

Estimação da força lateral a partir da seleção de atributos de sinais de aceleração de pneus inteligentes utilizando algoritmos genéticos e SVR

Rhuan Carlos Silva de Souza

Departamento de Automática

Universidade Federal de Lavras(UFLA)

Lavras, Brasil

rhuan.souza1@estudante.ufla.br

Bruno Henrique Groenner Barbosa

Departamento de Automática

Universidade Federal de Lavras(UFLA)

Lavras, Brasil

brunohb@ufla.br

Danton Diego Ferreira

Departamento de Automática

Universidade Federal de Lavras(UFLA)

Lavras, Brasil

danton@ufla.br

Nan Xu

State Key Laboratory of Automotive Simulation and Control

Jilin University

Jilin, China

xunan@jlu.edu.cn

Resumo: —Pneus inteligentes são pneus que apresentam sensores em sua estrutura capazes de se comunicar com os sistemas de assistência ao motorista (ADAS) para fins de estimação de parâmetros e estados dos veículos. Assim, este trabalho tem como objetivo a seleção de atributos relacionados com os sinais de aceleração triaxial utilizando algoritmos genéticos e um modelo de aprendizagem de máquina, *Support Vector Regression* (SVR), para estimação da força lateral, variável de suma importância para o controle de estabilidade dos veículos. A abordagem proposta conseguiu obter um modelo com erro percentual e coeficiente de determinação, respectivamente, iguais a 15,99% e 93%, estimando a força lateral de maneira satisfatória.

Index Terms—pneu inteligente; support vector, regression, algoritmo genético, força lateral

I. INTRODUÇÃO

Os pneus atuais são considerados estruturas passivas em veículos, ou seja, são projetados e testados de forma rigorosa para que sejam capazes de sofrer ações externas e conferir segurança, controlabilidade e conforto aos ocupantes dos veículos. No entanto, não há nenhuma troca de informações ou estado dos pneus para o sistema de assistência ao motorista (ou *driver assistance system* ou ADAs) [1]. Assim, existe a necessidade de os pneus se tornarem cada vez mais ativos no processo de controle de um veículo, surgindo os pneus inteligentes [2].

Os pneus inteligentes apresentam sensores acoplados à sua estrutura, logo, são estruturas ativas, já que se comunicam com o ADAs e participam ativamente na estimação de parâmetros e estados presentes na interface pneu-solo [3], podendo melhorar a controlabilidade do veículo. O processo de estimação de parâmetros no uso de pneus inteligentes pode-se basear na modelagem cinemática, este tipo de modelagem tem como foco utilizar a relação cinemática existente entre o veículo e o sinal medido pelo o sensor presente nos pneus para determinar os parâmetros desejados na região de interface pneu-solo [4],

logo, não há um conhecimento *a priori* sobre os parâmetros e estados do veículo e o solo em que o pneu se encontra [2]. O processo de construção de um modelo de estimação pode-se utilizar da modelagem caixa-preta, ou seja, é construído um modelo a partir dos sinais de entrada e de saída que se deseja estimar e, nessa modelagem, não há conhecimento sobre o sistema que a partir dos dados de entrada gerou a saída [5], assim sendo, para o presente trabalho, não se conhece as partes que constituem o sistema gerador da saída, por exemplo: a estrutura do pneu, das relações dinâmicas e cinemáticas presentes na interação pneu-solo, tipo do solo e entre outras características.

O processo de estimação de estados pelo sistema de assistência ao motorista, ao utilizar os pneus inteligentes, apresenta como vantagem o não conhecimento de parâmetros e estados iniciais do veículo [6]. No entanto, a identificação dos modelos a partir de sinais provenientes de sensores são afetadas pelos ruídos e vieses inerentes aos sensores utilizados em situações reais [7].

Assim, este trabalho tem como contribuição a proposição de uma metodologia para identificação de modelo caixa-preta para prever as forças laterais presentes na região de interface pneu-solo utilizando sinais provenientes de um acelerômetro acoplado a um pneu a partir de atributos selecionados por um algoritmo genético.

