

Classificação de Superfície de Rodovias utilizando Técnicas de Aprendizado de Máquinas em Pneus Inteligentes

Rafael Ávila dos Santos
*Programa de Pós-Graduação em
Engenharia de Sistemas e Automação
Universidade Federal de Lavras
Lavras, MG, Brasil
rafael.santos0t5@gmail.com*

Bruno H. G. Barbosa
*Departamento de Automática
Universidade Federal de Lavras
Lavras, MG, Brasil
brunohb@ufla.br*

Danton D. Ferreira
*Departamento de Automática
Universidade Federal de Lavras
Lavras, MG, Brasil
danton@ufla.br*

Hassan Askari
*Department of Engineering
Brock University
St. Catharines, ON, Canadá
haskari@brocku.ca*

Nan Xu
*National Key Laboratory of
Automotive Chassis Integration
Jilin University
Changchun, JL, China
xunan@jlu.edu.cn*

Abstract—Conhecimentos da dinâmica veicular são essenciais para melhorar a segurança e a tecnologia dos veículos. Com esse propósito, os pneus inteligentes vêm sendo bastante utilizados para mensurar a interação pneu-solo e contribuir para uma melhor estimativa dos estados do veículo e condições da superfície. Nesse sentido, este trabalho tem por objetivo classificar o tipo de superfície que o veículo se encontra por meio de técnicas de Aprendizado de Máquinas aplicadas em dados de sensores instalados dentro do pneu. Para isso, recorreu-se a um banco de dados contendo oito tipos de superfícies, sendo o pneu submetido a velocidades de 30, 60 e 90 mph, cujos dados foram obtidos por meio de um acelerômetro triaxial e um sensor nanogerador baseado no polímero Fluoreto de polivinilideno (PVDF). Após a extração de características temporais desses sensores dentro da zona de contato pneu-solo, foram utilizados diversos modelos de aprendizado de máquina para identificar os oito tipos de superfícies. A partir da leitura do acelerômetro, o modelo *Random Forest* obteve 90% de acurácia no teste, demonstrando superioridade em relação aos demais. Já com os dados do PVDF tanto o modelo *Gradient Boosting* quanto o *Extra Tree* obtiveram resultados de acurácia próximos de 97% em teste, mostrando que o uso do PVDF é aconselhável para o problema abordado. Finalmente, foi aplicada a técnica LIME para explicar e entender a influência das características sobre as classificações das superfícies.

Index Terms—Dinâmica Veicular, Pneu Inteligente, Machine Learning, Inteligência Computacional, Sistemas Inteligentes.

I. INTRODUÇÃO

Atualmente, a presença de sistemas de controle integrado nos veículos é imprescindível. A implementação destes sistemas proporciona benefícios diversos, incluindo o aumento da segurança dos passageiros, a melhoria da autonomia do veículo, entre outros aprimoramentos, graças às configurações estabelecidas a partir do reconhecimento da rodovia [1][2]. Inicialmente, é necessário um sensor que capte variáveis re-

levantes e que represente adequadamente a dinâmica veicular, o que habitualmente constitui um desafio significativo [3]. Nesse sentido, uma das soluções emergentes reside nos pneus inteligentes [4]. Os pneus inteligentes são compostos por sensores que registram, por exemplo, as forças aplicadas na roda. A informação obtida pelos sensores pode ser suficiente para determinar o estado do veículo e tipo de via onde o pneu está sendo utilizado [5].

Para esse efeito, é necessário o uso de sensores, tais como os acelerômetros e os PVDF, presentes em pneus inteligentes [6]. O acelerômetro triaxial constitui um sensor que fornece a aceleração aplicada nos três eixos cartesianos. Deste modo, quando ocorre o contato do pneu com o solo na região do sensor, a leitura dos sinais desses eixos oscila de forma característica, uma vez que é o momento em que atuam mais forças na região do sensor no pneu. O mesmo acontece com o sensor nanogerador PVDF. Ele gera tensão à medida que o pneu sofre deformações, principalmente na região em contato com o solo [7]. Ambos os sensores apresentam um custo reduzido, facilitando a sua aplicação, por meio de seu acoplamento interno nos pneus inteligentes.

