

Patrocinado por



Resolvendo problemas

do mundo real com

classificação multirrótulo: uma introdução

Conheça sobre a técnica utilizada em machine learning, deep learning e inteligência artificial



Elaine **Gatto - Cissa**

Cientista de Dados e
Pesquisadora de IA





Patrocinado por



**MOUSER
ELECTRONICS**

Resolvendo problemas do mundo real com classificação multirrótulo: uma introdução

Conheça sobre a técnica utilizada em machine learning, deep learning e inteligência artificial

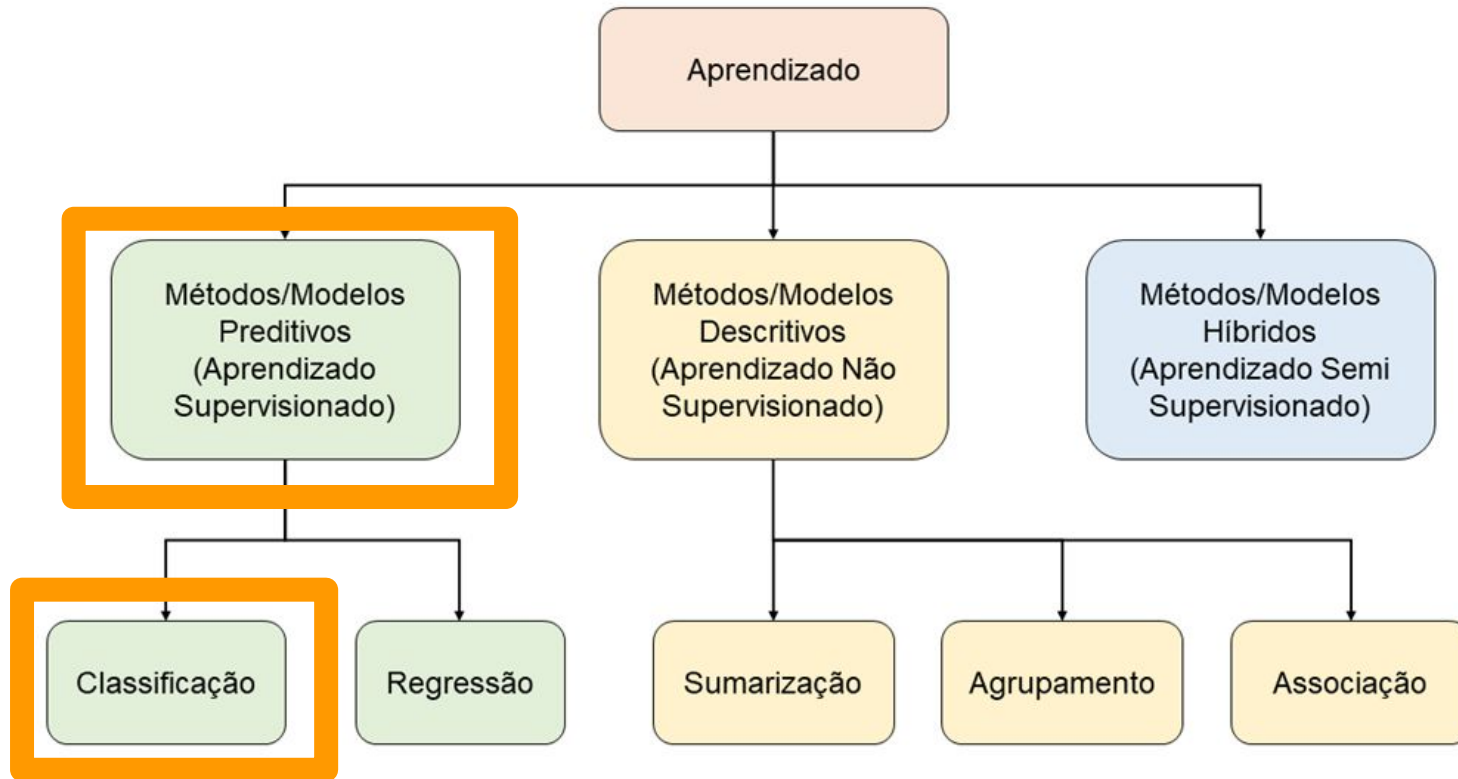
QUEM SOU EU?

