

Classifying Readers with Dyslexia from Eye Movements using Machine Learning and Wavelets

Isabella de A. Ceravolo¹, Antonio R. A. Brasil², Karin S. Komati³

¹ Programa de Pós-graduação em Ciência de Dados com Big Data

² Programa de Pós-graduação em Engenharia de Controle e Automação

³ Programa de Pós-graduação em Computação Aplicada (PPComp)

Campus Serra do Instituto Federal do Espírito Santo (Ifes)

Serra – ES – Brasil

iac.isabella@gmail.com, anribrasil@gmail.com, kkomati@ifes.edu.br

Abstract. *Dyslexia is a disorder that affects individuals' linguistic abilities. Traditional diagnosis methods are based on word decoding tests, which must be analyzed by an expert. It is an error-prone method that does not consider the reading process itself. Since dyslexics have different movements than regular readers it is possible to assess the reading process by tracking eye movements. This paper proposes a dyslexia trial method that employs wavelets and machine learning algorithms to analyze eye movements during reading. As a result, it was possible to obtain a model with an accuracy of 97.30 % with the Random Forest algorithm, standing out from the results found in the literature.*

Resumo. *Dislexia é um transtorno que dificulta a leitura e compreensão de textos. O diagnóstico é feito por um especialista através de testes orais e escritos. Isso o torna propenso a erros, por ser uma avaliação indireta do processo de leitura. A leitura pode ser avaliada diretamente através do rastreamento dos movimentos oculares durante o processo de leitura, e pessoas com dislexia possuem movimentos diferentes de pessoas sem dislexia. Esse trabalho propõe a análise destes movimentos utilizando wavelets e algoritmos de aprendizado de máquina, a fim de identificar leitores propensos a dislexia. A base de dados é pública e foi coletada de crianças entre 9 e 10 anos. Como resultado, obteve-se um modelo com acurácia de 97,30% com o algoritmo Floresta Aleatória.*

1. Introdução

Dislexia é um transtorno de aprendizado que afeta as habilidades linguísticas do indivíduo [Lyon et al. 2003]. Como consequência da dificuldade em reconhecer e associar letras e fonemas, a fluência na leitura e a compreensão de textos são prejudicadas. As causas da dislexia ainda não foram plenamente identificadas, mas sabe-se que o transtorno não está associado à habilidade cognitiva do indivíduo. Contudo, indivíduos com essa condição frequentemente sofrem com problemas acadêmicos, dificuldade de interação social e baixa autoestima. O impacto causado pela dislexia é diferente para cada pessoa, dependendo da gravidade de sua condição e da assistência que recebe, de acordo com a IDA (*International Dyslexia Association*) [IDA 2017].

De modo geral, o diagnóstico da dislexia é um processo longo e custoso, que requer o acompanhamento por parte de especialistas [Vellutino et al. 2004]. Os exames

utilizados nesse processo consistem em testes orais ou escritos, avaliando a proporção de respostas corretas, sem considerar o processo de leitura em si [Benfatto et al. 2016a]. Além disso, por serem diretamente ligadas às habilidades linguísticas, as manifestações da dislexia variam conforme o idioma. Em idiomas de ortografia “rasa”, como o italiano, há uma correspondência direta entre grafia e som, tornando a detecção das manifestações da dislexia mais difícil do que em idiomas de ortografia regular, como o inglês [Vellutino et al. 2004].

Uma solução para que o diagnóstico seja do processo de leitura em si é a avaliação direta dos movimentos oculares realizados durante a leitura. Os olhos têm um comportamento bem definido durante a leitura, alternando períodos estáveis (fixação) com movimentos rápidos para trazer novas regiões ao campo de visão (movimentos sacádicos) [Carmo 2014]. Os movimentos oculares de leitores com dislexia são diferentes dos leitores regulares. Pessoas com dislexia podem apresentar movimentações fora da área de leitura, podem não seguir cada linha do texto, podem ter tempos de leitura mais longos ou podem fazer fixações mais longas do que leitores sem dislexia [Rello and Ballesteros 2015a].

Os estudos anteriores, realizados por Benfatto et al. (2016a) e Rello and Ballesteros (2015a) demonstraram o uso bem sucedido de algoritmos de aprendizado de máquina na identificação de dislexia pelo rastreamento dos movimentos oculares durante a leitura. Técnicas de aprendizado de máquina proveem o ferramental para a análise de tais dados de forma rápida, sistemática e automatizada. Ambos os trabalhos realizam a classificação dos dados empregando exclusivamente o algoritmo de máquina de vetores de suporte, o SVM (do inglês *Support Vector Machine*).

Nesse sentido, a proposta deste trabalho é de identificar se: (i) a extração de características através de *wavelets* (técnica proveniente do domínio de processamento digital de sinais) possibilita extrair atributos relevantes dos dados brutos do rastreamento; (ii) dentre os algoritmos de classificação, aqueles que mais se adéquam ao resultado da extração de características do problema de identificação de pessoas com dislexia, analisando seus movimentos oculares. Para atingir esse objetivo, foram realizadas duas análises comparativas: uma análise da influência de diferentes *wavelets* no desempenho do classificador e outra análise quanto ao desempenho de diferentes algoritmos de classificação.

