

Diagnóstico de falhas em máquinas elétricas rotativas utilizando técnicas de *ensemble learning*

Joaquim O. F. Moura Filho * Marcelo E. da Silva **
Joan K. C. Parente ** Márcio A. B. Amora * Vandilberto P. Pinto ***

* Programa de Pós-Graduação em Engenharia Elétrica e Computação (PPGEEC), Campus Sobral, Universidade Federal do Ceará, CE, (e-mail: joaquim1905@alu.ufc.br, marcio@sobral.ufc.br)

** Engenharia Elétrica, Campus Sobral, Universidade Federal do Ceará, CE, (e-mail: marcelo.estevao@alu.ufc.br, joank13@alu.ufc.br)

*** Instituto de Engenharias e Desenvolvimento Sustentável, Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB), Redenção, CE, (e-mail: vandilberto@unilab.edu.br)

Abstract: This article analyzes the problem of classifying faults in rotating electrical machines. For this, a comparison between Random Forest (RF) and Gradient Boosting (GB) ensemble learning techniques was performed in order to analyze the performance of these algorithms. The database used is composed of eight mechanical variables related to motor operation under failure and non-failure conditions. The feature extraction technique employed was Root Mean Square (RMS). Therefore, the simulations performed of the algorithms resulted in high success rates, with Gradient Boosting obtaining the best performance, with an accuracy higher than 99%, which reinforces the great applicability of these algorithms in problems of this nature.

Resumo: Este artigo analisa o problema da classificação de falhas em máquinas elétricas rotativas. Para isso, uma comparação entre técnicas de ensemble learning Random Forest (RF) e Gradient Boosting (GB) foi realizada a fim de analisar a performance desses algoritmos. O banco de dados utilizado é composto por oito variáveis mecânicas relacionadas ao funcionamento do motor sob as condições de falha e não falha. A técnica de extração de características empregada foi Root Mean Square (RMS). As simulações realizadas dos algoritmos resultaram em altas taxas de acerto, com o Gradient Boosting obtendo a melhor performance, com uma acurácia superior a 99%, que reforça a grande aplicabilidade desses algoritmos em problemas desta natureza.

Keywords: Fault Diagnosis; Feature Extraction; Machine Learning; Pattern Classification; Rotating Electrical Machines.

Palavras-chaves: Diagnóstico de Falhas; Extração de Características; Machine Learning; Classificação de Padrões; Máquinas Elétricas Rotativas.

1. INTRODUÇÃO

A indústria passou por muitas mudanças desde o seu início. Atualmente está passando por uma quarta revolução, na qual novas tecnologias de integração e automação são introduzidas. O aumento da competitividade entre as grandes empresas deu início à busca por uma instrumentação cada vez mais inteligente que elimine a necessidade de interferência humana nos processos (Hand, 2015).

Um dos setores industriais que está passando por esta alteração é o de manutenção. Antes ela era feita por um processo reativo, no qual, quando o equipamento apresentasse algum defeito deveria ser trocado. O tempo perdido na troca e a utilização do equipamento com alguma falha, gerava perdas econômicas e ambientais para a empresa (Hand, 2015; Moura Filho, 2021). A adoção de novas medidas para se realizar a manutenção acabou se tornando necessária para a resolução destes problemas. Desta forma

este setor passou a empregar medidas preditivas e gradativamente se torna mais automatizada e conectada com outras atividades da fábrica (Moura Filho, 2021).

As máquinas elétricas rotativas, por sua participação fundamental neste setor, contribuem muito no consumo de energia e nos gastos derivados do seu uso. O uso de novas metodologias para realizar a manutenção deste dispositivo torna-se imprescindível, e neste contexto o uso de inteligência computacional começa a ser aplicado para a detecção de falhas em máquinas (Marins, 2016; Rocha, 2018).

A base de dados analisada, Mafaulda (2017), já foi utilizada em outros trabalhos acadêmicos para realizar diagnósticos de falhas em máquinas elétricas rotativas. A maioria desses trabalhos, a saber, Lima et al. (2013), López (2014), Pestana-Viana et al. (2016), Marins (2016) usaram como método de extração de características a *Fast Fourier Transform* (FFT) com um aumento na dimensionalidade, de modo que obtiveram bons resultados na classificação.

