

# Indução de Árvore de Decisão utilizando Meta-Aprendizado

Caíque Augusto Ferreira  
caiqueaugustoferreira@alumni.usp.br  
Universidade de São Paulo  
Ribeirão Preto, São Paulo, Brasil

José Augusto Baranauskas  
augusto@usp.br  
Universidade de São Paulo  
Ribeirão Preto, São Paulo, Brasil

## Abstract

Symbolic learning models stand out within the Machine Learning area because their representations are interpretable by humans. A feature of this model is very responsive to the set of examples used, which can result in a significant change in the model if there are small variations in the training set. The model combination strategy (ensembles) is presented as an alternative to improve the accuracy and stability of the models. The strategy consists of generating different models from the same training set and combining them into a single final model, usually through a voting process. An undesirable characteristic of the set strategy is the complexity of the final model, since it is formed by a set of models. In this research, an approach is proposed to induce a decision meta-tree based on the combination of decision trees from one (Random Forest). The experiments were performed on 150 datasets from different domains. The proposed approach applied to 43 sets of categorical data out of 150 analyzed, obtained a performance as good as a forest with 128 trees without statistically significant differences. This is an important result, considering the interpretability provided by a single decision tree as the resulting model.

**Keywords:** Meta-Learning. Decision tree. Model Combination. Explainable Artificial Intelligence

## 1 Introdução

A estratégia de combinação de modelos (*ensemble*) proposta por [2], apresenta-se como uma alternativa para melhorar o desempenho dos modelos simbólicos. Esta estratégia apoia-se na ideia de que o desempenho de um conjunto de modelos considerados fracos é geralmente melhor do que um único modelo considerado forte [13]. A estratégia consiste em gerar diferentes modelos com base no mesmo conjunto de treinamento e combiná-los em um modelo final. Geralmente o processo de combinação ocorre por meio de algum mecanismo de votação, no qual o conjunto de modelos define o rótulo dos novos exemplos. Além da estabilidade, a

utilização da estratégia *ensemble* pode melhorar a precisão do modelo, de forma que o modelo resultante da combinação é geralmente mais preciso e mais estável do que um modelo individual.

Apesar dos algoritmos baseados em *ensemble* aperfeiçoarem o desempenho do modelo, para a categoria simbólica, há uma dificuldade com relação a interpretabilidade do modelo final, já que o mesmo é formado por diferentes modelos combinados. Mesmo considerando que os modelos sejam individualmente interpretáveis, quando o conjunto é muito grande, torna-se humanamente complexo o processo de interpretação do modelo resultante, até mesmo para os especialistas do domínio em questão.

Com base nisso, combinar o conjunto de modelos resultantes da estratégia *ensemble* em apenas um único modelo, poderia resgatar a interpretabilidade e também preservar, de certa forma, a precisão e a estabilidade. Neste projeto de pesquisa é proposto um novo algoritmo para combinar as árvores de decisão geradas pelo algoritmo *Random Forest* em uma única árvore de decisão usando meta-aprendizado [16].

### 1.1 Motivação

Por meio dos estudos realizados na área [1, 3, 5, 6, 9, 11, 14], caracterizam-se alguns critérios para avaliar os resultados produzidos pelo Aprendizado de Máquina. Um desses critérios, pode ser considerado um dos mais importantes, é a compreensibilidade do resultado [3]. Para certas aplicações, devido aos riscos envolvidos, tem-se a necessidade de compreender o modelo antes de tomar alguma decisão. Para tais aplicações, fazer o modelo produzir um resultado preciso não é suficiente, o modelo também precisa ser humanamente compreensível para considerá-lo útil, confiável e aceitável. Além disso, existem situações nas quais o objetivo principal é obter informações sobre o domínio e não apenas um resultado preciso. Até mesmo quando a precisão preditiva é o objetivo mais importante, a compreensibilidade é um recurso crucial, pois facilita o processo de renovação interativa do modelo.