No estudo de pneus inteligentes, é também possível observar trabalhos que preveem a força lateral [4] [8], força vertical [3], força longitudinal [9], bem como outros que abordam o ângulo de deriva [10], responsável pelo estudo da derrapagem de veículos e utilizado para o controle da estabilidade, entre outras linhas de estudo. A utilização do acelerômetro e do PVDF é igualmente observada em trabalhos como os de Xu, Nan et al. [11] e de Quan, Zhenqiang et al. [12].

Desta forma, o objetivo deste trabalho foi a construção de modelos de classificação baseados em aprendizado de máquinas capazes de definir em que tipo de rodovia o pneu

se encontra submetido com base em sinais gerados pelo acelerômetro e pelo PVDF, comparando o desempenho de diversos modelos e os diferentes sensores utilizados. Posteriormente, foi analisada a importância das características temporais extraídas para a classificação de cada um dos tipos de rodovia por meio da técnica LIME (*Local Interpretable Model-Agnostic Explanations*).

Este artigo está estruturado da seguinte forma: a Seção II descreve o banco de dados, assim como o pré-processamento realizado. A Seção III mostra os resultados obtidos e discussões. Por último, na Seção IV, as conclusões são apresentadas.

II. MATERIAIS E MÉTODOS

O sistema com o pneu inteligente emprega uma solução de transmissão com fio, conforme mostrado na Figura 1. Esse esquema de aquisição consiste em um módulo de sensor, um módulo de transmissão, um módulo de regulação de sinal, um módulo de aquisição de dados e um módulo de armazenamento de dados. O módulo do sensor inclui um acelerômetro triaxial e um sensor PVDF, que são usados para coletar sinais de vibração e deformação da banda de rolagem, conforme ilustrado na 2. A Figura 3a mostra a amostra de teste integrada do pneu inteligente, e o veículo de teste selecionado para este estudo é um NIO ES7, mostrado na Figura 3b.

A Figura 4 ilustra a metodologia adotada neste trabalho após a coleta do banco de dados. Inicialmente, foi realizado o janelamento dos dados com o propósito de obter um intervalo suficiente para representar o ponto de contato do pneu com o solo, bem como os 35 graus anteriores e posteriores a esse momento. Após a realização deste pré-processamento nos dados, o segundo passo consistiu na extração das características temporais descritas na seção C. Conforme demonstrado na tabela I, o banco de dados resultante após o procedimento de janelamento apresenta-se como um banco de dados desequilibrado, tanto para o sensor PVDF como para o acelerômetro. Sabendo que é adequado o banco de dados ser equilibrado para treinamento de modelos de aprendizado de máquina, foi implementada a técnica de oversampling SMOTE [13]. Nesta técnica, amostras são criadas a partir dos vizinhos mais próximos, sendo cinco o valor padrão. Desta forma, todas as classes para os dados provenientes do PVDF e do acelerômetro passaram a dispor de 610 amostras para o processo de treino. O treinamento dos cinco modelos de classificação (Random Forest [14], Extra Tree [15], KNeighbors [16], Gradient Boosting [17], MLP [18]) foi efetuado retornando às métricas de avaliação obtidas por meio da validação cruzada k-fold com dez folds. A partir dos valores alcançados, foi possível identificar o modelo mais eficaz. Posteriormente, recorreu-se à técnica LIME para determinar as influências mais significativas, positivas e negativas, para cada um dos oito tipos de rodovias a ser classificada. As subsequentes seções detalham as etapas aqui descritas.

A. Banco de Dados

O banco de dados é constituído por leituras provenientes de dois sensores: um acelerômetro e um PVDF. Os sensores



Fig. 1. Aquisição de Dados.




Fig. 2. a: Acelerômetro Triaxial; b: PVDF

TABLE I
DIVISÃO DE AMOSTRAS POR TIPO DE RODOVIA PARA TREINO E TESTE

Rodovia	Treino - Inicial	Treino - Oversampling	Teste
Asfalto	530	610	148
Alvenaria	610	610	156
Cimento	267	610	67
Asfalto Grosso	543	610	137
Asfalto Fino	571	610	121
Asfalto Úmido	185	610	46
Basalto Úmido	243	610	66
Ladrilhos Úmidos	248	610	59

foram colocados no revestimento interno de um pneu.