A comparação entre *wavelets* considerou 4 diferentes funções base: Biorthogonal, Reverse Biorthogonal, Coiflets e Symlets. A comparação entre classificadores considerou 9 diferentes algoritmos: SVM [Cortes and Vapnik 1995], k-NN (do inglês *k-nearest neighbors*, em português k-Vizinhos mais próximos) [Altman 1992], Floresta Aleatória [Breiman 2001], árvore de decisão, processo gaussiano (do inglês *Gaussian processes*) [Rasmussen 2003], *Multi-Layer Perceptron* (em português perceptron de múltiplas camadas), Naive-Bayes [Zhang 2004], AdaBoost [Freund et al. 1999] e análise discriminante quadrática [Baudat and Anouar 2000].

Os dados utilizados nos experimentos foram disponibilizados por Benfatto et al. [Benfatto et al. 2016b]. Foram disponibilizadas 185 instâncias de rastreamento oculares de crianças entre 9 e 10 anos de idade. Essa informação é muito importante, pois o diagnóstico da dislexia nos estágios iniciais do desenvolvimento infantil pode minimizar o impacto da dislexia.

O artigo está organizado da seguinte maneira: a Seção 2 traz uma relação de artigos publicados sobre o tema, a Seção 3 faz a apresentação dos materiais e métodos utilizados nos experimentos deste trabalho. A Seção 4 discute os experimentos realizados e seus resultados. Por fim, na Seção 5 o trabalho é concluído e os trabalhos futuros são apresentados.

2. Trabalhos Relacionados

Nesta seção, serão abordados apenas os trabalhos que utilizaram algoritmos de aprendizado de máquina em dados de movimentos oculares para identificação da dislexia.

Um dos primeiros trabalhos que lidaram com a identificação de dislexia aplicando técnicas de aprendizado de máquina a partir de movimentos oculares foi o de Rello e Ballesteros [Rello and Ballesteros 2015b], que trabalharam em um modelo estatístico para predição de leitores com ou sem dislexia usando as características extraídas de movimentos oculares. O modelo se baseia no uso de uma SVM de classificação binária, e a partir de testes realizados, os autores conseguiram obter cerca de 80,18% de acurácia. A base de dados utilizada foi composta de 97 pessoas, sendo 48 delas com dislexia (49,48% do total). Em relação às características utilizadas para treinar o classificador, os autores optaram por realizar um processamento e extraí-las a partir das fixações, como a média de fixações, número de fixações, e características quanto ao experimento, como a idade do participante e o tipo de estímulo apresentado ao participante.

Posteriormente, Rello, Ballesteros et al. [Rello et al. 2016] desenvolveram um jogo educativo com o objetivo de diagnosticar dislexia em pessoas com a idade variando entre 7 a 70 anos. Seus experimentos foram aplicados a uma base contendo 243 crianças e adultos, sendo 95 com o diagnóstico confirmado de dislexia. A partir do treinamento e da validação do modelo, os autores obtiveram uma melhor acurácia de 83%. Além disso, para treinar o classificador, o autor utilizou de 197 características extraídas durante o experimento: idade do participante, sexo do participante e 192 características acerca do desempenho cognitivo das tarefas. Para a acurácia, foi realizado um treinamento utilizando SVM polinomial.

Em Benfatto et al. [Benfatto et al. 2016a], os autores lidaram com a identificação de dislexia durante a leitura. Os autores obtiveram uma acurácia média de 95,6% com a utilização de 48 características, extraídas a partir da classificação dos movimentos oculares dos participantes, usando o algoritmo *dynamic dispersion threshold algorithm*, e em seguida, para cada tipo de movimento (fixação e sacada) os autores extraíram as características, tais como, a duração do evento e a posição média do olho durante o evento. Para o classificador, os autores optaram por utilizar o SVM e avaliaram os resultados usando K-Fold 10.

Asvestopoulou et al. [Asvestopoulou et al. 2019] propuseram o DysLexML, uma ferramenta de triagem para dislexia. A base de dados era composto por informações de movimentos oculares de 69 crianças, sendo que 32 delas com o diagnóstico de dislexia feita pela agência governamental na Grécia. A partir dos movimentos de fixação e das sacadas foram extraídas 35 características, tais como o número de fixações, média e mediana da duração das fixações, e a média e mediana das sacadas. A melhor acurácia obtida foi de 97,10% com o SVM linear e redução das características a partir o método de LASSO (*Least Absolute Shrinkage and Selection Operator*).

Já Johni Prabha e Bhargavi [Jothi Prabha and Bhargavi 2019] propuseram um modelo preditivo que utiliza métodos estatísticos para diferenciar pessoas disléxicas de pessoas não disléxicas usando os seus movimentos oculares. Os autores fizeram um pré-processamento dos dados, removendo valores nulos e brancos. Em seguida, identificam e diferenciam os movimentos de fixação e os sacádicos, utilizando modelos estatísticos. Segue-se uma etapa de seleção de características utilizando PCA (*Principal Component Analysis*). Por fim, o artigo utiliza SVM com PSO (*Particle Swarm Optimization*) para calibração dos melhores pesos do SVM. Como resultado, os autores obtiveram uma melhor acurácia de 95%.

