

Uso de Aprendizado de Máquina para Identificar o Tipo de Afasia Progressiva Primária a partir do Desempenho no Trog-2Br

Maurício de Freitas
UNIVALI – Universidade do Vale
do Itajaí, SC, Brasil
mauriciopasetto@edu.univali.br

Vinicius Piai
UNIVALI – Universidade do
Vale do Itajaí, SC, Brasil
vinicius_piai@edu.univali.br

Paulo Souza
UNIVALI – Universidade do
Vale do Itajaí, SC, Brasil
paulosouza@edu.univali.br

Alejandro Ramirez
UNIVALI – Universidade do
Vale do Itajaí, SC, Brasil
ramirez@univali.br

Anita Fernandes
UNIVALI – Universidade do
Vale do Itajaí, SC, Brasil
anita.fernandes@univali.br

ABSTRACT

Primary Progressive Aphasia (PPA) refers to a group of clinical syndromes caused by a neurodegenerative disease and is categorized into 3 types: APP-S, APP-NF/A, and APP-L. The Grammar Reception Test, in the Brazilian version (TROG2-Br), which focuses on the detection of problems in the Portuguese-Brazilian language, was used in individuals with PPA. The objective of this work is to show the feasibility of using Machine Learning algorithms to classify APP types, based on the individual's performance in the TROG-Br test. For this, the algorithms of Decision Tree, Naive Bayes, kNN, and SVM are applied and evaluated. The results are promising and show that it is possible to classify the types of APP using the individual's performance in the TROG-Br test as predictive attributes.

KEYWORDS

Primary Progressive Aphasia, TROG2-Br, Machine Learning, kNN, Naive Bayes, SVM.

1 INTRODUÇÃO

Segundo Carthey-Goulart et.al. [1], Afasia Progressiva Primária (APP) se refere a um grupo de síndromes clínicas, causados por uma doença neurodegenerativa. O sintoma predominante da APP é um transtorno progressivo lento das habilidades de linguagens, na ausência de deficiências cognitivas, motoras ou comportamentais significativas. Existem três subtipos de APP reconhecidos:

variante semântica (APP-S), que é caracterizada por fala espontânea fluente, mas com recorrentes episódios de anomia e dificuldade de compreensão de palavras isoladas; variante agramática ou não-fluente (APP-NF/A), que se caracteriza principalmente por uma fala frequentemente interrompida, podendo apresentar apraxia de fala e agramatismo; e variante logopênica

(APP-L), que se caracteriza por dificuldade em repetir sentenças e para encontrar as palavras no momento da comunicação oral [2].

O Teste de Recepção de Gramática (TROG-2) foi proposto por Bishop [3] como uma avaliação abrangente da compreensão auditiva de sentenças. O teste tem sido amplamente usado em crianças e adultos para caracterizar e diagnosticar déficits morfossintáticos [1]. Neste estudo é utilizado uma variação da TROG-2, focado na detecção de problemas de fala na língua portuguesa-brasileira, a TROG2-Br.

2 METODOLOGIA

O objetivo deste trabalho é propor a utilização de algoritmos de aprendizado de máquina (AM) na classificação de tipos de APP a partir do desempenho do indivíduo no teste TROG-Br. São consideradas as variantes de APP mais comuns: semântica (S), agramatical/não-fluente (NF/A) e logopênica (L). Para esta avaliação foram utilizados dados referentes a 23 pessoas diagnosticadas com estas variantes de APP. Estes dados foram disponibilizados no artigo de Carthey-Goulart et.al. [1]. No conjunto de dados (Tabela. 1), para cada indivíduo são apresentados: o diagnóstico da variante de APP, representado por L, NF/A, S e MX (não classificado); a avaliação do teste TROG2-Br em seus blocos 20 blocos (de A a T), indicando o número de erros ou P para cada bloco correto (100% de acertos); o somatório do número de erros; e o somatório dos blocos corretos.

Tabela 1: Performance Individual de Pessoas Afásicas [1].

Casos	PPA	A N/P	...	T N/P	Total de Itens	Total de Blocos
1	L	P	...	3	39	3
2	L	1	...	2	42	1

...
34	S	P	...	P	79	19

Na fase de pré-processamento foram imputadas as linhas referentes a PPA Mx, ou seja, APP não identificada, por não ser alvo da classificação. Também foram substituídas as ocorrências de P por 0, indicando que não houve erros no respectivo bloco. Devido o desbalanceamento do dataset resultante, contendo um total de 23 instâncias, 5 da classe L, 6 da classe NF/A e 12 da classe S, foi aplicado o método de sobre amostragem SMOTE (do inglês, Synthetic Minority Oversampling Techenique). O SMOTE adiciona instâncias sintéticas as classes minoritárias, agrupando-as em torno das instâncias reais destas classes. Este método reduz os problemas decorrentes do desequilíbrio de classes e melhora o desempenho na classificação das classes minoritárias [4].