No trabalho de Lima et al. (2013), o modelo foi criado utilizando apenas três classes: normal, desalinhamento e desbalanceamento. Foi feito um balanceamento na classe normal, no qual, aumentou o número de elementos e salienta-se que o algoritmo utilizado foi uma perceptron de multicamadas (*Multilayer Perceptron* - MLP). Em termos de resultados o modelo obteve uma acurácia de 93,5%.

No artigo de Pestana-Viana et al. (2016) são acrescentados as falhas nos mancais de rolamento e como uma forma de conseguir resultados melhores, a classe de desalinhamento foi dividido em duas classes. Foi realizado também um aumento de dimensionalidade, utilizando medidas estatísticas como a curtose e a entropia. O algoritmo obteve uma acurácia de 95,8%.

Em Marins (2016) foi utilizado a *Random Forest* (RF) com a adição do método *Similarity-Based Modeling* (SBM), o modelo obteve uma acurácia de 98,49%. Já Silva (2018), utilizando 19 atributos e o algoritmo *K-Nearest Neighbors* (KNN) alcançou uma acurácia de 96,78%.

Em Rocha (2018) é apresentado além da FFT, mais duas formas de se realizar a extração de características, a saber, *Root Mean Square* (RMS) e a Transformada de Wavelet. Este trabalho conseguiu bons resultados utilizando as três técnicas de extração, tendo como destaque o uso da Transformada de Wavelet que, possuindo ainda um aumento de dimensionalidade, conseguiu um resultado de 98,70% de acurácia na classificação. O banco de dados utilizado para a criação do modelo não passou por nenhum balanceamento.

Este artigo tem como objetivo apresentar uma comparação entre técnicas de *ensemble learning* para realizar diagnóstico de falhas em máquinas elétricas rotativas, utilizando também métodos de otimização de hiperparâmetros. Também é realizada uma comparação entre os resultados deste artigo e aqueles apresentados em outros trabalhos acadêmicos.

2. FALHAS MECÂNICAS

As falhas podem ocorrer do envelhecimento gerado pelo uso, condições ambientais e tempo (Roemer et al., 2005). Entre os problemas que podem surgir estão o desalinhamento, desbalanceamento e falhas nos mancais de rolamento.

2.1 Desalinhamento

O desalinhamento é um problema que ocorre no alinhamento entre o eixo da máquina motora e o eixo da carga que está ligada a ela. Este desalinhamento pode ser na vertical, horizontal, ou os dois. O desalinhamento pode provocar na máquina um aumento nas vibrações e perdas de energia (López, 2014; Rocha, 2018; Moura Filho, 2021).

2.2 Desbalanceamento

O desbalanceamento ocorre quando existe um excesso de carga em torno do eixo de rotação do motor, isso tem como consequência a falta de simetria entre o eixo de rotação da máquina e seu eixo de inércia. Este problema traz para o motor alguns defeitos e também um aumento nas vibrações da máquina (López, 2014).

2.3 Falhas nos mancais de rolamento

As falhas nos mancais de rolamentos são causados pelo desgaste que ocorre com a sua utilização. As falhas ocorrem nos elementos que compõem o mancal, como o elemento rolante, a gaiola e a pista externa. Para a máquina este problema tem como consequência um aumento na tensão mecânica no eixo e nos rolamentos (López, 2014; Moura Filho, 2021).

3. TÉCNICAS DE MINERAÇÃO DE DADOS

As técnicas utilizadas neste trabalho para realizar o diagnóstico de falhas em máquinas elétricas rotativas foram a RF e a *Gradient Boosting* (GB). São algoritmos que possuem como princípio a combinação de vários modelos simples (*ensemble learning*) de árvores de decisão que são utilizados para a criação de um algoritmo mais robusto (Friedman et al., 2009; Witten and Frank, 2005). Esses algoritmos foram empregados como solução para os problemas de instabilidade de modelos mais simples. A combinação de vários modelos pode servir como um complemento para se conseguir um bom desempenho na classificação (Friedman et al., 2009).