3. Materiais e Métodos

Com base nas técnicas de processamento digital de sinais e de aprendizado de máquina que serão apresentadas nessa seção, foi desenvolvido um modelo para apoiar a identificação de dislexia. Tomando como entrada os dados de rastreamento ocular (referentes ao olho esquerdo), foi gerada uma nova base de dados. O processo de extração de características para compor a nova base iniciou-se realizando a transformação *wavelet* dos dados disponibilizados por [Benfatto et al. 2016b]. O resultado da transformação é um conjunto contendo os coeficientes de aproximação de vários níveis de decomposição. Em seguida, foram calculadas as medidas de variância, comprimento de onda, energia e entropia dos coeficientes de cada um dos níveis de decomposição. Além desses atributos, foram incluídos o atributo que indica o sexo do participante e o rótulo indicando sua classe.

A seguir será apresentada a base de dados utilizada neste trabalho, os métodos de extração de características serão discutidos e, por fim, abordaremos sucintamente os algoritmos de aprendizado de máquina para classificação.

3.1. Base de Dados

Os dados utilizados nesse trabalho são oriundos de estudos, realizados entre 1989 e 2010, no âmbito do projeto Kronoberg [Benfatto et al. 2016a]. No projeto foram selecionados dois grupos, dentre as crianças cursando a segunda série (equivalente ao atual terceiro ano do ensino fundamental no Brasil), com idades entre 8 e 9 anos. Para compor o grupo chamado **alto risco** foram selecionadas crianças que tivessem o idioma sueco como primeira língua; inteligência normal (de acordo com testes de QI); baixo desempenho em testes padronizados de leitura; e identificados, por professores, problemas persistentes em leitura. Para compor o grupo de controle, chamado **baixo risco**, foram selecionadas crianças que tivessem os seguintes critérios em comum com os participantes do grupo de alto risco: mesmo idioma como primeira língua, mesma turma na escola e o mesmo nível de habilidades não verbais, mas como diferença, que apresentassem desempenho igual ou superior à média da turma em testes de leitura.

Enquanto as crianças cursavam a terceira série (equivalente ao atual quarto ano no Brasil), foi realizado um exame oftalmológico que consistiu em posicionar a criança a 45 cm de um texto adaptado para sua faixa etária e registrar sua movimentação ocular durante a leitura. O exame concluiu que as dificuldades em leitura do grupo de alto risco não estavam ligadas à problemas oculomotores. Os registros foram então mantidos e originaram a base de dados [Benfatto et al. 2016b], que contém 185 instâncias de rastreamento ocular (97 do grupo alto risco e 88 do grupo baixo risco).

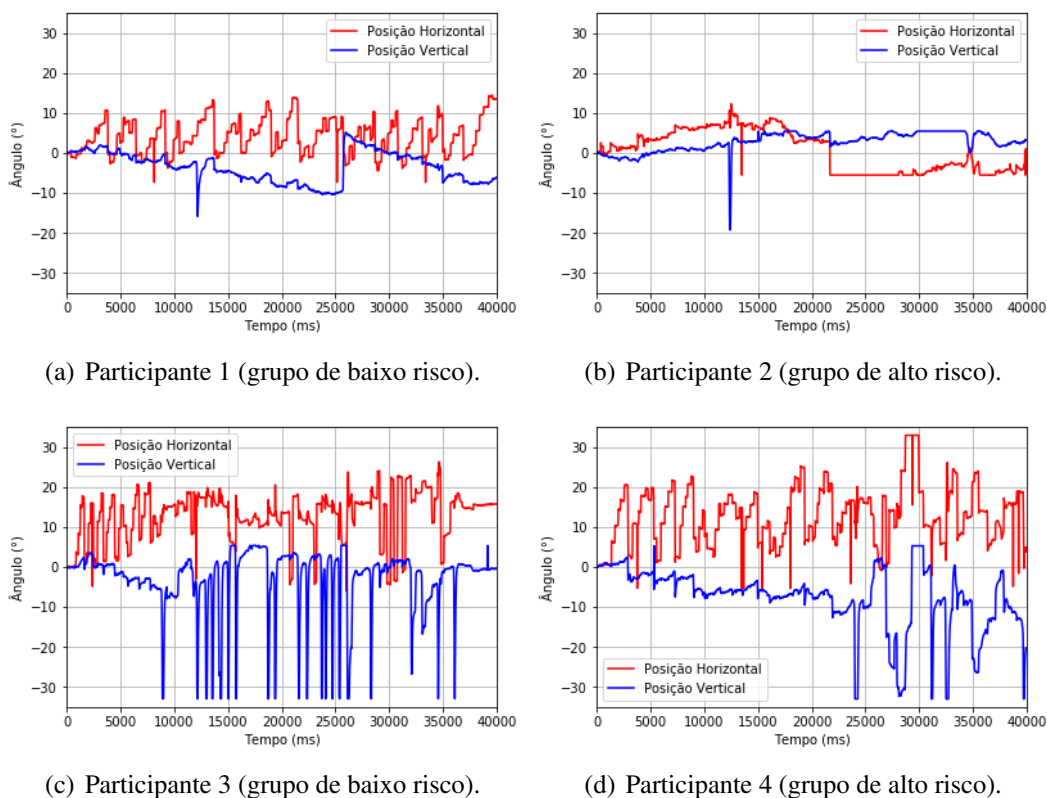


Figura 1. Representação da movimentação ocular de participantes de ambos os grupos.