Os algoritmos de classificação utilizados foram Decision Tree (árvore de decisão), kNN (k vizinhos mais próximos), Naive Bayes e SVM (support vector Machine). O Decision Tree, efetua a criação de uma árvore para tomada de decisão com base nos dados de treinamento, retornando um valor de saída único (uma decisão). Os dados de treinamento são sucessivamente particionados com base em um critério de divisão pré-estabelecidos. Cada nó interno da árvore representa o teste de um dos atributos de entrada, cada ramificação os possíveis valores para estes atributos, sendo que o nó folha (ou terminal) representa a decisão no processo de inferência [5]. O kNN é um método baseado em distâncias, onde cada instância representa um ponto no espaço, sendo este definido por seus atributos preditivos. O kNN utiliza medidas de distâncias para definir K instâncias mais próximas/similares, assim definindo o rótulo de uma nova instância [6]. O Naive Bayes é um algoritmo de aprendizado baseado em probabilidade, inspirado no Teorema de Bayes. É considerado “Naive” (em português ingênuo) por admitir a independência dos atributos/variáveis, o que no teorema não ocorre. Esta cria uma matriz de probabilidades e é utilizada para classificar uma nova instância de dados [7]. O SVM é um modelo robusto de aprendizagem por otimização. Este, busca minimizar uma função de custo para encontrar um hiperplano separador em conjuntos de dados lineares e não lineares utilizando técnicas de Kernel. Trabalha com o conceito de margem para definir uma tolerância a erros de classificação, impactando na generalização do modelo [8].

As fases de pré-processamento, treinamento e teste dos modelos foram feitas utilizando a ferramenta Orange Data Mining [9].

3 RESULTADOS OBTIDOS

A Tabela 21 apresenta as métricas de desempenho dos modelos na classificação de APP. Os algoritmos Decision Tree e SVM,

apresentaram melhor performance se comparados ao Naive Bayes e kNN. Entretanto, observa-se um melhor resultado com o Decision Tree.

Tabela 2: Desempenho dos modelos.

Modelo	Acurácia	F1-Score	Precisão	Recall	AUC
Decision Tree	0.750	0.741	0.761	0.750	0.822
SVM	0.694	0.700	0.714	0.694	0.830
Naive Bayes	0.694	0.695	0.713	0.694	0.807
KNN	0.667	0.666	0.676	0.667	0.817

A Figura 1 apresenta a matriz de confusão para os algoritmos Decision Tree e SVM. Por meio deste, pode-se observar que ambos os modelos tiveram mais facilidade em classificar instâncias da classe L, classificando de forma similar instâncias da classe NF/A e S. Este baixo desempenho se dá, pela baixa quantidade de amostras para explicar o fenômeno. Entretanto, o desempenho dos algoritmos mostra que é possível prever as APP utilizando como atributos preditivos os resultados do teste TROG-Br. E que é necessário um maior conjunto de dados para que o desempenho dos algoritmos aumente.

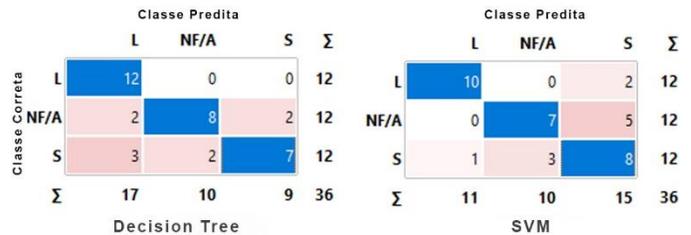


Figura 1: Matriz de confusão com o desempenho dos algoritmos Decision Tree e SVM.

Uma das vantagens da Decision Tree é que elas são facilmente interpretáveis [10]. A Figura 2 apresenta a árvore de decisão referente a classificação das classes S, NF/A e L. A partir desta árvore, regras são definidas para a classificação correta para cada classe. Para a classe S, por exemplo, considerando a Figura 2, isto acontece quando o valor do atributo Q for ≤ 1 e o valor M ≤ 0 , classificando corretamente 100% das amostras. Da mesma forma, para a classe NF/A, quando o valor de Q ≤ 1 e o valor de M > 0 , classificando corretamente 80% das amostras. Já para a classe L, quando Q for > 1 , K ≤ 2 e H > 1 , classificando corretamente 85,7% das amostras.

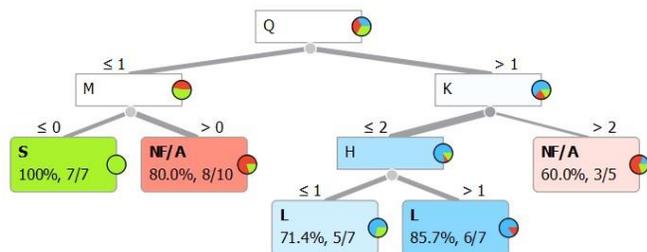


Figura 2: Árvore gerada pelo modelo Decision Tree.