Posteriormente, o pneu foi submetido a oito tipos de rodovias, classificadas como: asfalto, alvenaria, cimento, asfalto grosso, asfalto fino, asfalto úmido, basalto úmido e ladrilhos úmidos, conforme ilustrado na figura 6. O acelerômetro, por ser triaxial, retorna informações pertinentes



Fig. 3. a: Pneu de Teste; b: Veículo de Teste.




Fig. 4. Metodologia

à força exercida nos três eixos (X, Y, Z). Já o sensor PVDF retorna apenas a leitura da variação da tensão. Além das diferentes condições das rodovias, a velocidade do pneu também varia entre 30, 60 e 90 mph (milhas por hora). Ambos os sensores foram amostrados a uma frequência de amostragem de 10 kHz.

O tempo total em que os dados foram amostrados apresenta uma variação considerável. Para uma velocidade de 30 mph, os dados foram coletados num período mínimo de 24,539 segundos para a rodovia do tipo asfalto úmido, enquanto o período máximo foi de 75,269 segundos para a rodovia do tipo asfalto. Já para 60 mph, o tempo máximo de recolha de dados foi de 76,210 s, enquanto o mínimo foi de 9,879 s. Por fim, para 90 mph, o tempo máximo de recolha de dados foi de 76,210 s, enquanto o tempo mínimo foi de 7,949 s. A figura 5 mostra a leitura temporal do eixo x do acelerômetro e do PVDF em uma rodovia do tipo asfalto com o veículo a 30 mph.




Fig. 5. Leitura Temporal dos Sensores Para Rodovia Tipo Asfalto.




Fig. 6. a: Asfalto; b: Asfalto Fino; c: Asfalto Grosso; d: Alvenaria; e: Cimento; f: Asfalto Úmido; g: Basalto Úmido; h: Ladrilhos Úmidos;

B. Janelamento

Com o propósito de aumentar o banco de dados e selecionar intervalos que contivessem informações suficientes para a classificação, neste trabalho foi implementado o janelamento dos dados, seguindo a metodologia apresentada em [4] e ilustrada pela figura adaptada 7. Inicialmente, por meio do gráfico do sinal gerado pela leitura dos dados obtidos, é possível identificar os pontos de início e fim de contato do pneu com o solo (representados pelas letras B e D, respectivamente). Esses dois momentos são reconhecidos devido às suas caracterizações que são dadas por oscilações abruptas do sinal. A amostra intermediária do sinal entre esses dois pontos representa o momento de contato total do pneu com o solo (ponto C). Juntamente com estas informações e com a frequência de amostragem do sinal, é possível inferir a janela do sinal que representa a amplitude em graus desejada. Neste trabalho, o janelamento do sinal é equivalente a 35° antes e depois do contato total com o solo (contemplando assim, apenas 70° do giro total do pneu sob seu próprio eixo). Os limites do janelamento são representados no gráfico pelas letras A e E.

C. Características Temporais

As características temporais extraídas dos dados após o janelamento foram selecionadas com base num critério análogo ao observado em [19]. As características em questão são: Média (1), Variância (2), Máximo Absoluto (5), Desvio padrão (3), Distorção (6), Curtose (7), Pico a pico, Raiz Quadrada Média (4), *Crest Factor* (8), *Margin Factor* (9), *Shape Factor* (10), *Impulse Factor* (11), Desvio Abstrato Mediano, Média Abs. Derivação, Raiz da Soma dos Quadrados (12), Energia (13) e Logaritmo da Energia (14):