Para aplicações não críticas como recomendações de filmes, produtos e conteúdos digitais, a não compreensão de como o modelo chegou ao resultado não oferece riscos ou impactos significativos caso o resultado obtido não seja tão bom. Porém, existem áreas, como por exemplo a medicina, na qual

In: V Concurso de Teses e Dissertações (CTD 2023), Ribeirão Preto, Brasil. Anais Estendidos do Simpósio Brasileiro de Sistemas Multimídia e Web (WebMedia). Porto Alegre: Sociedade Brasileira de Computação, 2023.

© 2023 SBC – Sociedade Brasileira de Computação.  
ISSN 2596-1683

o impacto de uma predição errada pode causar grandes prejuízos. Ainda que o modelo resultante seja utilizado somente como apoio à tomada de decisão, o fato de não conseguir compreender como se chegou àquele resultado é um fator que inviabiliza sua utilização [12]. Além disso, com a popularização da Inteligência Artificial, novas leis surgiram para controlar o seu uso, como fez a União Européia ao criar no Regulamento Geral sobre a Proteção de Dados (GDPR, do inglês *General Data Protection Regulation*); o artigo 22, que define o direito de explicação, garante que qualquer pessoa afetada pela decisão de um algoritmo tenha o direito de saber o porquê aquela decisão foi tomada [15].

A interpretabilidade e explicabilidade são conceitos relacionados à Inteligência Artificial Explicável (XAI, do inglês *Explainable Artificial Intelligence*). A XAI é um campo de pesquisa que visa tornar os modelos de IA mais compreensíveis e transparentes, proporcionando explicações claras sobre suas decisões. O objetivo final é promover uma interação mais eficaz entre humanos e máquinas inteligentes [7].

## 1.2 Objetivo

O objetivo geral deste projeto de pesquisa consiste em desenvolver um novo algoritmo para combinar as árvores de decisão geradas pelo algoritmo *Random Forest* em uma única árvore de decisão utilizando meta-aprendizado; o modelo produzido pelo algoritmo proposto é referenciado como *Meta-Tree* (MT) e representado esquematicamente pela Figura 1.

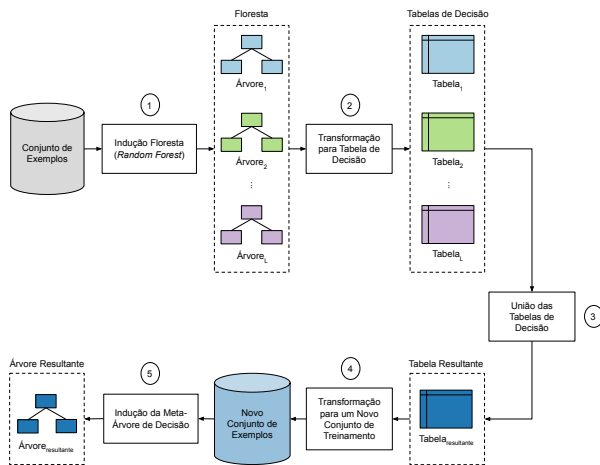


Figure 1. Processo de Indução da Meta-Árvore de Decisão.

## 2 Avaliação Experimental

### 2.1 Datasets

No total foram selecionados 150 *datasets*. Para facilitar a análise de resultados, os *datasets* foram particionados em quatro categorias: (i) 43 *datasets* que contém somente atributos categóricos; (ii) 51 *datasets* que contém somente atributos

numéricos; (iii) 56 *datasets* que contém atributos categóricos e numéricos; (iv) a união de (i), (ii) e (iii) resultando nos 150 *datasets* analisados. Nota-se que as categorias (i), (ii) e (iii) são disjuntas entre si.