- Bacharel em Engenharia de Computação
- Mestre em Ciência da Computação
 - Sistemas de Recomendação
 - Sistemas Distribuídos
 - TV Digital
- Doutora em Ciência da Computação
 - Classificação Multirrótulo
 - Aprendizado de Máquina
 - Inteligência Artificial
- Cientista de Dados, Pesquisadora, Professora, Palestrante e Escritora.
- Pesquisadora Convidada na UNESP/Bauru
- Co-Fundadora e Líder da Comunidade #GarotasCPBr
- Gamer, Geek, Nerd, Otaku, Cantora e Jogadora de Vôlei nas horas vagas

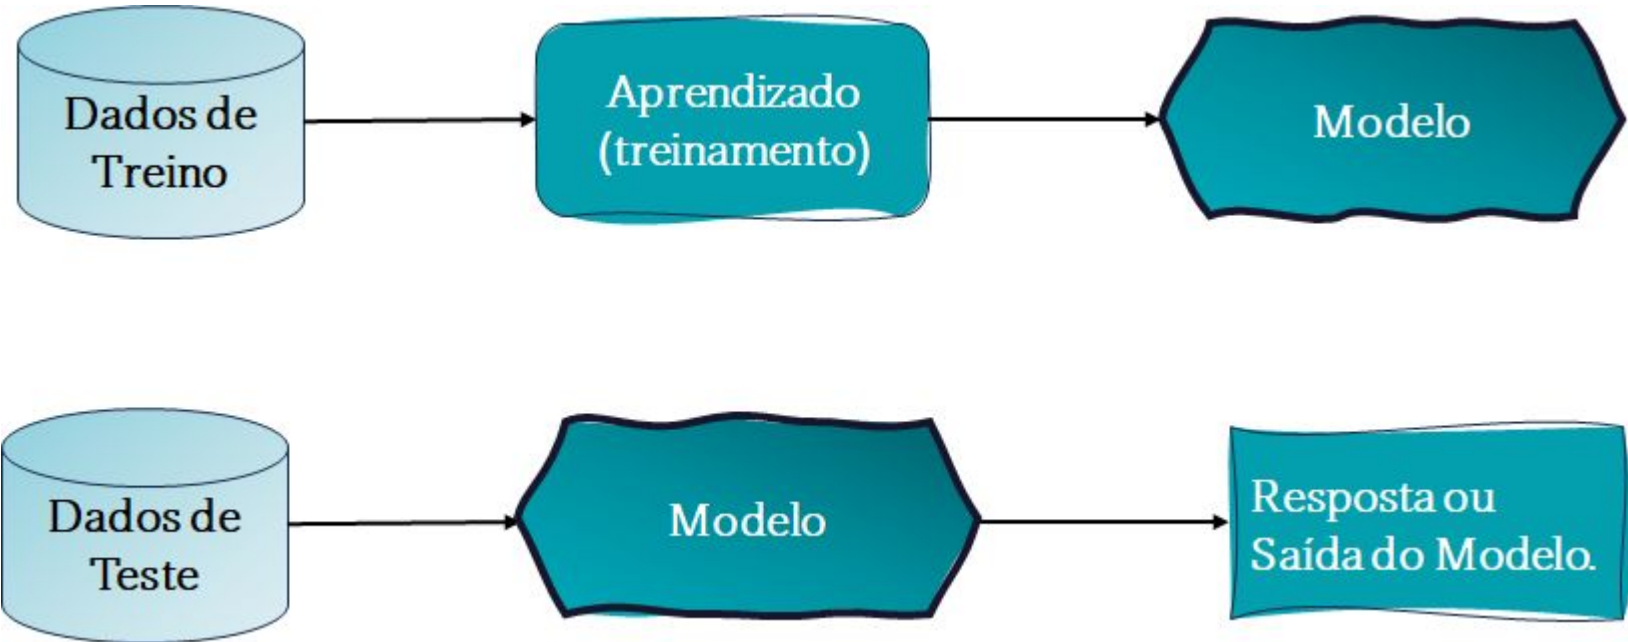
TÓPICOS

- Conceitos e fundamentos sobre a tarefa de aprendizado supervisionado chamada Classificação Multirrótulo;
- Exemplos de problemas do mundo real que podem ser resolvidos com esta tarefa;
- Desafios e tendências da Classificação Multirrótulo;
- Principais abordagens para resolução de problemas multirrótulo.