Este artigo está organizado da seguinte forma. A descrição do problema estudado e as ferramentas utilizadas são apresentados na Seção II; os materiais e métodos empregados são descritos na Seção III; os resultados obtidos e discussões são apresentados na Seção IV; e, por fim, a Seção V indica possíveis trabalhos futuros.

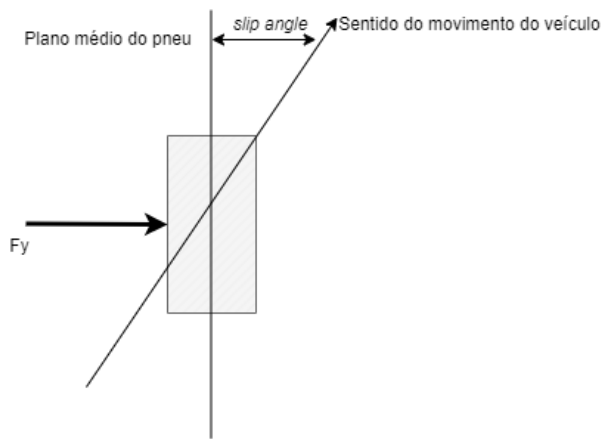


Fig. 1. Força lateral e ângulo de deriva de um pneu, adaptado de [9].

II. FUNDAMENTAÇÃO TEÓRICA

A. Força Lateral

O pneu na região de interface pneu-solo apresenta três forças: a força longitudinal (F_x), a força lateral (F_y) e a força axial (F_z). Estas forças estão presentes, respectivamente, nos eixos x , y e z da interface pneu-solo em seu plano tridimensional [8].

A força lateral (F_y) é um tipo força que ocorre sobre os pneus de um veículo para manter o equilíbrio dinâmico e para que o veículo permaneça na trajetória. A presença desta força ocasiona uma deformação no pneu que altera seu sentido de movimento em relação à trajetória do veículo, ou seja, em relação ao eixo x , surgindo o ângulo de deriva ou *slip angle* [8], como pode ser observado na Figura 1. Assim, é possível notar a importância da estimação da força lateral para uma possível melhora do conforto e segurança dos passageiros.

A força lateral depende de fatores como as características construtiva do pneu (largura, tamanho, tipo de pneu) e a carga e pressão interna em cada um dos pneus do veículo [9]. Entre estes fatores mencionados, a força lateral possui uma forte dependência com a força axial do pneu ao longo do percurso, consequentemente, afetando o equilíbrio dinâmico do veículo em sua trajetória, principalmente em trajetórias curvas [9].

Em [10] e [11] é realizada a estimação de forças por meio de um acelerômetro triaxial acoplado ao pneu. No primeiro, os autores utilizam os sinais de aceleração provenientes do eixo x , y e z e *Gaussian Process Regression*, um método de aprendizagem de máquina, para prever a força lateral presente no pneu do veículo com intervalo de confiança, sendo este intervalo útil para melhorar projetos de controladores de veículos. Já o modelo de estimação utilizado por [11] tem como foco o uso de diferentes métodos de aprendizagem de máquina para estimar as forças lateral, axial e longitudinal presentes no pneu ao entrar em contato com o solo.

B. Algoritmos Genéticos

Os algoritmos genéticos são algoritmos bio-inspirados, na qual se inspiram no processo de seleção natural teorizado

e proposto por Charles Darwin [12]. A seleção natural é um processo em que os indivíduos mais aptos sobrevivem, reproduzem e evoluem em um determinado bioma ao longo de gerações.

