68-80).
- [2] FRIEDMAN, J.; HASTIE, T.; TIBSHIRANI, R. **The Elements of Statistical Learning: Data Mining, Inference, and Prediction**. 2. ed. New York: Springer, 2009.
- [3] JAMES, G.; WITTEN, D.; HASTIE, T.; TIBSHIRANI, R. **An Introduction to Statistical Learning: With Application in R**. 1. ed. New York: Springer, 2013.

# Um estudo sobre métodos baseados em árvores de decisão

**Alunos:** João Victor da Silva

Talia Correia Schulz

Graduandos em Bacharelado em Matemática, Universidade Federal do Paraná

jossilva602@gmail.com

taliacschulz@gmail.com

**Orientador:** Lucas Gracia Pedroso

Departamento de Matemática, Universidade Federal do Paraná

lucaspedroso@ufpr.br

## Resumo:

Neste trabalho abordamos as árvores de decisão (*Decision Trees*), que são modelos para problemas de aprendizado de máquinas supervisionado tanto de classificação como de regressão. Um dos motivos de se utilizar esse método é a facilidade em visualizar os resultados obtidos e de convertê-los em decisões práticas. Por produzirem muitas vezes resultados com alta variância, foram propostas na literatura modificações da técnica, tais como o método de Floresta Aleatória (*Random Forest*) e o *Bagging*. Além de discutir as ideias por trás de tais estratégias, faremos uma comparação de seus desempenhos para diversos conjuntos de dados, a fim de verificar como os métodos baseados em árvores propostos evoluíram ao longo dos anos.

**Palavras-chave:** árvore de decisão, floresta aleatória, bagging.

## Referências Bibliográficas:

- [1] FRIEDMAN, J.; HASTIE, T.; TIBSHIRANI, R. **The Elements of Statistical Learning**: Data Mining, Inference, and Prediction. 2. ed. New York: Springer, 2009.
- [2] JAMES, G.; WITTEN, D.; HASTIE, T.; TIBSHIRANI, R. **An Introduction to Statistical Learning**: With Application in R. 1. ed. New York: Springer, 2013.

# Transparência Algorítmica em soluções de IA - Inteligência Artificial

**Aluno:** Lucas de Barros Teixeira

Mestrando em Ciências da Computação, Escola de Artes, Ciências e Humanidades da  
Universidade de São Paulo

[triate@gmail.com](mailto:triate@gmail.com)

**Orientador:** Marcelo Morandini

Departamento de Ciência de Computação, Escola de Artes, Ciências e Humanidades  
da Universidade de São Paulo

[m.morandini@usp.br](mailto:m.morandini@usp.br)

## Resumo:

Nos dias atuais a sociedade é influenciada por novas tecnologias culminando em questões éticas que jamais existiram, além de sermos há anos uma sociedade conectada. A todo momento, ao termos contato com uma solução tecnológica, nos perguntamos como as decisões dos aplicativos que utilizam esses algoritmos são geradas. Esses procedimentos computacionais amplamente utilizados pelos governos mundo afora, quando o Estado, independente da esfera, é acionado para suprir necessidades da população. Assim, em muitos momentos decisões automatizadas pela IA - Inteligência Artificial são utilizadas. Nessa abordagem, levantaremos sobre a transparência dos algoritmos e descreveremos como tal tema é abordado no Brasil.

**Palavras-chave:** transparência algorítmica; inteligência artificial; ciberdemocracia; interação humano-computador; governo aberto; racismo algorítmico.

## Referências Bibliográficas:

[1] Auditabilidade em IA. Disponível em:

[https://isitics.com/2018/10/17/confia\\_inteligencia\\_artificial](https://isitics.com/2018/10/17/confia_inteligencia_artificial) Acesso: out de 2020

[2] BHARGAVA, A. et al. Entendendo Algoritmos. Editora Novatec, 2017.

[3] Carta Europeia de Ética sobre o uso da IA, disponível em: <https://rm.coe.int/carta-etica-traduzida-para-portuguesrevista/168093b7e0#:~:text=Reconhecendoaimport%C3%A2nciacrescenteda,Carta%C3%89ticaEuropeiasobrea>. Acesso: Ago de 2020.

[4] Cortiz, Diogo. Inteligência Artificial: equidade, justiça e consequências, 2020. Disponível em: <https://cetic.br/pt/publicacao/ano-xii-n-1-inteligencia-artificial-equidade-justica-e-consequencias>. Acesso: Jul de 2020.

[5] Explicabilidade em IA. Disponível em: <https://itsrio.org/pt/projetos/inteligencia-artificial-algoritmos-big-data-e-direitos>. Acesso: out de 2020.

- [6] Google Scholar. Disponível em: <https://scholar.google.com/>. Acesso: dez de 2020.
- [7] FIQUEM SABENDO. Disponível em: <https://fiquemsabendo.com.br/> Acesso: jan de 2021.
- [8] FREITAS, H.; Judiciário brasileiro tem ao menos 72 projetos de inteligência artificial nos tribunais. JOTA, 2020. Disponível em: <https://www.jota.info/coberturas-especiais/Inova-e-acao/judiciario-brasileiro-tem-ao-menos-72-projetos-de-inteligencia-artificial-nos-tribunais-09072020>. Acesso: out de 2020.
- [9] Lei nº 12.527/2011. Disponível em: [http://www.planalto.gov.br/ccivil\\_03/\\_ato2011-2014/2011/lei/l12527.htm](http://www.planalto.gov.br/ccivil_03/_ato2011-2014/2011/lei/l12527.htm). Acesso: dez de 2020.
- [10] NUNES, Dierle; MEDEIROS, Nathália. Inteligência artificial – litigantes habituais e eventuais. Consultor Jurídico, 20 nov. 2018. Disponível em: [www.conjur.com.br/2018-nov-20/opinioao-tecnologia-direito-litigantes-habituais-eventuais](http://www.conjur.com.br/2018-nov-20/opinioao-tecnologia-direito-litigantes-habituais-eventuais). Acesso: fev de 2020
- [11] O'NEIL, C.; Weapons of Math Destruction: How Big Data Increases Inequality and Threatens Democracy, 2017.
- [12] PACITTI, T.; Paradigmas do Software Aberto: Editora Ltc, 2016.
- [13] Portaria nº 25/2019. Disponível em: <https://atos.cnj.jus.br/atos/detalhar/282>. Acesso: ago de 2020.
- [14] Resolução n. 331. Disponível em: <https://juslaboris.tst.jus.br/handle/20.500.12178/176371>. Acesso: ago de 2020.
- [15] Resolução n. 332. Disponível em: <https://www.jusbrasil.com.br/diarios/documentos/917269827/resolucao-n-332-25-08-2020-do-cnj>. Acesso: ago de 2020.
- [16] SILVEIRA, S. A. Governos dos Algoritmos, 2016. Disponível em: <http://www.periodicoeletronicos.ufma.br/index.php/rppublica/article/view/6123/4492>. Acesso: jul de 2020.