Cada participante examinado teve os dados de sua movimentação ocular armazenados em um arquivo de texto, contendo as posições vertical e horizontal de ambos os olhos ao longo da leitura. A Figura 1 apresenta os dados da movimentação do olho esquerdo de participantes de ambos os grupos. A curva em vermelho são os movimentos horizontais e a curva em azul são os movimentos verticais, ambos em relação ao tempo. O eixo vertical do gráfico é o ângulo entre o eixo e a distância (horizontal ou vertical) para o ponto no qual o olho esquerdo está mirando.

Na Figura 1(a) podemos observar que o participante 1, do grupo de baixo risco, apresenta cadência no processo de leitura. Pela curva em vermelho, seu olho se movimenta para a direita, para leitura das palavras em uma linha, e retorna o início da próxima linha indo para a direita e assim sucessivamente. E progressivamente para baixo, avançando para as linhas seguintes. Na Figura 1(b) o participante 2 não aparenta seguir o fluxo do texto, algo já esperado de um leitor disléxico. Entretanto, a análise visual da movimentação ocular não é suficiente para identificar se o leitor pertence ao grupo de baixo risco ou de alto risco.

Comparando as Figuras 1(c) e 1(d), nota-se que entre os participantes 3 e 4, que pertencem a grupos diferentes, há semelhanças na representação visual da movimentação ocular. Contudo, o participante 3 (do grupo de baixo risco) não apresenta a mesma interpretação que o participante 1, apresentado na Figura 1(a), também pertencente ao grupo de baixo risco. Isso demonstra que dentro de um mesmo grupo pode não haver uniformidade. Portanto, há a necessidade de realizar um pré-processamento da base de dados para obter características que permitam identificar ambos os grupos.

3.2. Extração de Características

Conforme Salvucci and Goldberg (2000), o processo de identificação de eventos é uma parte essencial da análise de dados da movimentação ocular e que pode interferir nos resultados das análises de alto nível. Entretanto, não há uma taxonomia acerca desses eventos que seja amplamente aceita. Enquanto Rigas et al. (2018) se baseia em três tipos de eventos (fixações, sacadas e oscilações pós-sacádicas), Andersson et al. (2017) estabelece sua análise sobre um conjunto diferente de eventos (fixações, sacadas e oscilações pós-sacádicas, perseguição suave e indefinido). Isso se deve, em parte, à descrição informal dos algoritmos de identificação de eventos e à carência de comparações com os demais [Salvucci and Goldberg 2000].

Além disso, alguns desses algoritmos dependem de parâmetros definidos pelo usuário e podem classificar os dados incorretamente se forem executados sobre dados amostrados com uma frequência fora do intervalo suportado [Zemblys et al. 2018]. Desse modo, conclui-se que há um alto grau de subjetividade no processo de transformação das coordenadas em eventos.

A fim de obter atributos que caracterizem o processo de leitura de forma mais objetiva, optou-se por tratar os movimentos oculares como um sinal digital. Nesse caso, o sinal é a movimentação ocular durante a leitura, cujas posições horizontal e vertical de ambos os olhos foram amostradas com a frequência de aproximadamente 100 Hz, utilizando um sistema de reflexão corneal infravermelho baseado em óculos [Benfatto et al. 2016a]. Em processamento digital de sinais, é comum aplicar transformações matemáticas no sinal a fim de obter informações adicionais. Uma das técnicas para realizar tais transformações consiste em utilizar funções de duração limitada, chamadas *wavelets* [Bianchi 2006].

A transformada *wavelet* possibilita obter uma representação aproximada do sinal que relaciona frequência com tempo, sendo recomendada para a análise de sinais não estacionários (como é o caso da movimentação ocular). Os atributos são os coeficientes que servem como uma medida de semelhança entre o sinal e a função *wavelet*. Na variante da transformação *wavelet* direcionada para sinais discretos, o processo de transformação ou decomposição, baseia-se em separar as porções do sinal cuja frequência se encontra dentro de um intervalo pré-definido. São efetuadas sucessivas filtrações, até atingir o nível desejado. Como resultado têm-se diferentes versões do mesmo sinal, separadas por faixa de frequência [Polikar 1996].

A função *wavelet* mãe produz, através de escalonamentos, as famílias de funções base. Dentro de cada família de *wavelets*, as subclasses de *wavelets* são distinguidas pelo número de coeficientes e pelo nível de decomposição. As diferentes famílias de *wavelets* fazem diferentes trocas entre quão compactamente as funções de base são localizadas no espaço e quão suaves elas são [Graps 1995]. Para selecionar, dentre essas famílias, as funções base que participariam da comparação, foram considerados os seguintes critérios:

- Seleção de ondas diferentes entre si. Algumas funções base são similares, apesar de pertencerem a famílias diferentes. Isso ocorre, por exemplo, entre a *wavelet* Haar e a *wavelet* Daubechies.
- Seleção de funções base que suportam a mesma quantidade de níveis de decomposição sem que ocorra o efeito de borda, tendo em vista que essa quantidade depende do tamanho do sinal a ser transformado.