Portanto, os algoritmos genéticos são uma técnica largamente utilizada para problemas de otimização, pois definem, a partir de uma função custo a ser minimizada ou maximizada, um indivíduo (solução) mais apto, ou seja, em que apresenta um resultado ótimo ou sub-ótimo para a função custo [13]. Assim, os algoritmos genéticos possuem as seguintes etapas que os caracterizam:

- **Inicialização da população:** inicia-se a população de indivíduos, em que cada indivíduo é uma representação cromossômica, em que determinadas partes do cromossomo (genes) representam uma variável ou atributo de uma função custo a ser minimizada ou maximizada. O cromossomo é uma possível solução dessa função podendo possuir uma representação binária, ou seja, constituída de 0 e 1, sendo a forma de representação mais simples e utilizada [14];
- **Avaliação:** avalia-se cada indivíduo a partir de uma função custo ou de aptidão, em que a partir do resultado é determinado o indivíduo mais apto a ser selecionado [14];
- **Seleção:** nesta etapa são definidos os indivíduos mais aptos a cruzar, assim, gerar novos indivíduos para uma próxima geração. Para exemplificar o processo de seleção, pode-se citar o método de seleção por torneio, em que este método tem como objetivo determinar a partir de dois ou mais indivíduos o mais apto para o procedimento de cruzamento [15], [16];
- **Cruzamento:** esta etapa consiste em cruzar dois indivíduos ou mais selecionados a partir de uma definição de probabilidade de cruzamento. O processo de cruzamento é bastante relevante pois ele possibilita a troca de informação genética entre indivíduos da população e favorece o processo de convergência e obtenção de soluções ótimas [16];
- **Mutação:** essa etapa ocorre somente após ao cruzamento, ou seja, na obtenção de novos indivíduos existe a possibilidade de genes destes indivíduos sofrerem mutação, por exemplo, o bit 0 se tornar 1 e vice-versa. O processo de mutação na natureza ocorre com menos frequência, assim, a probabilidade de mutação nos algoritmos genéticos tende a ser menor que a de cruzamento [17]. Essa etapa é importante para manter a diversidade genética na população [14];
- **Atualização da população:** após as etapas supracitadas, a população é atualizada para a próxima geração. Este processo de atualização da população pode conter somente os novos indivíduos ou uma combinação de novos e indivíduos de gerações anteriores [14].

C. Support Vector Regression(SVR)

Support Vector Regression (SVR) é uma extensão do *Support Vector Machine (SVM)*, em que ambos os métodos são algorit-

mos de aprendizagem de máquina supervisionado, ou seja, os modelos são construídos a partir de observações conhecidas, y_i e sua respectiva entrada x_i para $i = 1, 2, 3, 4, \dots, N$ [18]. O SVR, é um método de regressão que tem como objetivo obter uma função linear $f(x) = b + wx$ que minimize os dados de entrada x e de saída y , em que apresenta boa generalização, ou seja, para determinados conjuntos de dados que apresentam *outliers* os modelos não sofrem *overfitting*, isto é, criação de modelos robustos que se ajustam a ocorrência desses dados [19].

A boa generalização é devido ao fato de que a função $f(x)$ a ser estimada é equilibrada pela função objetivo do problema de otimização que define o comportamento do SVR, expresso pela seguinte relação [20], [21]:

$$\begin{aligned} \min \quad & \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) \\ \text{s.t.} \quad & y_i - wx_i - b \leq \epsilon + \xi_i, \\ & wx_i + b - y_i \leq \epsilon + \xi_i^*, \\ & \xi, \xi_i^* \geq 0 \end{aligned} \quad (1)$$

em que:

- C , é a variável de penalidade;
- w , coeficiente angular de $f(x)$;
- b , coeficiente linear de $f(x)$;
- ϵ , variável de precisão da função de regressão a ser estimada;
- ξ^* e ξ , variável de folga.

III. MATERIAIS E MÉTODOS

Os materiais e métodos para obtenção dos resultados são descritos nesta seção.

A. Materiais

Esta seção detalhará o conjunto de dados e linguagem de programação utilizadas.