Geralmente, a RF, com o aumento do número de variáveis, tende a formar árvores mais profundas que costumam ter um baixo viés e uma alta variância, em contraposição, o GB cria árvores mais rasas que possuem um alto viés e uma baixa variância. Um comparativo também possível de ser feito é no número de estimadores (árvores de decisão) para a criação do modelo. A RF tende a possuir um menor número de estimadores quando se comparado com o GB, levando assim menos tempo no treinamento do modelo (Witten and Frank, 2005; Friedman et al., 2009).

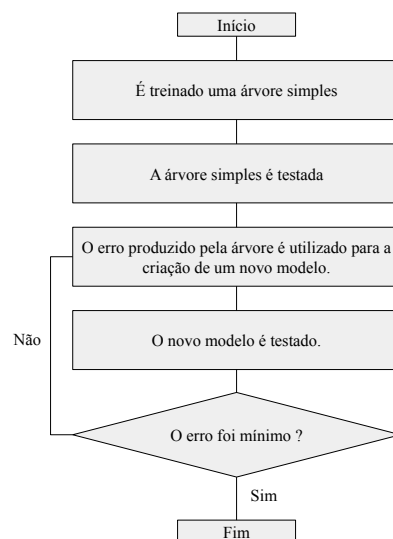


Figura 1. Etapas do *boosting*.

A criação de modelos de *ensemble learning* pode ocorrer de duas maneiras: em série (*boosting*) ou em paralelo (*bagging*). No *boosting*, como apresentado na Figura 1, modelos simples de árvores de decisão são criados de forma sequencial, possuindo uma ponderação nos pesos; desta forma um modelo aprende com os erros do outro, resultando num aprendizado por reforço (Witten and Frank,

2005). Assim o algoritmo vai se ajustando e aumentando a sua complexidade, gerando uma menor taxa de erros na classificação. O algoritmo GB utiliza este método para a criação do modelo de mineração de dados.

Já o *bagging* utiliza como princípio a criação de modelos simples de árvores de decisão em paralelo, possuindo pesos iguais. O banco de dados é dividido em n subconjuntos de treinamento com tamanhos iguais, sendo seus elementos escolhidos aleatoriamente. Com cada subconjunto é possível criar um exemplar de uma árvore de decisão. A partir de cada modelo é realizado um processo de votação para escolher as regras de decisão que foram mais adotadas pelas árvores mais simples. Desta forma, no final dessa seleção é obtido um espécime mais complexo que abrange as regras de decisões que geraram os melhores resultados na classificação (Witten and Frank, 2005). O algoritmo RF utiliza este método para a criação do seu modelo. Na Figura 2 é mostrado como esta técnica funciona.

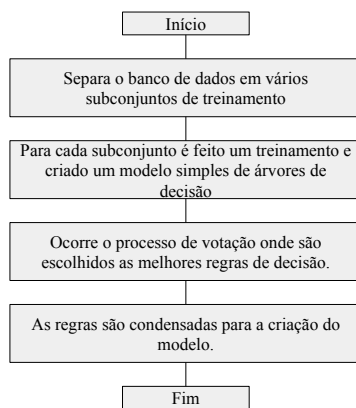


Figura 2. Etapas do *bagging*.

4. METODOLOGIA

O banco de dados utilizado para realizar a criação dos algoritmos foi retirado de Mafaulda (2017). Ele é composto por 1951 séries temporais multivariadas retiradas de medições realizadas em um motor de corrente contínua utilizando uma *SpectraQuest's Machinery Fault Simulator* (MFS). As séries temporais encontradas no banco de dados são formadas por matrizes de 250000 amostras e 8 colunas. Os atributos que formam o banco de dados são medições de um tacômetro, um acelerômetro triaxial modelo 604B31, três acelerômetros modelo 601A01 e um microfone. Os acelerômetros eram utilizados para fazer as medições em três direções diferentes: radial, axial e tangencial. O banco de dados é composto pelas seguintes classes: normal, desalinhamento do eixo horizontal, desalinhamento do eixo vertical, desbalanceamento, falha no mancal de rolamento interno e falha no mancal de rolamento externo. Na Tabela 1 pode-se observar o número de elementos para cada classes.