Com base nos critérios mencionados, foram escolhidas as funções base Biorthogonal, Reverse Biorthogonal, Coiflets e Symlets. Nascimento et al. (2016) propõem o uso de *wavelets* para obtenção de características para reconhecimento de emoções na fala. A partir da transformação *wavelet*, são calculadas quatro métricas para cada um dos níveis de coeficientes: variância, energia, comprimento de onda e entropia. Essa técnica, aplicada aos dados de movimentação ocular, permite gerar uma nova base de dados com dimensionalidade reduzida.

3.3. Classificadores

Os modelos preditivos podem ser baseados em distância, probabilístico, otimização e procura [Lorena et al. 2000].

Baseado em distância, k-NN efetua a classificação a partir de uma votação por maioria simples dos vizinhos mais próximos de cada ponto. Classificar um ponto, utilizando o k-NN, pode ser resumido em três passos, segundo Neto et al. [Neto et al. 2017], que são (i) O cálculo da distância entre o exemplo que não é conhecido, com os demais exemplos do conjunto de treinamento, (ii) a identificação dos K vizinhos mais próximos e (iii) a utilização do rótulo da classe de vizinhos mais próximos para determinar o rótulo do exemplo desconhecido, usando um sistema de votação.

Baseado em otimização, SVM constrói hiperplanos para separar diferentes classes no espaço. Esse algoritmo tem como vantagem ser eficaz em dados com muitas dimensões, mesmo que haja um número de instâncias menor do que o total de dimensões [Lima et al. 2017]. Nesse último caso, é possível evitar o sobreajuste aos dados de treinamento, escolhendo diferentes funções de decisão (*kernel*). As mais comuns são linear, polinomial, *Radial Basis Function* (RBF) e sigmóide. Já o MLP, que também é baseado em otimização, é um método que simula um neurônio biológico por meio de um modelo formal, baseado na fisiologia do neurônio [Brandão et al. 2017].

Baseada em procura, a árvore de decisão classifica os dados com base em regras inferidas a partir de seus atributos, tendo como vantagem facilitar o entendimento do modelo, bem como dos atributos mais relevantes. De modo geral, no método de árvore de decisão, o problema é representado como uma árvore, onde cada nó de entrada é analisado e dividido [Lima et al. 2017].

Baseado em uma teoria probabilística, o Naive-Bayes, trabalha com a ideia de independência de atributos. Sendo considerado como ingênuo (*naive* em inglês), desconsidera a associação entre os atributos e os analisa como condicionalmente independentes. Naive-Bayes oferece bons resultados quando se tem disponível um conjunto de treinamento médio ou grande [Brandão et al. 2017]. Já o Processo Gaussiano é um método que utiliza distribuições de probabilidade para estimar a classe de um ponto através de inferência Bayesiana [Rasmussen 2003]. Também baseado em teoria probabilística, a Análise Discriminante Quadrática modela a probabilidade de cada classe como uma distribuição gaussiana e então usa a distribuição para estimar a classe para um determinado ponto de teste [Srivastava et al. 2007].

Os métodos *ensemble* são métodos que realizam previsões baseado em uma análise de modelos combinados de forma paralela e/ou em série. Métodos *ensemble* tendem a apresentar um menor *overfitting*. A Floresta Aleatória constrói diversas árvores em paralelo, que foram construídas com partes diferentes da base de trei-

namento, que posteriormente se combinam para obter uma única resposta como saída [Alvarenga and Lemos 2017, Rodrigues et al. 2018]. O Adaboost combina classificadores em série e é um método que aprende pelos erros, ajustando os pesos dos dados classificados erroneamente [Brandão et al. 2017].

A base de dados foi separada em 80% para treinamento e 20% para teste, tal como realizado por Johni Prabha e Bhargavi [Jothi Prabha and Bhargavi 2019], tomando o cuidado de fornecer o mesmo conjunto de treinamento e de teste para todos os classificadores. Não foi realizada validação cruzada dos resultados. Para avaliar os resultados, foram considerados duas métricas de avaliação: a acurácia, que é a proporção de predições corretas [Leal et al. 2017], e que mede a capacidade que o classificador tem de não rotular como positiva uma instância que seja negativa, e a medida F1, que é uma média harmônica entre a precisão e revocação de um determinado classificador, onde seus valores variam entre 0, sendo o pior desempenho, e 1 o melhor desempenho [Cardoso et al. 2017].

4. Resultados e Discussões

Nesta seção, serão apresentados os resultados dos dois experimentos realizados. Primeiro, será investigada a influência da *wavelet* no resultado da classificação. Após avaliar os resultados obtidos na comparação entre *wavelets* e níveis de decomposição, escolheu-se a configuração de melhor resultado. Como segundo experimento, foi realizada a comparação entre diferentes algoritmos de classificação.