1) *Dataset*: O conjunto de dados usado neste trabalho é composto por valores medidos provenientes de ensaios realizados com pneus em uma plataforma de testes MTS Flat-Trac, conforme descrito em [10] e apresentado na Figura 2. Os ensaios foram realizados com diferentes velocidades do pneus (30 e 60 km/h), variando o ângulo de deriva entre -8° e 8° e com diferentes cargas aplicadas (2080 N, 4160 N e 6240 N). Este conjunto é composto por 1.796.122 amostras obtidas com uma taxa de amostragem de 10 kHz com 5 variáveis, como pode ser visto na Tabela I.

Os sinais de aceleração, medidos por uma placa de aquisição NI-DAQ, explicitados na Tabela I, possuem duas regiões para cada ciclo do pneu: uma que corresponde ao percurso do acelerômetro dentro da região onde o pneu está em contato com a superfície, chamada de *contact patch*, e outra com dados de medição de aceleração fora da região de contato, conforme pode ser visto na Figura 3.

2) *Linguagem de programação*: A linguagem de programação utilizada neste trabalho é a linguagem Python 3.8, utilizando o *Pycharm* 2021.1 como ambiente de desenvolvimento para a implementação do algoritmo em um *notebook Dell* com um processador *Intel Core i5*.

B. Metodologia

Esta seção descreve os processos realizados para seleção de atributos utilizando os algoritmos genéticos e o SVR. A Figura 4 apresenta o fluxograma da metodologia implementada.

1) *Obtenção de janelas de dados de um ciclo completo*: A partir dos valores da variável *tag* são obtidas as janelas que correspondem a um ciclo completo do pneu. A volta completa do pneu nesta etapa corresponde à uma faixa de valores anterior e após a região de contato, como pode ser observado na Figura 5.

2) *Filtro passa-baixa de 400Hz*: Aplica-se uma filtro passa-baixa Butterworth de ordem 2 com frequência de corte igual a 400 Hz para eliminar ruídos em falta frequência.

3) *Codificação das janelas de dados*: Este passo consiste em obter os dados de entrada e os atributos para, assim, ser submetido ao processo de seleção de atributos e na construção do modelo de aprendizagem de máquina. O processo consiste em codificar os sinais de aceleração a_x , a_y e a_z para que cada ponto dentro da janela de dados corresponda à 0.5° . A partir da codificação são obtidos 720 pontos, equivalente à 0° à 360° , para cada sinal de aceleração. Os sinais de aceleração são concatenados após o processo descrito, como pode ser observado na Figura 6. Portanto, a partir da codificação, os sinais são independentes do tempo e cada uma das 720 amostras de aceleração são possíveis atributos a serem usados no modelo de aprendizagem de máquina.

4) *Seleção de atributos*: O processo de seleção visa obter os atributos a partir dos sinais de aceleração codificados que reduzem o erro *NRMSE* (*Normalize Root Mean Square Error*) de predição ao utilizar os dados de teste no modelo *Support Vector Regression* construído a partir dos dados de treinamento:

$$NRMSE(\%) = 100 \frac{\sqrt{\frac{1}{N} \sum_{k=1}^N (y_k - \hat{y}_k)^2}}{y_{max}} \quad (2)$$

em que y_k é a força lateral medida na janela k e \hat{y}_k é a força predita pelo modelo a partir da seleção de atributos definida pelo indivíduo (cromossomo).

TABLE I
DESCRIÇÃO DOS DADOS.

Sinais	Significado
$a_x(g)$	aceleração no eixo x (m/s^2)
$a_y(g)$	aceleração no eixo y (m/s^2)
$a_z(g)$	aceleração no eixo z (m/s^2)
$F_y(g)$	Força lateral(N)
tag	Sinal que indica o acelerômetro percorrendo o <i>contact patch</i>