Fig. 7. Janelamento do Sinal no Pneu Inteligente

$$X_1 = \frac{\sum_{n=1}^N L[n]}{N}, \quad (1)$$

$$X_2 = \frac{\sum_{n=1}^N (L[n] - X_1)^2}{N}, \quad (2)$$

$$X_3 = \sqrt{\frac{\sum_{n=1}^N (L[n] - X_1)^2}{N - 1}}, \quad (3)$$

$$X_4 = \sqrt{\frac{\sum_{n=1}^N (L[n])^2}{N}}, \quad (4)$$

$$X_5 = \max |L[n]|, \quad (5)$$

$$X_6 = \frac{\sum_{n=1}^N (L[n] - X_1)^3}{(N - 1)(X_3)^3}, \quad (6)$$

$$X_7 = \frac{\sum_{n=1}^N (L[n] - X_1)^4}{(N - 1)(X_3)^4}, \quad (7)$$

$$X_8 = \frac{\max |L[n]|}{\sqrt{\frac{\sum_{n=1}^N (L[n])^2}{N}}}, \quad (8)$$

$$X_9 = \frac{\max |L[n]|}{(\sum_{n=1}^N \sqrt{|L[n]|})^2}, \quad (9)$$

$$X_{10} = \frac{X_4}{\frac{1}{N} \sum_{n=1}^N |L[n]|}, \quad (10)$$

$$X_{11} = \frac{\max |L[n]|}{\frac{1}{N} \sum_{n=1}^N |L[n]|}, \quad (11)$$

$$X_{12} = \sqrt{\sum_{n=1}^N (L[n])^2}, \quad (12)$$

$$X_{13} = \sum_{n=1}^N (|L[n]|)^2, \quad (13)$$

$$X_{14} = \text{Log}(\sum_{n=1}^N (|L[n]|)^2). \quad (14)$$

D. Métrica de Avaliação

As métricas de avaliação utilizadas no presente estudo foram: Acurácia, Desvio Padrão da Acurácia, *Recall*, *Precision*, *F1-Score* e a Acurácia em Teste.

E. LIME

A técnica LIME (*Local Interpretable Model-agnostic Explanations*) [20] recorre a modelos locais substitutos para explicar a influência favorável ou desfavorável das características utilizadas para a classificação de uma amostra. A equação que descreve a utilização do LIME é apresentada por:

$$\text{explanation}(x) = \arg \min_{g \in G} L(f, g, \pi_x) + \Omega(g). \quad (15)$$

sendo g é o modelo que minimiza a função custo L entre o modelo original f e o modelo aproximado. $\Omega(g)$ é o termo adicionado que se refere a complexidade do modelo a fim de obter um modelo local simples. π_x é a medida de proximidade de outras amostras de x , a qual está aplicando a metodologia. G é o conjunto de explicações possíveis, ou seja, conjunto de modelos locais possíveis.

Desta forma, uma vez que o LIME consiste numa análise por amostra, o presente trabalho realizou a média destas influências e apresentou graficamente apenas as cinco variáveis mais influentes, tanto positivamente como negativamente, para cada um dos oito tipos de solo classificados.

III. RESULTADOS E DISCUSSÕES

A utilização dos dados de aceleração do eixo x permitiu obter os resultados para os cinco modelos de classificação avaliados, apresentados na tabela II. Esta tabela evidencia que todos os modelos apresentaram valores superiores a 70% para todas as métricas. Adicionalmente, o classificador **Random Forest** demonstrou a maior precisão no teste, seguido de perto pelos modelos **Extra tree** e **Gradient Boosting**.

TABLE II
DESEMPENHO DOS MODELOS COM DADOS DO EIXO X DO ACELERÔMETRO.

Model	Acc.	Std. Acc.	Recall	Prec.	F1	Test Acc.
Random Forest	0,9254	0,0136	0,8990	0,8820	0,8896	0,8925
Extra Tree	0,9324	0,0118	0,8893	0,8764	0,8824	0,8888
KNeighbors	0,8246	0,0348	0,7547	0,7094	0,7212	0,7375
GBoosting	0,9357	0,0146	0,8948	0,8763	0,8842	0,8862
MLP	0,7744	0,0570	0,7446	0,7059	0,7037	0,7163

A figura 8 ilustra a matriz de confusão com os dados do eixo x do acelerômetro para o modelo de classificação **Random Forest**. A referida figura evidencia a confusão entre asfalto e asfalto fino, com um total de 25 amostras confundidas, bem como entre alvenaria e ladrilhos úmidos onde 18 amostras foram confundidas. A imagem também indica confusões entre asfalto fino com asfalto além de outras confusões com um menor número de amostras.