### 2.2 Algoritmos e Parametrização

Para a realização dos experimentos foi utilizada a ferramenta Weka [8] e selecionados os algoritmos: J48 (DT) e *Random-Forest* (RF). O algoritmo proposto foi codificado e agregado à Weka e denominado *MetaTree* (MT). Os parâmetros utilizados foram os seguintes:

1. DT: algoritmo de indução de árvore de decisão J48 executado com seus parâmetros *defaults*;
2. MT: denotado por MT(*peso*, *discretização*) para os *datasets* das categorias (ii) e (iii) ou MT(*peso*) para os *datasets* da categoria (i), com:
  - *peso*: que indica a métrica utilizada na ponderação das linhas da tabela de decisão (*meta-dataset*). Foram utilizadas as métricas de Confiabilidade Positiva (*prel*), Laplace (*lacc*), Novidade (*nov4*) e Satisfação (*sat*), ou seja,  $peso \in \{prel, lacc, nov4, sat\}$  e
  - *discretização*, que indica a estratégia de discretização utilizada para o tratamento de atributos numéricos. Foram utilizadas as estratégias de Intervalo (*range*) e Média (*mean*) dos valores, ou seja,  $discretização \in \{mean, range\}$
3. RF: *Random Forest* utilizando 128 árvores. Este valor é proveniente de resultado de pesquisa anterior realizada por [10];

## 3 Resultados

Foram analisados recortes nas quatro categorias mencionadas na Seção 2.1. Foram utilizadas as estratégias de intervalo e média para lidar com atributos numéricos; as métricas utilizadas para o peso da folha, foram Confiabilidade Positiva, Laplace, Novidade e Satisfação. Os resultados dos testes *post-hoc* de Bonferroni-Dunn (95% de confiança) para as métricas ROC AUC e número de folhas podem ser encontrados na forma de diagramas de diferenças críticas nas Figura 2 e 3.

## 4 Discussão

### 4.1 Datasets Categóricos

Como pode ser observado na Figura 2(a), MT(*prel*) e MT(*sat*) obtiveram um desempenho inferior, porém não significativamente, em relação a *RF*. Nota-se que *DT* foi significativamente inferior à *RF*. Esse resultado é interessante, pois, o desempenho de uma única árvore induzida pelo algoritmo proposto se assemelhou ao desempenho de uma floresta de 128 árvores, o que apresenta significativa melhoria em relação à compreensibilidade do modelo final, por tratar-se de apenas uma única árvore de decisão. Na Figura 3(a), é possível observar que MT(*prel*) e MT(*sat*) induziram uma árvore de decisão maior, porém não significativamente, do que