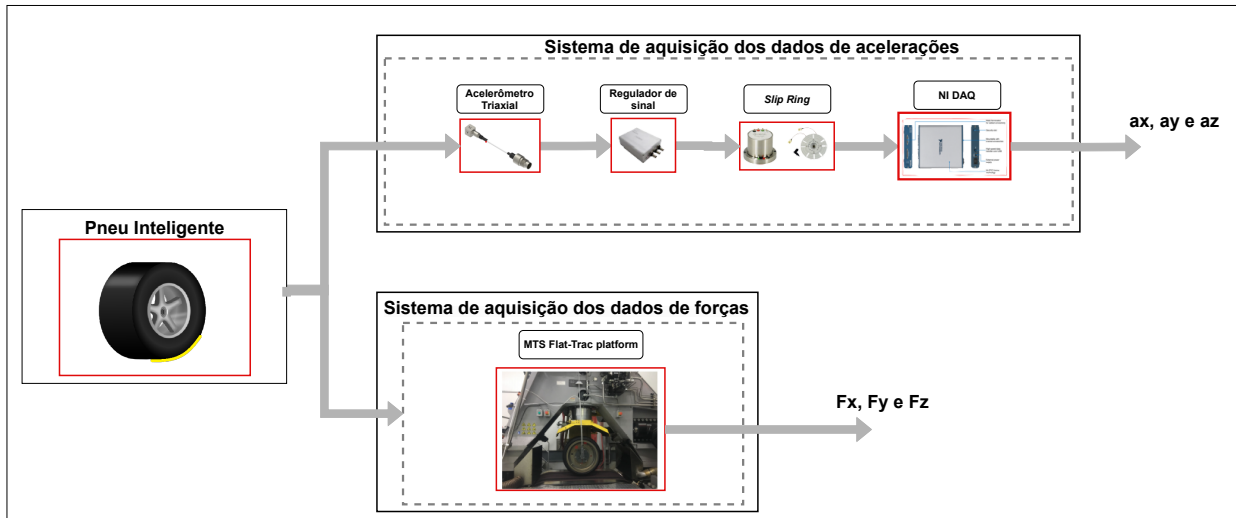


Fig. 2. Sistema de testes e aquisição de dados de pneus inteligentes, em que a região em amarelo no pneu indica a localização do sensor acoplado ao pneu. Fonte: Adaptado de [10]




Fig. 3. Janelas de dados dentro e fora da região de contato. As áreas que estão fora da região tracejada correspondem à região dentro do *contact patch* onde a variável *tag* recebe o valor unitário. Fonte: autor

Para o processo de seleção os dados de treinamento e de teste correspondem a 70% e 30%, respectivamente, dos dados codificados e da força lateral dentro da região de contato.

O algoritmo 1 apresenta o processo de seleção utilizado para obter o melhor indivíduo em tempo de execução de 5 horas.

O algoritmo 1 apresenta as seguintes características:

- A função **SVR** é o modelo *Support Vector Regressor* a ser treinado e testado para obtenção do NRMSE, em que o modelo utilizado para o processo de seleção possui a tolerância ao erro, ϵ e número de iterações iguais, respectivamente, a 10^{-4} , 0 e 1500.
- A probabilidade de cruzamento varia linearmente ao longo do processo de seleção indicado pela **FuncaoLinear**, para evitar a convergência prematura do algoritmo

a probabilidade de cruzamento é reduzida ao longo das gerações e a probabilidade de mutação é aumentada ($1 - p_c$), logo, aumentando a diversidade da população ao longo das gerações;

- A técnica de cruzamento, representada pela função **Cruzamento** utilizada é a de *crossover* uniforme [22], conforme apresentado na Figura 7

5) *Análise do modelo implementado*: O processo de análise é verificar e inferir sobre o desempenho da métrica de avaliação ao longo das gerações do método de seleção de atributos. Por fim, comparar o modelo SVR treinado com os atributos selecionados pelos algoritmos genéticos com um modelo SVR treinado usando todos os atributos, sendo esta comparação realizada a partir da métrica de avaliação e pelo coeficiente de determinação r^2 , para determinar quão bem o modelo SVR construído se ajusta a novas amostras de dados, no caso o conjunto de dados de testes.