4.1. Comparação entre *Wavelets*

O uso da transformação *wavelet* tem a finalidade de extrair características dos dados de rastreamento ocular de modo mais objetivo que algoritmos de detecção de eventos. No entanto, sabendo que há diferentes famílias *wavelet*, é pertinente a análise do impacto da escolha da família no desempenho da classificação. Além disso, a quantidade de níveis de decomposição utilizados na transformação influencia diretamente no total de características geradas, o que também pode ter impacto no desempenho da classificação.

Foi utilizada a biblioteca `pywavelets`¹ para o desenvolvimento da extração de características. As 4 famílias de *wavelets* discretas receberam os seguintes apelidos nos experimentos: *Symlets* (`sym`); *Coiflets* (`coif`); *Biorthogonal* (`bior`) e; *Reverse biorthogonal* (`rbio`). Todas as funções suportam até 8 níveis de decomposição, mas, para fins de comparação, a decomposição do sinal foi realizada com 2, 4, 6 e 8 níveis. Desse modo, foram criados 16 experimentos (cada um referente à uma combinação *wavelet* x nível). Para efetuar a classificação, foi utilizado o algoritmo SVM, também empregado em [Rello and Ballesteros 2015a] e [Benfatto et al. 2016a]. Os resultados da classificação para cada experimento são apresentados na Tabela 1.

Foram usadas duas formas de análise para a seleção da melhor configuração de família/nível. A primeira foi uma escolha direta pelos valores mais altos, e no caso, foi para `bior1.3/4` níveis. A segunda foi considerando as médias das métricas para cada família, e a `sym3` se destaca tanto na acurácia como na medida F1. Para a comparação de desempenho entre os níveis, também foram calculadas as médias das métricas, no qual os níveis 4 e 6 produziram bons resultados. Considerando apenas a família `sym3`, nota-se que 6 níveis produzem melhores resultados.

¹<https://pywavelets.readthedocs.io>

Tabela 1. Medidas de desempenho do classificador SVM utilizando diferentes *wavelets* e níveis de decomposição.

Wavelet	2 níveis		4 níveis		6 níveis		8 níveis	
	Acurácia	F1	Acurácia	F1	Acurácia	F1	Acurácia	F1
bior1.3	0,784	0,810	0,946	0,955	0,865	0,878	0,757	0,780
coif1	0,784	0,800	0,865	0,872	0,865	0,865	0,811	0,811
sym3	0,838	0,842	0,811	0,829	0,892	0,900	0,865	0,878
rbio1.3	0,811	0,780	0,865	0,884	0,838	0,850	0,730	0,762

4.2. Comparação entre Classificadores

A partir do primeiro experimento, utilizou-se duas formas de extração de características: (i) a base de dados gerada pela *wavelet* *sym3* com 6 níveis, possuindo 57 atributos; e (ii) a base gerada pela *bior1.3* com 4 níveis, possuindo 41 atributos.

Foram utilizados somente algoritmos de aprendizado supervisionado, todos fornecidos pela biblioteca *scikit-learn*: k-NN, com k=2; SVM linear; SVM RBF; Processo Gaussiano; Árvore de Decisão; Floresta Aleatória, com 10 estimadores; *Multi-layer Perceptron* (MLP); AdaBoost; Naive-Bayes gaussiano; e Análise Discriminante Quadrática (ADQ). O desempenho de cada um dos algoritmos utilizando a base gerada por *bior1.3* e a base gerada por *sym3* é apresentado nas Tabelas 2(a) e 2(b).

Utilizando *bior1.3*, os melhores resultados, tanto em termos de acurácia como medida F1, são gerados pelos algoritmos Floresta Aleatória, Árvore de Decisão e SVM linear. Utilizando *sym3*, os melhores resultados são gerados pelos algoritmos Floresta Aleatória, MLP e Árvore de Decisão. Considerando a acurácia, o melhor resultado é gerado pela combinação da base de dados gerada por *sym3* com o algoritmo Floresta Aleatória. Considerando a medida F1, o melhor resultado é gerado pelo algoritmo Floresta Aleatória, para ambas as configurações de família/nível.

Tabela 2. Medidas de desempenho de diferentes classificadores.

(a) Acurácia			(b) Medida F1		
Classificador	bior1.3	sym3	Classificador	bior1.3	sym3
k-NN	0,702	0,838	k-NN	0,756	0,875
SVM (linear)	0,945	0,892	SVM (linear)	0,955	0,900
SVM (RBF)	0,567	0,568	SVM (RBF)	0,724	0,724
Processo gaussiano	0,567	0,568	Processo gaussiano	0,724	0,724
Árvore de decisão	0,972	0,919	Árvore de decisão	0,976	0,930
Floresta aleatória	0,972	0,973	Floresta aleatória	0,977	0,977
MLP	0,540	0,946	MLP	0,622	0,955
AdaBoost	0,810	0,892	AdaBoost	0,821	0,905
Naive-Bayes	0,729	0,784	Naive Bayes	0,792	0,826
ADQ	0,918	0,730	ADQ	0,923	0,706

Tabela 3. Comparação com os trabalhos anteriores.