4.1 Extração de características

Como mencionado, as séries temporais são formadas por matrizes que possuem 250000 amostras, desta forma existe

a necessidade de realizar a extração de características destas matrizes. Para isso baseado nos estudos do trabalho de Rocha (2018) foi utilizado para a extração a média RMS. Esta técnica é bastante utilizada na literatura: Tsyppkin (2013), Rocha (2018), Guo et al. (2018), para a extração de características energéticas dos sinais, como também é de fácil implementação e, em comparação com outros métodos empregados na literatura, gera um número menor de atributos. O RMS é calculado como mostrado em (1).

$$RMS = \sqrt{\left(\frac{1}{N} \sum_{i=1}^N x_i^2\right)} \quad (1)$$

no qual $i = (1, 2, \dots, N)$, em que N é número de elementos e x_i é cada amostra da coluna de dados. Aplicando o RMS no conjunto de dados, é obtido para cada matriz um vetor de elementos que sintetiza as medições realizadas. O vetor é formado por 8 amostras e pode ser representado em (2), adaptado de Rocha (2018).

$$V = [RMS_a, RMS_b, RMS_c, RMS_d, RMS_e, RMS_f, RMS_g, RMS_h] \quad (2)$$

4.2 Pré-processamento

Como pode ser observado na Tabela 1, o banco de dados apresenta um desbalanceamento evidente entre as suas classes, este fator pode diminuir a taxa dos acertos resultante dos algoritmos. Por isso uma das metodologias empregadas para realizar o balanceamento das classes que foi utilizado no trabalho de López (2014), é o aumento de elementos da classe Normal. Para isto é necessário pegar cada matriz de elementos da classe normal e subdividi-la em 8 novas matrizes para essa classe. Em cada matriz dessa é aplicado o RMS, com isto é criado novas linhas de amostras para a classe que esteja com poucos elementos. Ao final deste processo a classe Normal passou a ter 392 amostras.

Tabela 1. Número de elementos de cada classe no banco de dados Mafaulda (2017).

Classes	Elementos
Normal	49
Desalinhamento no eixo horizontal	197
Desalinhamento no eixo vertical	301
Desbalanceamento	333
Falha no mancal de rolamento interno	558
Falha no mancal de rolamento externo	513

4.3 Treinamento

Para realizar o processo de construção dos algoritmos, o banco de dados foi dividido em dois subconjuntos. A divisão realizada foi seguindo a proporção de 80% para treinamento do algoritmo e 20% para o teste. Com o banco dados de treinamento foi realizado um processo de validação cruzada por *k-fold*, sendo $k = 3$, no qual, se definiu os melhores hiperparâmetros para o desenvolvimento do modelo. O modelo criado é aplicado no banco de dados de teste, resultando nas medidas de avaliação de desempenho. É apresentado na Figura 3 como esta metodologia é feita.

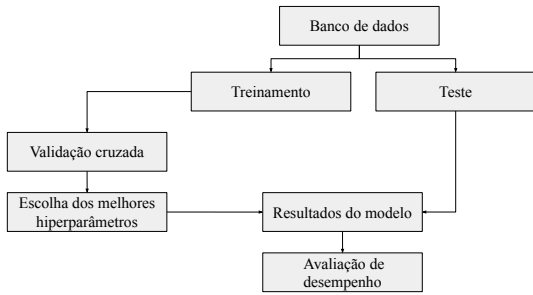


Figura 3. Metodologia usada no treinamento.

4.4 Otimização de hiperparâmetros

A estratégia de otimização de hiperparâmetros consiste em duas etapas. A primeira etapa é a Busca Aleatória com Validação Cruzada K -fold e a segunda etapa é a Busca de Grade com Validação Cruzada K -fold.