Com base nos dados do PVDF, foi possível obter os resultados do treinamento dos modelos de classificação apresentados na tabela III. Conforme observado na tabela referida, todos




Fig. 8. Matriz de Confusão do Random Forest com dados do Acelerômetro

os modelos apresentaram resultados satisfatórios para todas as métricas, destacando-se os modelos *Gradient Boosting* e *Extra Tree*, que obtiveram os melhores valores de Acurácia no Teste, seguidos pelo modelo *Random Forest*.

TABLE III
DESEMPENHO DOS MODELOS COM DADOS DO PVDF

Model	Acc.	Std. Acc.	Recall	Prec.	F1	Test Acc.
Random Forest	0,9770	0,0110	0,9541	0,9513	0,9524	0,9600
Extra Tree	0,9824	0,0057	0,9590	0,9601	0,9595	0,9650
KNeighbors	0,8818	0,0207	0,8250	0,8128	0,8171	0,8413
GBoosting	0,9789	0,0100	0,9629	0,9626	0,9627	0,9688
MLP	0,8170	0,0497	0,8078	0,8204	0,8108	0,8375

A figura 9 apresenta a matriz de confusão com os dados do PVDF para o modelo de classificação *Gradient Boosting*. Nesta matriz, é possível observar que a maior confusão acontece entre cimento e asfalto fino, com um total de 12 amostras confundidas. As demais discrepâncias entre os tipos de rodovia não excedem quatro amostras.

A figura 10 apresenta os *boxplots* referentes às acurácias de teste, para cada um dos cinco modelos de classificação avaliados na validação cruzada de dez *folds*, para cada um dos conjuntos de dados utilizados. Na imagem, é possível observar que todas as medianas dos *boxplots* dos modelos treinados com os dados do PVDF se apresentam acima daquelas dos *boxplots* com os dados do eixo *x* do acelerômetro. Destacam-se os modelos *Random Forest*, *Extra Tree* e *Gradient Boosting*, que não cruzam nenhum quartil com os *boxplots* comparados. Deste modo, a partir da análise gráfica, é possível verificar estatisticamente que os modelos *Random Forest*, *Extra Tree* e *Gradient Boosting* apresentam uma maior eficácia com os dados do PVDF.

As figuras 11 até à 18 apresentam a análise do LIME aplicado ao *Gradient Boosting* com os dados do PVDF para cada um dos oito tipos de rodovia. Desta forma, é possível




Fig. 9. Matriz de Confusão do Gradient Boosting com dados do PVDF




Fig. 10. BoxPlot Comparativo dos modelos entre AccX e PVDF

identificar as contribuições mais favoráveis para a classificação do tipo de rodovia, bem como as contribuições mais desfavoráveis, na média.




Fig. 11. Contribuições médias de características para rodovia do tipo asfalto

A figura 11 ilustra a influência das variáveis na classificação da rodovia como sendo do tipo asfalto. O gráfico demonstra que a característica “Energy”, com um valor superior a 18,75, apresentou a influência mais significativa de natureza positiva.

No entanto, se esta característica exceder 11,48 e for inferior ou igual a 18,75, gerará a maior influência negativa observada na média das amostras.




Fig. 12. Contribuições médias de características para rodovia do tipo asfalto grosso

A figura 12, demonstra que, para a rodovia do tipo asfalto grosso, a “Median Abs Deviation” superior a 0,01 constitui a característica mais relevante para a sua classificação. Em contraste, o valor de “Energy” superior a 18,75 representa, em média, a influência mais negativa para esta categoria.




Fig. 13. Contribuições médias de características para rodovia do tipo asfalto fino

No que diz respeito à rodovia rotulada como asfalto fino, a característica “Median Abs Deviation” pode ter uma influência significativa, tanto positiva como negativa, dependendo do intervalo dos seus valores. Esta observação pode ser comprovada por meio de análise da figura 13. O intervalo menor ou igual a zero desta característica atribui um peso positivo à sua classificação, enquanto o intervalo maior do que 0,01 é negativo para esta.