Conceitos e fundamentos da Classificação Multirrótulo




Hierarquia - Tipos de Aprendizados Clássicos



COMO FUNCIONA O APRENDIZADO?


Classificação Binária

- Número de Classes = 1
- Uma instância pertence ou não pertence ao rótulo do problema




Classificação Multiclasse

- Número de Classes > 1
- Uma instância pertence ou não pertence a um dos rótulos do problema




Classificação Multirrótulo

- Número de Classes > 1
- Uma instância pode pertencer a nenhum ou mais rótulos do problema ao mesmo tempo



Classificação Hierárquica Multirrótulo

- Número de Classes > 1
- Uma instância pode pertencer a nenhum ou mais rótulos do problema ao mesmo tempo
- Existe uma hierarquia que deve ser respeitada



TAXONOMIA DE CLASSIFICAÇÃO

Problema Binário					
Instâncias	Atributos de entrada				Atributos de Saída
	Att ₁	Att ₂	...	Att _a	Y
X ₁					0
X ₂					1
...					
X _m					1

Instâncias: um objeto que representa o problema a ser resolvido.

Atributos de Entrada: características da instância;

Atributos de Saída: alvos, rótulos, classes ou categorias.

Problema Multiclasse					
Instâncias	Atributos de entrada				Atributos de Saída
	Att ₁	Att ₂	...	Att _a	Y
X ₁					Branco
X ₂					Preto
...					
X _m					Cinza

a = número total de atributos de entrada

m = número total de instâncias (linhas)

FORMATO DOS DATASETS

Problema Multirrótulo

Instâncias	Atributos de entrada				Atributos de Saída			
	Att ₁	Att ₂	...	Att _a	Y ₁	Y ₂	...	Y _l
X ₁					0			
X ₂					1			
...								
X _m					1			

Problema Hierárquico Multirrótulo

Instâncias	Atributos de entrada				Atributos de Saída
	Att ₁	Att ₂	...	Att _a	Y
X ₁					1/2/3
X ₂					1/1/1
...					
X _m					1/3/4/1

1/3/4/1 se transforma $Y_1=1, Y_2=0, Y_3=1, Y_4=1, Y_5=1$, onde cada Y representa um nível da hierarquia.

l = número total de rótulos (l pois vem de label que é rótulo em inglês)

Espaço de rótulos = atributos de saída

FORMATO DOS DATASETS

Exemplos de problemas do mundo real que podem ser resolvidos com Classificação Multirrótulo

EXEMPLOS

1. **Sistemas de Recomendação:** qualquer e-commerce ou site que ofereça qualquer tipo de produto ou serviço;
2. **Tagging de Imagens:** Tags são rótulos, classes, categorias, que ajudam a pesquisar, organizar e buscar imagens. Uma imagem tem inúmeras tags.
3. **Classificação de Filmes, Música, Livros, Textos, Notícias, etc.:** Netflix e Spotify são bons exemplos, mas qualquer outro sistema de streaming, vídeo, áudio, etc., pode usufruir desta técnica. Filmes, músicas e livros pertencem a inúmeros gêneros diferentes. Classificar novos itens adicionados à base ajuda os sistemas de recomendação. Vale ressaltar que fazer a classificação de novos itens de forma manual é custosa, portanto, o melhor é ter um modelo treinado e predizer o gênero.
4. **Detecção de Spam em E-mails:** Os filtros de spam em serviços de e-mail muitas vezes usam classificação multirrótulo para identificar mensagens indesejadas. As mensagens podem ser rotuladas com várias categorias, como "spam", "phishing", "publicidade", etc., com base em diferentes características da mensagem.
5. **Áreas que se encaixam como problemas multirrótulo:** Diagnóstico médico, Descoberta de fármacos, Agricultura, Energia, Astronomia, Bioinformática, Finanças, Robótica, Saúde, Telecomunicações, etc.

Além de Netflix, Spotify, podemos dizer que todas as big techs, como Microsoft, Google, Amazon, utilizam de alguma técnica de classificação multirrótulo.