4 CONSIDERAÇÕES

Este trabalho teve por objetivo classificar tipos de APP, a partir dos resultados de indivíduos diagnosticados com APP no teste TROG-Br. A base de dados utilizada foi disponibilizada no trabalho de Carthery-Goulart et al. [1]. Foram utilizados especificamente os dados referentes ao grupo de estudo, o que compreendeu observações referentes a pacientes com APP nas variações observadas. Em virtude do desbalanceamento das classes, antes do treinamento dos modelos, foi aplicada a técnica de sobre amostragem SMOTE. Foram avaliados os algoritmos Decision Tree, SVM, Naive Bayes e kNN para a classificação. O algoritmo Decision Tree, apresentou a melhor performance que os demais, com acurácia de 75% e F1-Score de 74.1%. A partir da árvore binária gerada pelo modelo Decision Tree, regras puderam ser definidas para a maior classificação correta de cada uma das classes avaliadas. Os resultados são promissores, e mostram que é possível classificar APP a partir da pontuação dos indivíduos no teste TROG-Br, entretanto se faz necessário um maior número de dados de treinamento para apresentar melhores resultados. Cabe salientar, no entanto, que o TROG deve ser combinado com outros instrumentos para avaliar a afasia e assim obter resultados mais precisos.

Como trabalhos futuros, considera-se aplicar novamente os experimentos sobre uma base de dados com um maior número de observações, quando eles estiverem disponíveis. Assim como aplicar os experimentos sobre os resultados no teste TROG no idioma inglês, onde o teste foi originalmente concebido. Entretanto, nenhuma base de dados foi encontrada, fazendo a relação entre o desempenho no TROG com os tipos de afasia. Também se considera a utilização de outros algoritmos de classificação para a análise de desempenho.

AGRADECIMENTOS

Agradecemos a FAPESC pelo fomento a este projeto através dos editais: Chamada Pública Fapesc nº 15/2021 - 2021TR001236 - Programa de Ciência, Tecnologia e Inovação de Apoio aos Grupos de Pesquisa da Associação Catarinense das Fundações Educacionais - ACAFE; Edital de Chamada Pública Fapesc nº 29/2021 - 2021TR001758 - Programa Estruturante Acadêmico de

Apoio à Infraestrutura de Laboratórios do Estado de Santa Catarina; Fapesc nº 21/2021 – Programa de Apoio aos Programas de Pós-graduação Emergentes e em Consolidação em Áreas Prioritárias nos Estados; e FAPESC (PRONEM) TO 2020 TR 729. Também agradecemos a CAPES pelo fomento através do Edital N° 58/2022/PPGIELA - Concessão De Bolsas - Programa De Desenvolvimento Da Pós-graduação Estratégico De Consolidação - Capes - Programa De Pós-graduação Interdisciplinar Em Estudos Latino-americanos.

REFERÊNCIAS

- [1] Carthery-Goulart MT, de Oliveira R, de Almeida JJ, Campanha A, da Silva Souza D, Zana Y, Caramelli P, Machado TH. *Sentence Comprehension in Primary Progressive Aphasia: A Study of the Application of the Brazilian Version of the Test for the Reception of Grammar (TROG2-Br)*. *Front Neurol*. 2022 May 16;13:815227. Doi: 10.3389/fneur.2022.815227. PMID: 35651345; PMCID: PMC9149594.
- [2] Reis, Talita Gallas dos. Afasia Progressiva Primária: um estudo das queixas iniciais e do histórico de dificuldades de aprendizagem. Dissertação (Mestrado em Ciências da Reabilitação). Universidade Federal de Ciências da Saúde de Porto Alegre, Porto Alegre, 2020.
- [3] Bishop, A. D. V. *Test for the Reception of Grammar: Version2; TROG-2*. Editora Harcourt Assessment, 2003. ISBN: 0749121319.
- [4] Srinilta, C., Kanharattanachai, S. *Application of natural neighbor-based algorithm on oversampling smote algorithms*. In 2021 7th International Conference on Engineering, Applied Sciences and Technology (ICEAST) (pp. 217-220). IEEE. Doi: 10.1109/ICEAST52143.2021.9426310.
- [5] Aggarwal, C.C. *Outlier Analysis*. Springer International Publishing, 2017. ISBN: 978-3-319-47577-6.
- [6] Faceli, K., Lorena, A.C., Gama, J., Almeida, T.A., Carvalho, A.C.P.L.F. *Inteligência artificial: uma abordagem de aprendizado de máquina*. Editora LTC, 2021. ISBN: 9788521637349.
- [7] Harrison, M. *Machine learning pocket reference: working with structured data in python*. O'Reilly Media, 2019. ISBN: 1492047546.
- [8] Géron, A. *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow*. O'Reilly Media; 2nd ed., 2022. ISBN: 1492032646.
- [9] Orange: *Data Mining Fuitful and Fun*. Disponível em: <<https://orangedatamining.com/>>. Acessado em: 12 de outubro de 2022.
- [10] Nkolele, R., Wang, H. *Explainable Machine Learning: A Manuscript on the Customer Churn in the Telecommunications Industry*. In 2021 Ethics and Explainability for Responsible Data Science (EE-RDS) (pp. 1-7). IEEE. Doi: 10.1109/EE-RDS53766.2021.9708561.