Trabalho	Classificador	Acurácia	Base de Dados
Este trabalho	Floresta aleatória	97,30%	[Benfatto et al. 2016a]
Asvestopoulou et al. [Asvestopoulou et al. 2019]	SVM	97,10%	[Smyrnakis et al. 2017]
Benfatto et al. [Benfatto et al. 2016a]	SVM	95,60%	[Benfatto et al. 2016a]
Johni Prabha e Bhargavi [Jothi Prabha and Bhargavi 2019]	SVM	95,00%	[Benfatto et al. 2016a]
Rello e Ballesteros [Rello and Ballesteros 2015b]	SVM	80,18%	[Rello and Ballesteros 2015b]
Rello, Ballesteros et al. [Rello et al. 2016]	SVM	83,00%	[Rello et al. 2016]

Na Tabela 3 é possível visualizar uma comparação com os resultados obtidos neste

trabalho, considerando a melhor acurácia da Floresta Aleatória, com os resultados obtidos pelos trabalhos anteriores. O resultado desse trabalho foi um pouco superior com o melhor resultado obtido por Asvestopoulou et al. (2019). A coluna “Base de dados” indica a base de dados que foi utilizada nos trabalhos. Comparando com os resultados obtidos dos trabalhos que utilizaram a mesma base de dados, é possível verificar que a acurácia deste trabalho foi superior aos obtidos por Benfatto et al. (2016a) (95,6%) e Johni Prabha e Bhargavi (2019) (95%).

5. Conclusão

Foi demonstrado nesse trabalho que *wavelets* possibilitam processar dados de movimentação ocular extraíndo atributos relevantes para a classificação de forma objetiva. De modo geral, as famílias *wavelets* utilizadas proporcionaram bons resultados, sendo o melhor desempenho obtido com Symlets com 6 níveis de decomposição.

Os experimentos também permitiram identificar que o algoritmo floresta aleatória pode entregar resultados superiores ao SVM na classificação dos dados de movimentação ocular durante a leitura. Além disso, algoritmos como *multi-layer* perceptron e árvore de decisão também apresentaram desempenho bastante competitivo. Esses resultados reforçam a tese de que técnicas de aprendizado de máquina podem contribuir substancialmente no processo de diagnóstico de dislexia. Embora não substitua o parecer dado por um especialista, o modelo para detecção de dislexia possibilita um processo de triagem mais rápido, sistemático e automatizado.

Como trabalhos futuros, pretende-se: (i) refazer as análises comparativas incluindo técnicas de validação cruzada, como K-Fold, para dar maior robustez aos resultados; (ii) investigar quais medidas utilizadas na extração de características (variância, energia, comprimento de onda e entropia) têm maior impacto na classificação, a fim de remover atributos irrelevantes ou redundantes no modelo; (iii) estender o modelo para lidar com leitores de outras faixas etárias e de outras línguas. Embora o método de extração de características não se baseie em elementos linguísticos, pretende-se testar a efetividade do modelo com o idioma português; e, por fim, (iv) estudar a aplicabilidade do modelo desenvolvido para detecção de outros tipos de distúrbios, como depressão, bipolaridade, déficit de atenção e esquizofrenia.

Referências

- Altman, N. S. (1992). An introduction to kernel and nearest-neighbor nonparametric regression. *The American Statistician*, 46(3):175–185.
- Alvarenga, W. J. and Lemos, A. P. (2017). Metodos de otimização hiperparamétrica: uma análise comparativa na abordagem de problemas de classificação binária utilizando floresta aleatória. *XIV Encontro Nacional de Inteligência Artificial e Computacional*, pages 367–378.
- Andersson, R., Larsson, L., Holmqvist, K., Stridh, M., and Nyström, M. (2017). One algorithm to rule them all? an evaluation and discussion of ten eye movement event-detection algorithms. *Behavior research methods*, 49(2):616–637.
- Asvestopoulou, T., Manousaki, V., Psistakis, A., Smyrnakis, I., Andreadakis, V., Aslanides, I. M., and Papadopouli, M. (2019). Dyslexml: Screening tool for dyslexia using machine learning. *arXiv preprint arXiv:1903.06274*.