Fig. 14. Contribuições médias de características para rodovia do tipo asfalto úmido

A derivada média absoluta (Mean Abs Derivation) superior a 0,02 representa a característica mais favorável para a rodovia do tipo asfalto úmido, conforme demonstrado na figura 14. Já a característica “Impulse Factor”, cuja variação se encontra entre 5,79 e 8,12, apresenta-se como a mais desfavorável.




Fig. 15. Contribuições médias de características para rodovia do tipo alvenaria

No que diz respeito à rodovia do tipo alvenaria, a característica “Variance” com um valor inferior ou igual a 0.03 apresenta a média mais favorável para esta classe, conforme apresentado na figura 15. No entanto, se a mesma característica apresentar um valor entre 0.04 e 0.06, a sua classificação será a mais negativa.




Fig. 16. Contribuições médias de características para rodovia do tipo ladrilhos úmidos

A característica “Mean Abs Derivation” superior a 0,02, assim como a “Mean” superior a 0,04, contribuíram significativamente para a classificação da rodovia do tipo ladrilhos úmidos, conforme ilustrado na figura 16. Em contraste, o “Impulse Factor”, variando entre 5,79 e 8,12, apresentou a contribuição mais negativa para essa classificação, juntamente com “Energy”, que excedeu 18,75.

Com vista à classificação da rodovia identificada como tipo cimento, as características que mais contribuíram de forma positiva foram o “Kurtosis” menor ou igual a 5,44 e o “Crest Factor” maior que 4,41. No entanto, é importante salientar que, caso a característica “Kurtosis” ultrapasse o valor de 7,17, tal constitui um fator prejudicial para a classificação em questão, conforme demonstrado pelas duas contribuições mais negativas representadas na figura 17. Além disso, é observável que algumas das características mais importantes também são vistas para asfalto fino, o que dialoga com a matriz de confusão entre esses dois tipos de rodovia vista na figura 9 anteriormente.




Fig. 17. Contribuições médias de características para rodovia do tipo cimento




Fig. 18. Contribuições médias de características para rodovia do tipo basalto úmido

As características “Mean”, “Mean Abs Derivation” e “Variance” com os respectivos intervalos, conforme demonstrado na figura 18, foram as que mais contribuíram positivamente para a classificação da rodovia tipo basalto úmido. No entanto, em intervalos distintos, o “Mean” e o “Variance” podem igualmente ter um impacto negativo na classificação.

IV. CONCLUSÃO

A análise dos resultados obtidos permite concluir que a implementação do pneu inteligente foi bem-sucedida. Esta hipótese pode ser considerada como comprovada, uma vez que foi possível obter valores elevados das métricas de avaliação para ambos os sensores utilizados, com características simples e temporais de baixo custo computacional.

Por meio da aplicação de modelos de classificação, foi possível obter bons resultados para definir em qual tipo de rodovia o pneu está submetido, com base em leitura de sinais gerados a partir de um acelerômetro e também de um PVDF. Para o acelerômetro, o melhor modelo foi o Random Forest com 90% de acurácia em teste. Já o PVDF apresentou dois modelos com acurácia em teste de 97% sendo eles Extra Tree e Gradient Boosting. Com base nos resultados, é possível concluir que o sensor PVDF teve um desempenho melhor se comparado com o acelerômetro nessa aplicação.

A aplicação da técnica LIME na análise de explicabilidade permitiu observar a influência das características sobre cada tipo de rodovia, bem como a possibilidade de uma mesma característica poder influenciar positivamente ou negativamente uma classe, em função do intervalo em que se apresenta.

Trabalhos futuros visarão ampliar a utilização do acelerômetro, comparando a utilização dos seus três

eixos. Outra vertente será o estudo sobre a resolução da aquisição dos dados, se é possível aumentá-la sem perder informação, e consequentemente, melhorando ainda mais o custo computacional associado à extração das características.

V. AGRADECIMENTOS

Agradecimento à FAPEMIG (Fundação de Amparo à Pesquisa do Estado de Minas Gerais), ao CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico) e à CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior) pelos recursos financeiros destinados à execução do projeto.