AVANÇOS NA PESQUISA CIENTÍFICA

MEDICINA

CAUDA LONGA:

Quando há um grande número de classes (rótulos, categorias, targets) que têm poucas instâncias de treinamento associadas a elas. Isso significa que algumas classes ocorrem com muito menos frequência do que outras.



Advanced Augmentation and Ensemble Approaches for Classifying Long-Tailed Multi-Label Chest X-Rays

Publisher: IEEE

Cite This

PDF

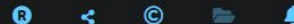


Trong-Hieu Nguyen-Mau ; Tuan-Luc Huynh ; Thanh-Danh Le ; Hai-Dang Nguyen ; Minh-Triet Tran All Authors

10

Full

Text Views



Abstract

Document Sections

1. Introduction
2. Related Work
3. Proposed Method
4. Experiments
5. Conclusion

Authors

Figures

References

Keywords

Metrics

Footnotes

Abstract:

Chest radiography is a common medical diagnostic procedure, often resulting in a long-tailed distribution of clinical findings. This challenges standard deep learning methods, which tend to favor more common classes and might miss less frequent but equally important "tail" classes. Chest X-ray diagnoses represent a multi-label problem due to the potential for multiple simultaneous diseases in patients. In this paper, we propose straightforward yet highly effective techniques to address the long-tailed imbalance in chest X-ray datasets. We specifically utilize EfficientNetV2 and ConvNeXt as our primary architectures, allowing the image sizes to influence architectural decisions. To counter dataset imbalance, we employ various basic and advanced augmentations. Mosaic augmentation is applied, and we alter the method of obtaining the label to manage this multilabel classification problem. We leverage the Binary Focal Cross-Entropy loss function and deploy several ensemble strategies to boost performance. These include Stratified K-Fold cross-validation and Test Time Augmentation. Our proposed method demonstrated its effectiveness during the Development and Testing phases of the CXR-LT: MultiLabel Long-Tailed Classification on Chest X-Rays competition. Our approach yields substantial results with an mAP of 0.354, securing a position within the top five.

Published in: 2023 IEEE/CVF International Conference on Computer Vision Workshops (ICCVW)

Date of Conference: 02-06 October 2023

DOI: 10.1109/ICCVW60793.2023.00288

Date Added to IEEE Xplore: 25 December 2023

Publisher: IEEE

▼ ISBN Information:

Electronic ISBN: 979-8-3503-0744-3

Print on Demand(PoD) ISBN: 979-8-3503-0745-0

Conference Location: Paris, France

▼ ISSN Information:

Electronic ISSN: 2473-9944

Print on Demand(PoD) ISSN: 2473-9936

▼ Funding Agency:

10.13039/501100010712-Viet Nam National University Ho Chi Minh City

AVANÇOS NA PESQUISA CIENTÍFICA

GEOCIÊNCIA

Motivados pela crescente disponibilidade de imagens de satélite de alta resolução, desenvolvemos modelos de aprendizagem profunda capazes de classificar com eficiência e precisão as condições atmosféricas e as classes dominantes de cobertura/uso da terra em imagens comerciais PlanetScope adquiridas sobre a floresta amazônica.



Deep Learning - a New Approach for Multi-Label Scene Classification in PlanetScope and Sentinel-2 Imagery

Publisher: IEEE [Cite This](#) [PDF](#)

Iurii Shendryk ; Yannik Rist ; Rob Lucas ; Peter Thorburn ; Catherine Ticehurst [All Authors](#)

17 Cites in Papers [478 Full Text Views](#)

[R](#) [Share](#) [CC](#) [Folder](#) [Bell](#)

Abstract

Document Sections

1. Introduction
2. Data
3. Methods
4. Results
5. Discussion

Show Full Outline ▾

Authors

Figures

References

Citations

Keywords

Metrics

Abstract:
Motivated by the increasing availability of high-resolution satellite imagery, we developed deep learning models able to efficiently and accurately classify the atmospheric conditions and dominant classes of land cover/land use in commercial PlanetScope imagery acquired over the Amazon rainforest. In specific, we trained deep convolutional neural network (CNN) to perform multi-label scene classification of high-resolution (<10 m) satellite imagery. We also discuss the challenges and opportunities in training deep CNN models for multi-label scene classification. Finally, we investigate the transferability of our PlanetScope-trained models to freely available Sentinel-2 imagery acquired over the wet tropics of Australia. Our best performing model achieved an F_p of 0.91, which was only 2% short of the top performing model in the Understanding the Amazon from Space Kaggle competition [1]. We also find that our models are suitable for classifying similar resolution satellite imagery, such as Sentinel-2.