- Baudat, G. and Anouar, F. (2000). Generalized discriminant analysis using a kernel approach. *Neural computation*, 12(10):2385–2404.
- Benfatto, M. N. et al. (2016a). Screening for dyslexia using eye tracking during reading. *PLoS ONE*, 11(12).
- Benfatto, M. N., Seimyr, G. O., Ygge, J., Pansell, T., Rydberg, A., and Jacobson, C. (2016b). Screening for dyslexia using eye tracking during reading.
- Bianchi, M. F. (2006). *Extração de características de imagens de faces humanas através de wavelets, PCA e IMPCA*. PhD thesis, Universidade de São Paulo.
- Brandão, J. O. S., Silva, A. J., Gouveia, R. M. M., and Soares, R. G. F. (2017). Aprendizado de máquina para predição de desempenho de estudantes de graduação na ufpe. *XIV Encontro Nacional de Inteligência Artificial e Computacional*, pages 204–216.
- Breiman, L. (2001). Random forests. *Machine learning*, 45(1):5–32.
- Cardoso, E. F., Almeida, T. A., and Silva, R. M. (2017). Detecção automática de opiniões falsas com base no conteúdo das mensagens. *XIV Encontro Nacional de Inteligência Artificial e Computacional*, pages 1–12.
- Carmo, M. P. (2014). Leitura e movimentos oculares. http://www.pucsp.br/linguagemesubjetividade/coluna_fonoaudiologia_em_questao/2014/dezembro.html. Acesso em: 20-06-2018.
- Cortes, C. and Vapnik, V. (1995). Support vector machine. *Machine learning*, 20(3):273–297.
- Freund, Y., Schapire, R., and Abe, N. (1999). A short introduction to boosting. *Journal-Japanese Society For Artificial Intelligence*, 14(771-780):1612.
- Graps, A. (1995). An introduction to wavelets. *IEEE computational science and engineering*, 2(2):50–61.
- IDA, International Dyslexia Association. (2017). Dyslexia basics. <https://dyslexiaida.org/dyslexia-basics/>. Acesso em: 20-06-2018.
- Jothi Prabha, A. and Bhargavi, R. (2019). Prediction of dyslexia from eye movements using machine learning. *IETE Journal of Research*, pages 1–10.
- Leal, I. d. H., Aires, K. R. T., and Veras, R. d. M. S. (2017). Diagnóstico de benignidade e malignidade em imagens mamográficas utilizando aprendizado profundo para extração das regiões de interesse e Índices de diversidade filogenéticas para classificação. *XIV Encontro Nacional de Inteligência Artificial e Computacional*, pages 1–12.
- Lima, A. A., Pinto, C. R., Moreira, L. H., Ralha, G. C., and Ishikawa, E. (2017). Applying machine learning to develop an automatic incident classifier: A massive event case. *XIV Encontro Nacional de Inteligência Artificial e Computacional*, pages 60–72.
- Lorena, A. C., Gama, J., and Faceli, K. (2000). *Inteligência Artificial*. LTC, Rio de Janeiro.
- Lyon, G. R., Shaywitz, S. E., and Shaywitz, B. A. (2003). A definition of dyslexia. *Annals of dyslexia*, 53(1):1–14.

- Nascimento, Costa, R., et al. (2016). Um estudo comparativo de características da fala baseadas em wavelets para reconhecimento de emoção. In *XXI Congresso Brasileiro de Automática (CBA 2016)*.
- Neto, W. B. d. R., Jr., J. M. P. d. M., and Souza, R. V. L. (2017). Análise de dados obtidos através de um sistema de telemetria automotivo utilizando k-nn. *XIV Encontro Nacional de Inteligência Artificial e Computacional*, pages 960–971.
- Polikar, R. (1996). The wavelet tutorial. <http://web.iitd.ac.in/~sumeet/WaveletTutorial.pdf>. Acesso em: 24-07-2019.
- Rasmussen, C. E. (2003). Gaussian processes in machine learning. In *Summer School on Machine Learning*, pages 63–71. Springer.
- Rello, L. and Ballesteros, M. (2015a). Detecting readers with dyslexia using machine learning with eye tracking measures. In *Proceedings of the 12th Web for All Conference, W4A '15*, pages 16:1–16:8, New York, NY, USA. ACM.
- Rello, L. and Ballesteros, M. (2015b). Detecting readers with dyslexia using machine learning with eye tracking measures. In *Proceedings of the 12th Web for All Conference*, page 16. ACM.
- Rello, L., Ballesteros, M., Ali, A., Serra, M., Sánchez, D. A., and Bigham, J. P. (2016). Dyetective: Diagnosing risk of dyslexia with a game. In *Proceedings of the 10th EAI International Conference on Pervasive Computing Technologies for Healthcare*, pages 89–96. ICST (Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering).
- Rigas, I., Friedman, L., and Komogortsev, O. (2018). Study of an extensive set of eye movement features: Extraction methods and statistical analysis. *Journal of Eye Movement Research*, 11(1):3.
- Rodrigues, D. S. et al. (2018). A comparative analysis of loan requests classification algorithms in a peer-to-peer lending platform. In *Proceedings of the XIV Brazilian Symposium on Information Systems*, page 42. ACM.
- Salvucci, D. D. and Goldberg, J. H. (2000). Identifying fixations and saccades in eye-tracking protocols. In *Proceedings of the 2000 symposium on Eye tracking research & applications*, pages 71–78. ACM.
- Smyrnakis, I., Andreadakis, V., Selimis, V., Kalaitzakis, M., Bachourou, T., Kaloutsakis, G., Kymionis, G. D., Smirnakis, S., and Aslanides, I. M. (2017). Radar: A novel fast-screening method for reading difficulties with special focus on dyslexia. *PloS one*, 12(8):e0182597.
- Srivastava, S., Gupta, M. R., and Frigyik, B. A. (2007). Bayesian quadratic discriminant analysis. *Journal of Machine Learning Research*, 8(Jun):1277–1305.
- Vellutino, F. R. et al. (2004). Specific reading disability (dyslexia): What have we learned in the past four decades? *Journal of child psychology and psychiatry*, 45(1):2–40.
- Zembyls, R., Niehorster, D. C., Komogortsev, O., and Holmqvist, K. (2018). Using machine learning to detect events in eye-tracking data. *Behavior research methods*, 50(1):160–181.
- Zhang, H. (2004). The optimality of Naive Bayes. *AA*, 1(2):3.