REFERENCES

- [1] W. Zhao, C. Zhang, and J. Zhang, “Continuous measurement of tire deformation using long-gauge strain sensors,” *Mechanical Systems and Signal Processing*, vol. 142, p. 106782, 2020.
- [2] A. Nepote *et al.*, “The intelligent tire: Acceleration sensors data acquisition,” *SAE Technical Paper*, no. 2005-01-1481, 2005.
- [3] N. Xu, Z. Wang, H. Askari, B. H. G. Barbosa, and A. Khajepour, “Intelligent mobility: Unveiling triboelectric nanogenerator-powered intelligent tire realization,” *Applied Materials Today*, vol. 42, p. 102506, 2025.
- [4] B. H. G. Barbosa *et al.*, “Lateral force prediction using gaussian process regression for intelligent tire systems,” *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, vol. 52, no. 8, pp. 5332–5343, 2021.
- [5] N. Xu *et al.*, “A soft sensor for estimating tire cornering properties for intelligent tires,” *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, vol. 53, no. 10, pp. 6056–6066, 2023.
- [6] Y. Xiong and X. Yang, “A review on in-tire sensor systems for tire-road interaction studies,” *Sensor review*, vol. 38, no. 2, pp. 231–238, 2018.
- [7] H. Askari *et al.*, “Intelligent systems using triboelectric, piezoelectric, and pyroelectric nanogenerators,” *Materials Today*, vol. 52, pp. 188–206, 2022.
- [8] R. C. S. Souza, B. H. G. Barbosa, D. D. Ferreira, and N. Xu, “Estimação da força lateral a partir da seleção de atributos de sinais de aceleração de pneus inteligentes utilizando algoritmos genéticos e SVR,” in *Congresso Brasileiro de Inteligência Computacional*, vol. 1, Salvador, 2023, pp. 1–7, cBIC2023.
- [9] N. Xu, H. Askari, Y. Huang, J. Zhou, and A. Khajepour, “Tire force estimation in intelligent tires using machine learning,” *IEEE Transactions on Intelligent Transportation Systems*, vol. 23, no. 4, pp. 3565–3574, 2020.
- [10] X. Sun *et al.*, “Direct tire slip angle estimation using intelligent tire equipped with pvdf sensors,” *IEEE/ASME Transactions on Mechatronics*, 2024.
- [11] N. Xu *et al.*, “Direct tire slip ratio estimation using intelligent tire system and machine learning algorithms,” *Mechanical Systems and Signal Processing*, vol. 175, p. 109085, 2022.

- [12] Z. Quan *et al.*, “Tire-road friction coefficient estimation method design for intelligent tires equipped with pvdf piezoelectric film sensors,” *Sensors and Actuators A: Physical*, vol. 349, p. 114007, 2023.
- [13] N. V. Chawla *et al.*, “Smote: synthetic minority over-sampling technique,” *Journal of artificial intelligence research*, vol. 16, pp. 321–357, 2002.
- [14] M. Pal, “Random forest classifier for remote sensing classification,” *International journal of remote sensing*, vol. 26, no. 1, pp. 217–222, 2005.
- [15] A. Sharaff and H. Gupta, “Extra-tree classifier with meta-heuristics approach for email classification,” *Advances in Computer Communication and Computational Sciences: Proceedings of IC4S 2018*, 2019.
- [16] P. Cunningham and S. J. Delany, “K-nearest neighbour classifiers-a tutorial,” *ACM computing surveys (CSUR)*, vol. 54, no. 6, pp. 1–25, 2021.
- [17] T. Chen *et al.*, “Xgboost: extreme gradient boosting,” *R package version*, vol. 0.4-2, no. 1.4, pp. 1–4, 2015.
- [18] M.-C. Popescu *et al.*, “Multilayer perceptron and neural networks,” *WSEAS Transactions on Circuits and Systems*, vol. 8, no. 7, pp. 579–588, 2009.
- [19] S. Z. H. Naqvi and M. A. Choudhry, “An automated system for classification of chronic obstructive pulmonary disease and pneumonia patients using lung sound analysis,” *Sensors*, vol. 20, no. 22, p. 6512, 2020.
- [20] M. R. Zafar and N. Khan, “Deterministic local interpretable model-agnostic explanations for stable explainability,” *Machine Learning and Knowledge Extraction*, vol. 3, no. 3, pp. 525–541, 2021.