A primeira etapa consiste em testar aleatoriamente a região dos valores de hiperparâmetros que resultam nos melhores valores de acurácia. Esta é uma das mais populares estratégias de otimização de hiperparâmetros. Em Bergstra and Bengio (2012), foi provado teoricamente e empiricamente que este método é mais efetivo para otimização de hiperparâmetros do que a estratégia de Busca de Grade. Por esta razão, na segunda etapa, a Busca de Grade é usada, de maneira sequencial e dependente da Busca Aleatória, como uma tentativa de encontrar o ajuste ótimo dos hiperparâmetros ou encontrar valores de hiperparâmetros com menor custo computacional e que ofereçam uma acurácia igual ou maior que os melhores hiperparâmetros encontrados pela Busca Aleatória.

Então, se \mathcal{A} é o algoritmo aprendiz, e se $\mathcal{L}(x; f)$ é a função custo minimizada pela função f onde x é uma amostra da distribuição \mathcal{G}_x , se $\chi^{(train)}$ é conjunto de treinamento e λ são os hiperparâmetros, então o problema de otimização de hiperparâmetros se resume a encontrar os valores de λ para qual a generalização do erro $E_{x \sim \mathcal{G}_x}[\mathcal{L}(x; \mathcal{A}_\lambda(\chi^{(train)}))]$ é mínima, de acordo com (3) (Bergstra and Bengio, 2012).

$$\lambda^{(*)} = \arg \min_{\lambda \in \Lambda} E_{x \sim \mathcal{G}_x}[\mathcal{L}(x; \mathcal{A}_\lambda(\chi^{(train)}))] \quad (3)$$

Em seguida, a etapa 2 é realizada. Nesta etapa uma busca mais refinada é realizada para os valores vizinhos aos melhores hiperparâmetros encontrados na etapa 1. Trata-se de uma busca exaustiva entre os valores dentro do intervalo de melhor acurácia encontrada na Busca Aleatória, onde cada combinação de hiperparâmetro é testada.

5. EXPERIMENTOS E RESULTADOS

5.1 Efeito do ajuste de hiperparâmetros na acurácia

Os hiperparâmetros mais importantes para os algoritmos RF e GB são o número de estimadores, a máxima profundidade dos modelos e o número máximo de atributos a serem considerados em cada divisão de nó da árvore. Antes da otimização, os algoritmos RF e GB seguiram a configuração padrão de hiperparâmetros da biblioteca *Scikit-Learn* (Buitinck et al., 2013).

I) Número de estimadores

A Figura 4 representa o comportamento da acurácia em função do número de estimadores do algoritmo RF e GB para o intervalo de 1 a 1200 estimadores (árvores de decisão). Da Figura 4 é possível notar que o algoritmo GB possui o maior valor de acurácia em relação ao algoritmo RF para a maioria dos valores de estimadores.

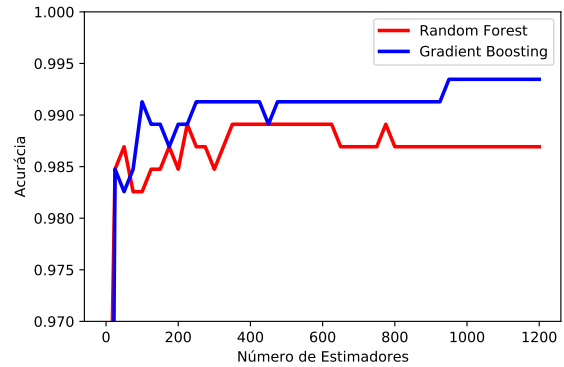


Figura 4. Influência do número de estimadores na acurácia.

Além disso, outra grande diferença entre os algoritmos é que o algoritmo GB atinge sua máxima acurácia quando o número de estimadores se aproxima de 1000, enquanto o algoritmo RF atinge sua máxima acurácia quando o número de estimadores se aproxima de 200.

Desta forma, a maior acurácia obtida para o algoritmo RF foi 98.91% para o valor de 225 estimadores, não obtendo acurácia maior com o aumento dos estimadores. Já para o algoritmo GB, a maior acurácia obtida foi de 99.35% para o valor de 950 estimadores, não obtendo acurácia maior com o aumento de estimadores.