Published in: [IGARSS 2018 - 2018 IEEE International Geoscience and Remote Sensing Symposium](#)

Date of Conference: 22-27 July 2018 [DOI: 10.1109/IGARSS.2018.8517499](#)

Date Added to IEEE Xplore: 04 November 2018 [Publisher: IEEE](#)

▼ ISBN Information: [Conference Location: Valencia, Spain](#)

Electronic ISBN:978-1-5386-7150-4
USB ISBN:978-1-5386-7149-8
Print on Demand(PoD) ISBN:978-1-5386-7151-1

▼ ISSN Information:

Electronic ISSN: 2153-7003
Print on Demand(PoD) ISSN: 2153-6996

AVANÇOS NA
PESQUISA
CIENTÍFICA

AGRICULTURA

A adaptabilidade das culturas num território foi abordada como um problema de aprendizagem multi-rótulo, avaliando o desempenho de diferentes modelos de classificação multi-rótulo e de classificação multi-rótulo multivisualização com dados de teste e reais.

Multi-Label Data Fusion to Support Agricultural Vulnerability Assessments

Publisher: IEEE

Cite This

PDF

Iván Darío López  ; Apolinar Figueroa  ; Juan Carlos Corrales  [All Authors](#)

2

Cites in
Papers

778

Full
Text Views



Open Access



Comment(s)

Under a Creative Commons License

Abstract

Document Sections

- I. Introduction
- II. Related Works
- III. Data Fusion Strategy
- IV. Results
- V. Conclusion

Authors

Figures

References

Abstract:

Identifying crop species and varieties adaptable to climate change impacts is one of the main aspects of climate vulnerability assessments. This estimation involves processing, integrating, and analyzing many information sources to provide accurate and timely responses. However, designing this evaluation, examine the information gathered, and reaching agreements among all stakeholders and experts, often requires considerable effort in time, money, and people. In this study, we propose a data fusion strategy to support climate vulnerability assessments by identifying the adaptability of crops in a territory in the short term. This strategy follows the Joint Directors of Laboratories' data fusion model guidelines. It was evaluated and validated through a case study in Colombia's upper Cauca river basin. For this purpose, we identified Climate, Soil, Water Quality, Productive Alliances, and Production as the most relevant data sources to be integrated, and using metrics such as Mean IR, SCUMBLE, TCS, among others, we evaluated the combined datasets according to their theoretical complexity. The adaptability of crops in a territory was addressed as a multi-label learning problem, assessing the performance of different multi-label classification and multi-view multi-label classification models with both test and actual data. Comparing the predicted crops with the actual ones, we obtained a 98% similarity without considering crop ranking using the Binary Relevance approach and the Random Forest and XGBoost algorithms. Using a more exhaustive test involving order, we obtained a maximum similarity of 67% applying Binary Relevance and Random Forest.

AVANÇOS NA PESQUISA CIENTÍFICA

Manipulações faciais
altamente realistas:
deepfakes.



Multi-Label Deepfake Classification

Publisher: [IEEE](#)

[Cite This](#)

[PDF](#)

USER
TRONICS

Inder Pal Singh ; Nesryne Mejri ; Van Dat Nguyen ; Enjie Ghorbel ; Djamila Aouada [All Authors](#)

36

Full

Text Views



Abstract

Document Sections

I. Introduction

II. Formulating Deepfake

Detection as a Multi-Label
Image Classification
Problem

III. Comparison of Multi-Label
Image Classification for
Deepfake Detection

IV. Experiments

V. Conclusion

Authors

Figures

References

Keywords

Metrics

Abstract:

In this paper, we investigate the suitability of current multi-label classification approaches for deepfake detection. With the recent advances in generative modeling, new deepfake detection methods have been proposed. Nevertheless, they mostly formulate this topic as a binary classification problem, resulting in poor explainability capabilities. Indeed, a forged image might be induced by multi-step manipulations with different properties. For a better interpretability of the results, recognizing the nature of these stacked manipulations is highly relevant. For that reason, we propose to model deepfake detection as a multi-label classification task, where each label corresponds to a specific kind of manipulation. In this context, state-of-the-art multi-label image classification methods are considered. Extensive experiments are performed to assess the practical use case of deepfake detection.