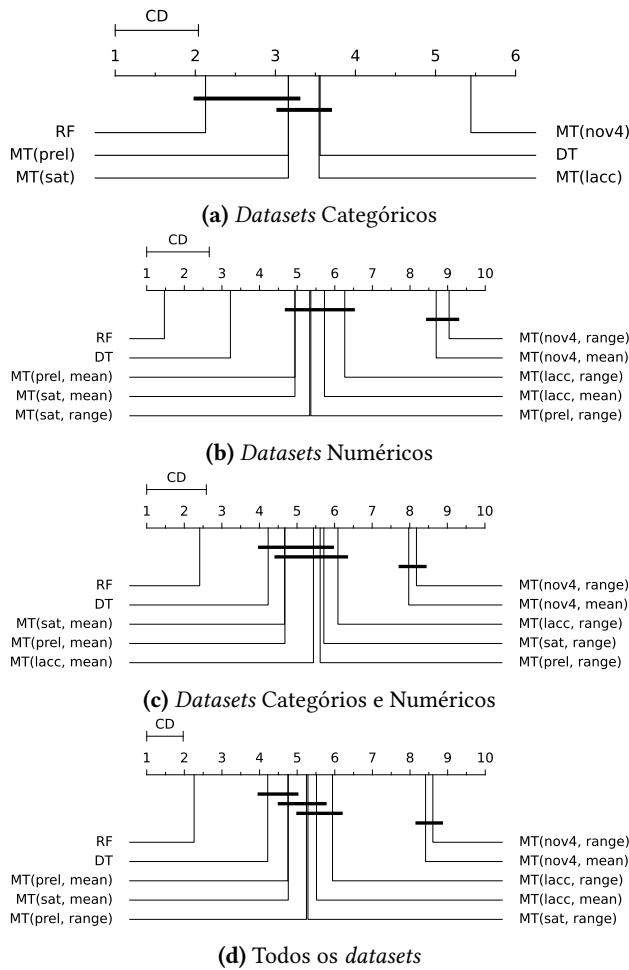


Figure 2. Diagrama de diferença crítica considerando os resultados obtidos de ROC AUC.

a *DT*. Este resultado é interessante pois a combinação das 128 árvores da floresta resultou em uma árvore de decisão não significativamente maior que uma árvore de decisão convencional, o que favorece a interpretabilidade do modelo resultante.

#### 4.2 Datasets Numéricos

Como pode ser observado na Figura 2(b), o algoritmo proposto em todas as possíveis configurações obteve um desempenho significativamente inferior a *DT* e *RF*. Nota-se que as abordagens propostas para lidar com os algoritmos numéricos (média e intervalo) não conseguiram se assemelhar ao desempenho obtido pela *DT* e *RF*. Na Figura 3(b), é possível observar que *MT(prel, mean)*, *MT(sat, mean)*, *MT(prel, range)* e *MT(sat, range)* induziram uma árvore de decisão menor, porém não significativamente, do que a *DT*. Apesar da combinação das árvores da floresta ter resultado em uma árvore de decisão menor, o desempenho obtido foi significativamente inferior.

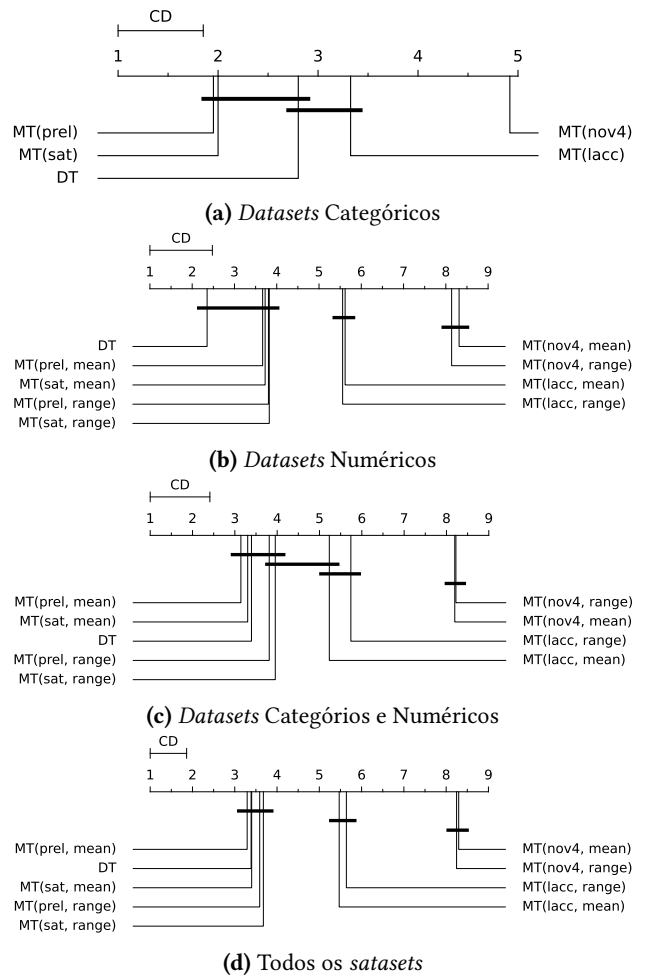


Figure 3. Diagrama de diferença crítica considerando o número de folhas da *DT* e das *MTs*.