IV. RESULTADO E DISCUSSÃO

A partir da metodologia descrita são obtidas 1145 janelas de dados correspondendo a um ciclo completo para as acelerações nos eixos x, y e z. Assim, após o processo de codificação é obtido um conjunto de dados com a dimensão de 1145 x 2160, na qual este conjunto é aplicado como entrada do algoritmo proposto em 1, juntamente com a força lateral, um conjunto de dados de dimensão 1445 x 1, que é o valor a ser estimado pelo modelo SVR.

A Figura 8 apresenta os resultado do algoritmo de seleção implementado para um tempo de execução igual a 5 horas. Pode se notar pelo gráfico apresentado que ao longo das gerações foi possível selecionar atributos que reduzissem o NRMSE ao longo das gerações, encontrando o melhor valor igual a 15,99%.

A quantidade de atributos selecionados a_x , a_y e a_z foram de 350, 355 e 355, respectivamente, para o melhor indivíduo, en-

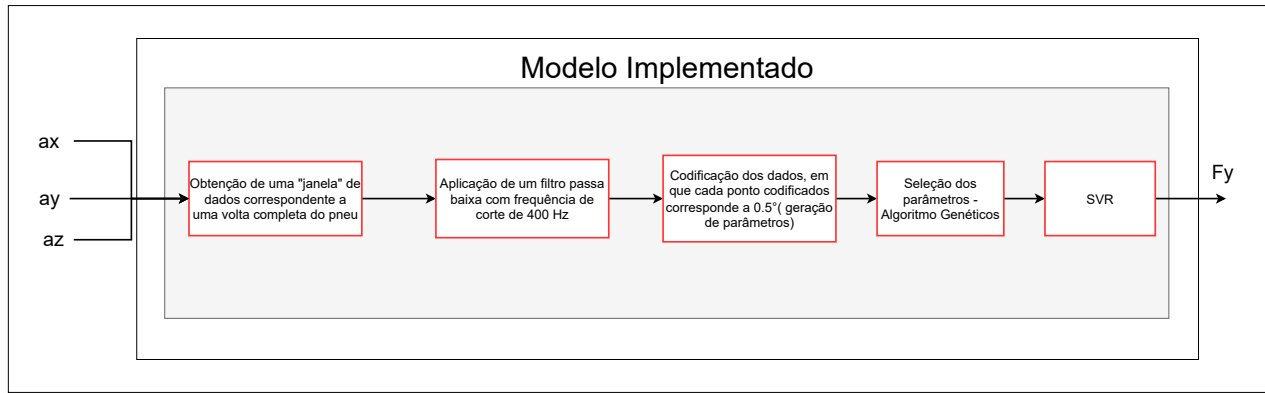


Fig. 4. Fluxograma da metodologia implementada. Fonte: autor




Fig. 5. Definição de um ciclo completo do pneu, a partir dados dentro e fora da área de contato. Os sinais dentro da área tracejada correspondem a um ciclo completo do pneu. Fonte: autor

contrado na geração 40. Pelas quantidades de atributos obtidos para cada sinal, é possível notar que a predição da força lateral é influenciada pelo uso tanto de sinais de fora quanto de dentro da região de contato, devido aos ângulos selecionados estarem distante do centro da região de contato, que corresponde ao ângulo de 180° . Outro fato observado é que a quantidade de atributos selecionados são semelhantes para as diferentes acelerações, o que corrobora o trabalho apresentado em [10] em que observou-se que as três acelerações são importantes para a predição da força lateral.