Published in: [2023 IEEE 25th International Workshop on Multimedia Signal Processing \(MMSP\)](#)

Date of Conference: 27-29 September 2023

DOI: [10.1109/MMSP59012.2023.10337658](#)

Date Added to IEEE Xplore: 08 December 2023

Publisher: IEEE

▼ ISBN Information:

Electronic ISBN: 979-8-3503-3893-5

Print on Demand(PoD) ISBN: 979-8-3503-3894-2

Conference Location: Poitiers, France

▼ ISSN Information:

Electronic ISSN: 2473-3628

Print on Demand(PoD) ISSN: 2163-3517

Desastres Naturais

Na realidade,
existem relações
entre diferentes
tipos de desastres.
E vários desastres
podem acontecer
simultaneamente.

Building A Deep Learning Model for Multi-Label Classification of Natural Disasters

Publisher: **IEEE**

[Cite This](#)

[PDF](#)

Qiang Cao ; Yan Liu ; Guangxu Wang ; Yuxin He ; Kuanglan Wang ; Shaoyi Stephen Liao ; Lixin Pu [All Authors](#)

130

Full

Text Views



Abstract

Document Sections

I. Introduction

II. Literature Review

III. Research Method

IV. Experiment Results

V. Discussion and Conclusion

Authors

Figures

References

Keywords

Abstract:

Natural disasters, such as earthquakes, hurricanes/typhoons and wildfires, usually cause severe damage. Disaster response and management is a great challenge to the authority. Current studies usually focus on a single disaster identification using social media data. In reality, there are relationships among different types of disasters. And several disasters may happen simultaneously. In this study, we explore the role of the deep learning model in multi-label disaster classification. We build a deep CNN model for multi-label classification with the instruction of a high-order strategy. We train and validate our model using a professional low-altitude disaster dataset, LADI. We find our proposed deep learning model with the transfer learning method outperforms many other machine learning models in the previous study.

Published in: [2023 IEEE 3rd International Conference on Information Technology, Big Data and Artificial Intelligence \(ICIBA\)](#)

Date of Conference: 26-28 May 2023

DOI: [10.1109/ICIBA56860.2023.10165349](#)

Date Added to IEEE Xplore: 06 July 2023

Publisher: IEEE

► ISBN Information:

Conference Location: Chongqing, China

ETC.!

Desafios e tendências da Classificação Multirrótulo

Dimensionalidade

Entrada X Saída

- Dimensão dos espaços de entrada e saída

Exemplo: um dataset com milhões de linhas e colunas.
Tudo isso é realmente importante para o modelo?

Reduzir as
dimensões

- O que é relevante para resolver o problema?
 - Técnicas de seleção de atributos
 - Técnicas de seleção de instâncias
 - Técnicas de extração de atributos
 - Amostra representativa e útil

DESAFIOS E TENDÊNCIAS

Escalabilidade

Processamento

- Recursos computacionais

Exemplo: um dataset com milhões de linhas e colunas.
Como processar tanta informação?
Dividir o problema em vários subproblemas é uma forma

DESAFIOS E TENDÊNCIAS

Desbalanceamento

Instâncias Positivas X
Instâncias Negativas

- Positiva: a instância pertence à classe do problema
- Negativa: a instância não pertence à classe do problema

Exemplo: um dataset com milhões instâncias, mas apenas algumas pertencem à classe - 20% pertence a alguma classe, enquanto 80% não. Refere-se à distribuição dos rótulos.