#### 4.3 Datasets Categóricos e Numéricos

Como pode ser observado na Figura 2(c), *MT(prel, mean)*, *MT(lacc, mean)*, *MT(sat, mean)*, *MT(prel, range)*, *MT(lacc, range)* e *MT(sat, range)* obtiveram um desempenho inferior, porém não significativamente, em relação a *DT*. Nota-se que todas as configurações do algoritmo proposto e a *DT* obtiveram um desempenho significativamente inferior à *RF*. Na Figura 3(c), é possível observar que *MT(prel, mean)*, *MT(sat, mean)*, *MT(prel, range)* e *MT(sat, range)* induziram uma árvore de decisão sem diferença significativa do número de folhas em relação a *DT*.

#### 4.4 Todos os Datasets

Como pode ser observado na Figura 2(d), *MT(prel, mean)* e *MT(sat, mean)* obtiveram um desempenho inferior, porém não significativamente, em relação a *DT*. Nota-se que todas as configurações do algoritmo proposto e a *DT* obtiveram um desempenho significativamente inferior *RF*. Na Figura 3(d), é possível observar que *MT(prel, mean)*, *MT(sat, mean)*, *MT(prel, range)*

range) e  $MT(\text{sat}, \text{range})$  induziram uma árvore de decisão sem diferença significativa do número de folhas em relação a  $DT$ .

#### 4.5 Tratamento de Atributos Numéricos

Em relação as estratégias para os atributos numéricos, é possível observar que a estratégia da média obteve um desempenho melhor que a estratégia de intervalo. Porém, ambas não se mostraram como boas alternativas para lidar com os atributos numéricos. Já para datasets somente com atributos categóricos, o algoritmo proposto obteve um resultados promissores.

#### 4.6 Ponderação das Folhas

Em relação as métricas de ponderação, a confiabilidade positiva e satisfação, obtiveram um resultado melhor que as métricas de Laplace e novidade. A métrica de novidade foi a que obteve o pior desempenho, o que mostra que sua proposta de busca de conhecimento possivelmente novo não se mostrou interessante para o peso das folhas. Em relação à Satisfação, que tem uma proposta semelhante à Novidade, ela se mostrou como uma métrica eficiente, obtendo um dos melhores desempenhos em relação as outras métricas. A métrica de Laplace, também não obteve um bom desempenho interessante para a ponderação dos pesos. Já a confiabilidade positiva obteve o melhor resultado.

### 5 Principais Contribuições

As principais contribuições da dissertação encontram-se publicadas [4]. Dentre elas, foi desenvolvido um algoritmo para realizar a transformação de uma árvore de decisão para uma tabela de decisão, apoiando-se no conceito de intercambialidade entre as representações do modelo. Por meio deste conceito e considerando a ponderação dos exemplos, foi possível criar um meta-conjunto para indução da árvore de decisão final.

Para dados categóricos, o algoritmo proposto, utilizando confiabilidade positiva e satisfação, obteve desempenho que não foi significativamente diferente em relação a uma Random Forest, o que ocorreu no caso de uma única árvore de decisão quando comparada à floresta. O resultado obtido é importante pois, o desempenho de uma única meta-árvore induzida pelo algoritmo proposto se não tem diferença estatística significativa em relação ao desempenho de uma floresta contendo 128 árvores, o que representa significativa melhoria em relação à compreensibilidade do modelo final, por tratar-se de apenas uma única árvore de decisão.

O trabalho desenvolvido dá abertura para aplicações nas quais há o interesse em entender como o modelo chegou ao resultado, como também, identificar quais atributos foram determinantes para a classificação.