Por fim, é analisado o desempenho do algoritmo SVR implementado para o conjunto de dados com todos atributos e com os atributos selecionados pelo melhor indivíduo encontrado, em que é obtido os valores de NRMSE, respectivamente, de 28,17% e 15,99%. Os valores de coeficiente

Algorithm 1 Algoritmo de seleção implementado

```

1: Inputs:  $\lambda$ ,  $N$ ,  $p_{c_{inicial}}$ ,  $p_{c_{final}}$ ,  $F_y$ ,  $X_{cod}$ 
2: Outputs:  $pop_{attr_{best}}$ 
3:  $pop_{attr} \leftarrow Population(\lambda)\{\text{População de tamanho } \lambda \text{ de atributos}\}$ 
4:  $generation \leftarrow 0$ 
5: while  $CriteriaodeParada() == True$  do
6:    $p_c$  gets FuncaoLinear( $p_{c_{inicial}}$ ,  $p_{c_{final}}$ )
7:   while  $avaliacao \leq \lambda$  do
8:      $NMRSE \leftarrow SVR(pop_{attr}, X_{cod}, F_y)$ 
9:      $avaliacao \leftarrow Avalia(NMRSE)$ 
10:  end while
11: while  $novoPop_{attr} \leq \lambda$  do
12:    $pai_1 \leftarrow SelecaoTorneio(pop_{attr}, avaliacao)$ 
13:    $pai_2 \leftarrow SelecaoTorneio(pop_{attr}, avaliacao)$ 
14:    $r \leftarrow Aleatorio()$ 
15:   if  $r \leq p_c$  then
16:      $filho_1 \leftarrow Cruzamento(pai_1, pai_2)$ 
17:      $filho_2 \leftarrow Cruzamento(pai_1, pai_2)$ 
18:      $m \leftarrow Aleatorio()$ 
19:     if  $m \leq 1 - p_c$  then
20:        $filho_1 \leftarrow Mutacao(filho_1)$ 
21:        $filho_2 \leftarrow Mutacao(filho_2)$ 
22:     end if
23:   end if
24:    $novoPop_{attr} \leftarrow Atualiza(filho_1, filho_2)$ 
25: end while
26:  $pop_{attr} \leftarrow novoPop_{attr} + Bests(pop_{attr})$ 
27:  $generation \leftarrow generation + 1$ 
28: end while=0
    
```

de determinação encontrados são, respectivamente, iguais a 0,77 e 0,93. Dessa forma, pode-se concluir que a etapa de seleção de atributos foi importante para a obtenção de um modelo de aprendizagem SVR com melhor resultado, como é demonstrado na Figura 9.




Fig. 6. Demonstração do processo de codificação para obtenção dos atributos e dados de entrada.




Fig. 7. Cruzamento uniforme. O método consiste em determinar a distribuição das porções que cada indivíduo filho receberá dos indivíduos pais, por exemplo, o Filho 1 recebe a porção vinda do Pai 2 se a distribuição possuir valor igual a 0, caso a contrário a porção virá do Pai 1. Fonte: adaptado de [22]

V. CONCLUSÃO

Observou-se que os sinais de aceleração, de acordo com os melhores atributos selecionados, fora da região de contato influenciam a predição da força lateral presente na região de contato. O processo de estimação com o SVR e um seletor de atributos por meio dos algoritmos genéticos teve o melhor resultado ao encontrar um erro de 15.99% e que este modelo construído é capaz de explicar 93% para novas amostras de dados ao comparar os resultados com conjunto de dados com todos os atributos.

Para trabalhos futuros é necessário utilizar um critério de parada que não dependa exclusivamente do tempo de execução, ou utilizar outras técnicas bio-inspiradas ou modelos de regressão que reduzam o tempo de execução.

AGRADECIMENTOS

Agradecimento à FAPEMIG (Fundação de Amparo à Pesquisa do Estado de Minas Gerais), ao CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico), CAPES(Coordenação de Aperfeiçoamento de Pessoal de Nível Superior) e à UFLA (Universidade Federal de Lavras) pelos recursos financeiros destinados e toda a infraestrutura necessária para execução do projeto.

REFERENCES

[1] M. Q. Khan and S. Lee, “A comprehensive survey of driving monitoring and assistance systems,” *Sensors*, vol. 19, no. 11, p. 2574, 2019.