Na classificação
Multirrótulo é ainda
mais complexo

- Impacto no Aprendizado (overfitting e underfitting)
- Aumentar o número de instâncias artificialmente
 - Instâncias não representativas

DESAFIOS E TENDÊNCIAS

Conjunto de Dados Multirrótulo

Instâncias	Att ₁	Att ₂	Att ₃	Att ₄	Y ₁	Y ₂	Y ₃	Y ₄
X ₁					0	1	1	0
X ₂					1	0	1	0
X ₃					1	1	1	0
X ₄					1	0	1	1
X ₅					0	1	1	0
X ₆					1	0	1	1
X ₇					1	1	1	0

Combinação de Rótulos

[0110]	→	[Y ₂ , Y ₃]
[1010]		[Y ₁ , Y ₃]
[1110]		[Y ₁ , Y ₂ , Y ₂]
[1011]		[Y ₁ , Y ₃ , Y ₄]

- O número de instâncias positivas para determinados rótulos pode ser bem pequeno e o número de instâncias negativas alto;
- Alguns rótulos podem ser mais frequentes que outros (rótulos majoritários e minoritários);
- **Label Skew**: quando há um número alto de instâncias associadas a conjuntos de rótulos frequentes, e também um alto número de instâncias associadas a conjuntos de rótulos menos frequentes.

DESAFIOS E TENDÊNCIAS

Correlações entre
Rótulos

Identificar, Capturar,
Aprender e Explorar

Natural do dataset
Multirrótulo

TENDÊNCIAS


- Extreme Multi-Label Classification
- Rotulagem dos dados e Partial Multi-Label Classification
- Clustering Multi-Label Classification
- Interpretabilidade
- Ética

DESAFIOS E TENDÊNCIAS

Principais abordagens para resolução de problemas multirrótulo

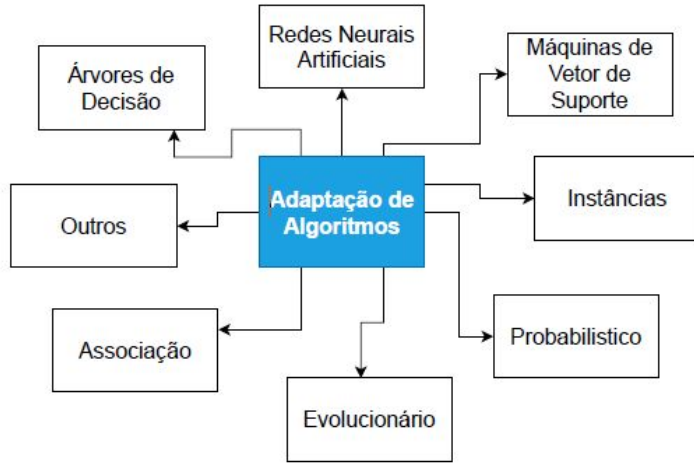
ABORDAGEM GLOBAL

- Novos modelos ou adaptação de modelos existentes;
- Aprende todos os rótulos de uma única vez;
- Não aprende corretamente as correlações;
- Indução de um único modelo (um classificador);