### References

- [1] Nadia Burkart and Marco F. Huber. 2021. A Survey on the Explainability of Supervised Machine Learning. *Journal of Artificial Intelligence Research* 70 (2021), 1–74.
- [2] T. G. Dietterich. 1997. Machine Learning Research: Four Current Directions. <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.42.5440>.
- [3] Pedro Domingos. 1997. Knowledge acquisition from examples via multiple models. In *MACHINE LEARNING-INTERNATIONAL WORKSHOP THEN CONFERENCE*. MORGAN KAUFMANN PUBLISHERS, INC., 98–106.
- [4] Caíque Augusto Ferreira, Adriano Henrique Cantão, and José Augusto Baranauskas. 2022. Decision Tree Induction Through Meta-learning. In *Artificial Intelligence Applications and Innovations*, Ilias Maglogiannis, Lazaros Iliadis, John Macintyre, and Paulo Cortez (Eds.). Springer International Publishing, Cham, 101–111. [https://doi.org/10.1007/978-3-031-08337-2\\_9](https://doi.org/10.1007/978-3-031-08337-2_9) [https://doi.org/10.1007/978-3-031-08337-2\\_9](https://doi.org/10.1007/978-3-031-08337-2_9).
- [5] Riccardo Guidotti, Anna Monreale, Fosca Giannotti, Dino Pedreschi, Salvatore Ruggieri, and Franco Turini. 2019. Factual and counterfactual explanations for black box decision making. *IEEE Intelligent Systems* 34, 6 (2019), 14–23.
- [6] Riccardo Guidotti, Anna Monreale, Salvatore Ruggieri, Franco Turini, Fosca Giannotti, and Dino Pedreschi. 2018. A survey of methods for explaining black box models. *ACM computing surveys (CSUR)* 51, 5 (2018), 1–42.
- [7] David Gunning. 2017. Explainable artificial intelligence (xai). *Defense advanced research projects agency (DARPA), nd Web 2, 2* (2017), 1.
- [8] Mark Hall, Eibe Frank, Geoffrey Holmes, Bernhard Pfahringer, Peter Reutemann, and Ian H Witten. 2009. The WEKA data mining software: an update. *ACM SIGKDD explorations newsletter* 11, 1 (2009), 10–18.
- [9] Pantelis Linardatos, Vasilis Papastefanopoulos, and Sotiris Kotsiantis. 2021. Explainable AI: A Review of Machine Learning Interpretability Methods. *Entropy* 23, 1 (2021).
- [10] T. M. Oshiro, P. S. Perez, and José Augusto Baranauskas. 2012. How Many Trees in a Random Forest?. In *Proceedings of the 8th International Conference on Machine Learning and Data Mining in Pattern Recognition, MLDM 2012, Lecture Notes in Computer Science, ISBN 978-3-642-31536-7, Vol. 7376*. Berlin, Germany, 154–168. [http://dx.doi.org/10.1007/978-3-642-31537-4\\_13](http://dx.doi.org/10.1007/978-3-642-31537-4_13).
- [11] Marco Tulio Ribeiro, Sameer Singh, and Carlos Guestrin. 2016. "Why should i trust you?" Explaining the predictions of any classifier. In *Proc. of the 22nd ACM SIGKDD Int. Conf. on knowledge discovery and data mining*. 1135–1144.
- [12] Marco Tulio Ribeiro, Sameer Singh, and Carlos Guestrin. 2016. "Why should i trust you?" Explaining the predictions of any classifier. In *Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining*. 1135–1144.
- [13] Naphaporn Sirikulviriyaya and Sukree Sinthupinyo. 2011. Integration of rules from a random forest. In *International Conference on Information and Electronics Engineering*, Vol. 6. 194–198.
- [14] Pedro Strecht, Joao Mendes-Moreira, and Carlos Soares. 2014. Merging Decision Trees: a case study in predicting student performance. In *International Conference on Advanced Data Mining and Applications*. Springer, 535–548.
- [15] COUNCIL OF EUROPEAN UNION. 2016. *Council regulation (EU) no 279/2016 - Official website of the European Union*. <https://eur-lex.europa.eu/eli/reg/2016/679/oj>
- [16] Joaquin Vanschoren. 2018. Meta-learning: A survey. *arXiv preprint arXiv:1810.03548* (2018).