Portanto, é esperado que o algoritmo GB obtenha o maior valor de acurácia com um alto número de estimadores, em comparação com o algoritmo RF, pois os estimadores do algoritmo GB são construídos de forma serial, isto é, a performance dos estimadores seguintes são melhorados com base nos estimadores anteriores, em detrimento do algoritmo RF, onde os estimadores são construídos de maneira paralela.

II) Profundidade máxima

A Figura 5 representa a variação da acurácia dos dois algoritmos em função da profundidade dos estimadores para um intervalo de 1 a 100. Nota-se que o algoritmo GB se mantém a frente do algoritmo RF. A acurácia mais alta para o algoritmo GB é obtida com uma profundidade de 4, e para o algoritmo RF a profundidade de maior acurácia é 24, para outros valores de profundidade não obteve-se acurácias maiores.

Portanto, os valores de profundidade máxima para ambos os algoritmos encontrados na Figura 5 comprovam o dilema viés-variância associado a cada modelo. Isto é, os estimadores do algoritmo RF tendem a ser mais profundos com baixo viés e alta variância, e de forma analogamente oposta, os estimadores do algoritmo GB tendem a ser mais rasos com alto viés e baixa variância.

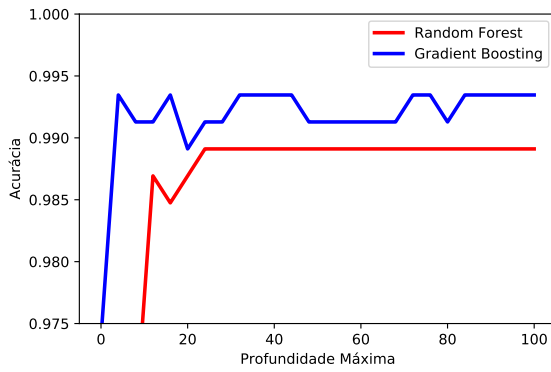


Figura 5. Influência do número de profundidade máxima na acurácia.

III) Número máximo de atributos

Na Figura 6 a variação do valor de acurácia dos dois algoritmos é representada em função do número de atributos a serem considerados na busca pela melhor divisão, em um intervalo de 1 a 8.

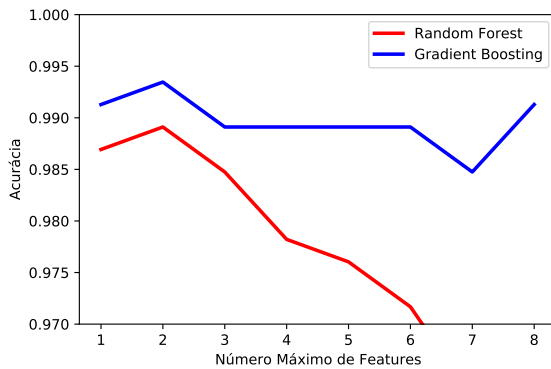


Figura 6. Influência do número máximo de atributos na acurácia.

O maior valor de acurácia para os algoritmos RF e GB foi alcançado para o valor máximo de atributos igual a 2.

5.2 Resultados Finais

Nas Tabelas 2 e 3 estão registradas as medidas de precisão, recall e F-score (Witten and Frank, 2005) calculadas para os algoritmos RF e GB depois da otimização de hiperparâmetros.

É possível verificar que as classes com melhor classificação são as classes Normal e Mancal Externo, com avaliação de 100% em todas as métricas. Além disso, a classe com pior avaliação foi a de Desbalanceamento, que apresentou o menor valor de recall e, conseqüentemente, o menor valor de F-score.

Tabela 2. Resultados do algoritmo RF após ajuste de hiperparâmetros.

Classe	Precisão	Recall	F-score
Desalinhamento	97.27%	100%	98.62%
Desbalanceamento	100%	94.29%	97.06%
Mancal Externo	100%	100%	100%
Mancal Interno	98.02%	99%	98.51%
Normal	100%	100%	100%

Tabela 3. Resultados do algoritmo GB após ajuste de hiperparâmetros.