ALGORITMOS

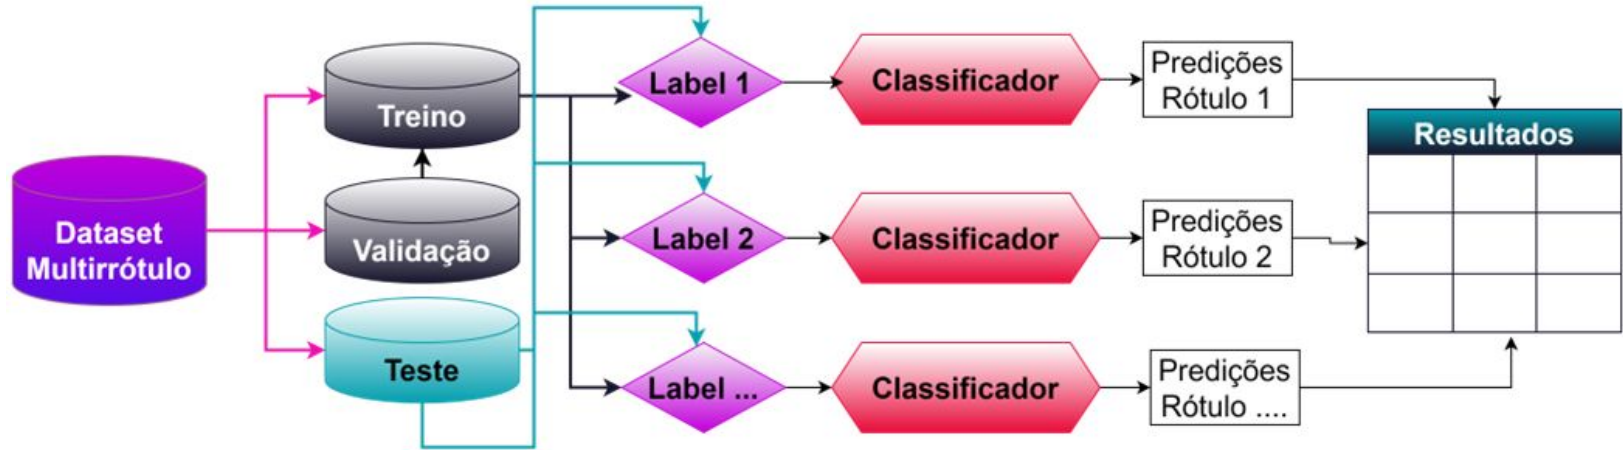
Abordagem Global



Método	Algoritmo
BP-MLL	RNAs
GACC	Evolutivo
ML-C4.5	Árvores de Decisão
ML- k NN	k NN
MMAC	Associativo
MMP	RNAs
MuLAM	Evolutivo
PCT	Árvores de Decisão
PMM	Probabilístico
Rank-SVM	SVM

ABORDAGEM LOCAL

- Divide o problema original em subproblemas;
- Aprende cada rótulo de forma individual;
- Não aprende as correlações;
- Indução de um modelo por rótulo;



ALGORITMOS Abordagem Local


Method	Name	Approach
br	Binary Relevance (BR)	one-against-all
brplus	BR+	one-against-all; stacking
cc	Classifier Chains	one-against-all; chaining
clr	Calibrated Label Ranking (CLR)	one-versus-one
dbr	Dependent Binary Relevance (DBR)	one-against-all; stacking
ebr	Ensemble of Binary Relevance (EBR)	one-against-all; ensemble
ecc	Ensemble of Classifier Chains (ECC)	one-against-all; ensemble
eps	Ensemble of Pruned Set (EPS)	powerset
homer	Hierarchy Of Multi-label classifier (HOMER)	hierarchy
lift	Learning with Label specific FeaTures (LIFT)	one-against-all
lp	Label Powerset (LP)	powerset
mbr	Meta-Binary Relevance (MBR or 2BR)	one-against-all; stacking
ns	Nested Stacking (NS)	one-against-all; chaining
ppt	Pruned Problem Transformation (PPT)	powerset
prudent	Pruned and Confident Stacking Approach (Prudent)	one-against-all; stacking
ps	Pruned Set (PS)	powerset
rakel	Random k-labelsets (RAKEL)	powerset
rdbr	Recursive Dependent Binary Relevance (RDBR)	one-against-all; stacking
rpc	Ranking by Pairwise Comparison (RPC)	one-versus-one

OUTRAS ABORDAGENS

- Combinação de classificadores
 - Homogêneos
 - Heterogêneos
- Combinação de técnicas não supervisionadas com supervisionadas e também semi-supervisionadas
 - Algoritmos de Agrupamentos
 - Grafos e Métodos de detecção de comunidades
- Aplicar técnicas de Sistemas de Recomendação para prever classes
- etc.

REFERÊNCIAS

- Capítulo 2 da Minha tese de doutorado disponível no repositório da UFSCar
<https://repositorio.ufscar.br/handle/ufscar/19284>
- Livro:
<https://www.amazon.com.br/Intelig%C3%AAncia-Artificial-Abordagem-Aprendizado-M%C3%A1quina/dp/8521637349>



Follow me on Instagram

personal content:

[@cissagatto](#)

*geek, nerd, and
otaku content:*

[@cissa.otaku](#)

gaming content:

[@cissa.gamer](#)

*music and singing
content:*

[@cissa.cantora](#)

*computer science
and engineering
content:*

[@prof.cissa](#)



LinkedIn | Research

LinkedIn Profile:

www.linkedin.com/in/elainececiliagatto

LinkedIn Company Page

www.linkedin.com/company/professoracissa

Research

www.researchgate.net/profile/Elaine-Gatto



OBRIGADO!



Patrocinado por



www.embarcados.com.br



[linkedin.com/embarcados](https://www.linkedin.com/company/embarcados)



[@portalembarcados](https://www.instagram.com/portalembarcados)



[youtube/Embarcados TV](https://www.youtube.com/EmbarcadosTV)