Classe	Precisão	Recall	F-score
Desalinhamento	98.17%	100%	99.07%
Desbalanceamento	100%	95.71%	97.81%
Mancal Externo	100%	100%	100%
Mancal Interno	99.01%	100%	99.50%
Normal	100%	100%	100%

Ademais, nas Tabelas 4 e 5 são registradas as matrizes de confusão para os algoritmos RF e GB após o ajuste dos hiperparâmetros, onde as linhas representam os *True Labels* e as colunas representam os *Predicted Labels*.

Tabela 4. Matriz de confusão para RF.

Classe	a	b	c	d	e
a = Desalinhamento	107	0	0	0	0
b = Desbalanceamento	2	66	0	2	0
c = Mancal Externo	0	0	100	0	0
d = Mancal Interno	1	0	0	99	0
e = Normal	0	0	0	0	82

Tabela 5. Matriz de confusão para GB.

Classe	a	b	c	d	e
a = Desalinhamento	107	0	0	0	0
b = Desbalanceamento	2	67	0	1	0
c = Mancal Externo	0	0	100	0	0
d = Mancal Interno	0	0	0	100	0
e = Normal	0	0	0	0	82

A comparação entre os valores de acurácia dos algoritmos RF e GB estão registrados na Tabela 6, para as situações antes e depois da otimização dos hiperparâmetros. O processo de otimização resultou em incremento de precisão de 0,89% e 1,11% para os algoritmos RF e GB, respectivamente.

Tabela 6. Comparação das acurácias.

	RF antes do ajuste	RF depois do ajuste	GB antes do ajuste	GB depois do ajuste
Acurácia	98.04%	98.91%	98.26%	99.35%

5.3 Comparação com trabalhos anteriores

Na Tabela 7 estão resumidos os valores de acurácia para o presente trabalho e para os trabalhos anteriores que usaram o mesmo banco de dados para classificar defeitos em máquinas rotativas.

Os algoritmos RF e GB apresentados neste trabalho superaram todos os trabalhos anteriores, com exceção do trabalho de López (2014) que obteve 100% de acurácia, mas para este resultado, ele precisou de 19 atributos e realizou a classificação em apenas 3 classes, enquanto o presente trabalho usou 8 atributos e realizou a classificação em 5 classes.

Em geral, a metodologia deste trabalho ofereceu a vantagem de superar a acurácia de quase todos os trabalhos anteriores que usaram este banco de dados, empregando um método de extração de recursos mais simples e com uma redução significativa no número de atributos em cada algoritmo de *ensemble learning*.

Tabela 7. Resultados dos trabalhos analisados que usaram o banco de dados Mafaulda (2017).

Autor	Método de Extração	Nº de classes	Nº de <i>features</i>	Algoritmo	Acurácia
Lima et al. (2013)	FFT	3	10	MLP	93,50%
López (2014)	FFT	3	19	RF	100%
Pestana-Viana et al. (2016)	FFT	6	31	MLP	95,80%
Marins (2016)	FFT	6	46	RF + SBM	98,49%
Rocha (2018)	Transformada de Wavelet	6	24	XGboost	98,70%
Silva (2018)	FFT	6	19	KNN	96,78%
Obtido pelos autores	RMS	5	8	RF	98,91%
Obtido pelos autores	RMS	5	8	GB	99,35%

6. CONCLUSÃO

Neste trabalho, foi realizada uma comparação de desempenho entre os modelos de *ensemble learning random forest* e *gradient boosting* empregados na classificação de falhas de máquinas elétricas rotativas. Os resultados mostraram um desempenho superior do GB, com uma acurácia de 99,35%, em relação ao RF, que obteve acurácia de 98,91%.

Os resultados obtidos aqui superaram quase todos os trabalhos anteriores que usaram o mesmo banco de dados para classificar falhas em máquinas elétricas rotativas usando técnicas de *machine learning*. Por outro lado, o método de extração de características RMS associado à estratégia de otimização de hiperparâmetros adotada, conferiu a este trabalho alta acurácia, com um menor número de atributos em comparação com trabalhos anteriores.

Como trabalhos futuros, espera-se analisar o uso de outras técnicas de mineração de dados a fim de obter resultados ainda melhores.

REFERÊNCIAS

- Bergstra, J. and Bengio, Y. (2012). Random search for hyper-parameter optimization. *Journal of Machine Learning Research*, 13, 281–305.
- Buitinck, L., Louppe, G., Blondel, M., Pedregosa, F., Mueller, A., Grisel, O., Niculae, V., Prettenhofer, P., Gramfort, A., Grobler, J., Layton, R., VanderPlas, J., Joly, A., Holt, B., and Varoquaux, G. (2013). API design for machine learning software: experiences from the scikit-learn project. In *ECML PKDD Workshop: Languages for Data Mining and Machine Learning*, 108–122.
- Friedman, J.H., Tibshirani, R., and Hastie, T. (2009). *The Elements of Statistical Learning*, volume 1. Springer.
- Guo, S., Ren, Y., Shi, S., Yang, L., and Lin, J. (2018). Rotating machinery vibration analysis of the rotary-laser scanning measurement system. *2017 International Conference on Optical Instruments and Technology: Optoelectronic Measurement Technology and Systems*.
- Hand, A. (2015). *Motores elétricos : manutenção e solução de problemas*, volume 1. Bookman, Porto Alegre.
- Lima, A.A., d. M. Prego, T., Netto, S.L., da Silva, E.A.B., Gutierrez, R.H.R., Monteiro, U.A., Troyman, A.C.R., d. C. Silveira, F.J., and Vaz, L. (2013). On fault classification in rotating machines using fourier domain features and neural networks. In *2013 IEEE 4th Latin American Symposium on Circuits and Systems (LASCAS)*, 1–4.
- López, R.Z. (2014). *Classificação automática de defeitos em máquinas rotativas*. 2014. 120 f. Trabalho de conclusão de curso, Escola Politécnica, Universidade Federal do Rio de Janeiro, Rio de Janeiro.
- Mafaulda (2017). Machinery fault database [online]. Disponível em: http://www02.smt.ufrj.br/~offshore/mfs/page_01.html. Acesso em 11 jan. 2021.
- Marins, M.A. (2016). *Classificação de falhas em máquinas rotativas utilizando métodos de similaridade e random forest* 2016. 67 f. Trabalho de conclusão de curso, Escola Politécnica, Universidade Federal do Rio de Janeiro, Rio de Janeiro.
- Moura Filho, J.O.F. (2021). *Diagnóstico de falhas em máquinas elétricas rotativas utilizando técnicas de reconhecimento de padrões* 2021. 82 f. Trabalho de conclusão de curso, Universidade Federal do Ceará, Sobral.
- Pestana-Viana, D., Zambrano-López, R., de Lima, A.A., Prego, T.D.M., Netto, S.L., and da Silva, E.A.B. (2016). The influence of feature vector on the classification of mechanical faults using neural networks. In *2016 IEEE 7th Latin American Symposium on Circuits Systems (LASCAS)*, 115–118.
- Rocha, D.S.C. (2018). *Aprendizado de máquina aplicado ao reconhecimento automático de falhas em máquinas rotativas* 2018. 78 f. Dissertação (mestrado em engenharia elétrica), Escola de engenharia, Programa de Pós-Graduação em Engenharia Elétrica: Universidade Federal de Minas Gerais, Belo Horizonte.
- Roemer, M.J., Byington, C.S., Kacprzynski, G.J., and Vachtsevanos, G. (2005). An overview of selected prognostic technologies with reference to an integrated phm architecture. In *In Proceedings of the First International Forum on Integrated System Health Engineering and Management in Aerospace, Big Sky*, 3941–3947.
- Silva, M.C. (2018). *Métodos de inteligência artificial para diagnóstico de defeitos em máquinas rotativas* 2018. 94 f. Trabalho de conclusão de curso, Departamento de Engenharia Elétrica e Eletrônica, Universidade Federal de Santa Catarina, Santa Catarina.
- Tsyppkin, M. (2013). Induction motor condition monitoring: Vibration analysis technique - a twice line frequency component as a diagnostic tool. In *2013 International Electric Machines Drives Conference*, 117–124.
- Witten, I.H. and Frank, E. (2005). *Data mining : practical machine learning tools and techniques*, volume 2. Elsevier.