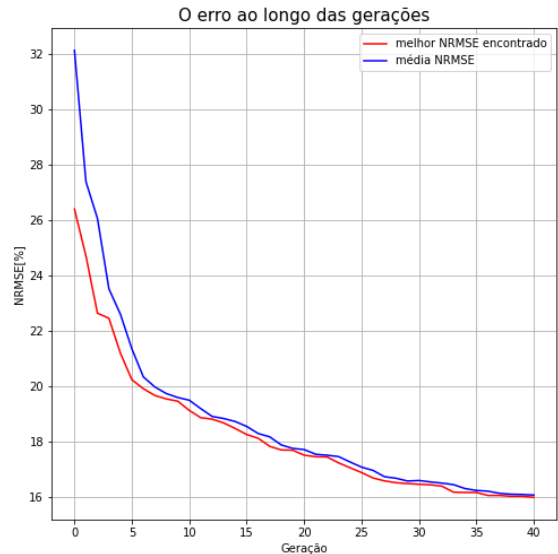


Fig. 8. Evolução do algoritmo de seleção ao longo das gerações. A curva em azul representa o erro médio da população ao longo das gerações e a curva vermelha representa o erro do melhor indivíduo encontrado em cada geração. Fonte: autor

[2] H. Guo, Z. Yin, D. Cao, H. Chen, and C. Lv, “A review of estimation for vehicle tire-road interactions toward automated driving,” *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, vol. 49, no. 1, pp. 14–30, 2019.

[3] H. Lee and S. Taheri, “Intelligent tires? a review of tire characterization literature,” *IEEE Intelligent Transportation Systems Magazine*, vol. 9, no. 2, pp. 114–135, 2017.

[4] T. Gräber, S. Lupberger, M. Unterreiner, and D. Schramm, “A hybrid approach to side-slip angle estimation with recurrent neural networks and kinematic vehicle models,” *IEEE Transactions on Intelligent Vehicles*, vol. 4, no. 1, pp. 39–47, 2019.

[5] L. Aguirre, *Introdução à Identificação de Sistemas – Técnicas Lineares e Não-Lineares Aplicadas a Sistemas Reais*. Editora UFMG, 2007.

[6] D. Jeong, S. B. Choi, J. Lee, M. Kim, and H. Lee, “Tire dimensionless numbers for analysis of tire characteristics and intelligent tire signals,” *Mechanical Systems and Signal Processing*, vol. 161, p. 107927, 2021.




Fig. 9. Secção do comparativo da força lateral estimada a partir da metodologia implementada e da força lateral medida (F_y). Fonte: autor

Academic Press, 2020, pp. 123–140. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/B9780128157398000079>

- [20] M. Awad, R. Khanna, M. Awad, and R. Khanna, “Support vector regression,” *Efficient learning machines: Theories, concepts, and applications for engineers and system designers*, pp. 67–80, 2015.
- [21] Z. Liao, S. Dai, and T. Kuosmanen, “Convex support vector regression,” *European Journal of Operational Research*, 2023.
- [22] W. M. Spears and K. D. De Jong, “On the virtues of parameterized uniform crossover,” Naval Research Lab Washington DC, Tech. Rep., 1995.

[Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0888327021003228>

- [7] K. B. Singh, M. A. Arat, and S. Taheri, “Literature review and fundamental approaches for vehicle and tire state estimation*,” *Vehicle System Dynamics*, vol. 57, no. 11, pp. 1643–1665, 2019.
- [8] R. Rajamani and R. Rajamani, “Lateral and longitudinal tire forces,” *Vehicle dynamics and control*, pp. 355–396, 2012.
- [9] T. D. Gillespie, *Fundamentals of vehicle dynamics*. Warrendale, PA: Society of Automotive Engineers, Inc, 1992.
- [10] B. H. G. Barbosa, N. Xu, H. Askari, and A. Khajepour, “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, 2022.
- [11] 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, 2022.
- [12] M. Kumar, D. M. Husain, N. Upreti, and D. Gupta, “Genetic algorithm: Review and application,” *Available at SSRN 3529843*, 2010.
- [13] S. Sivanandam, S. Deepa, S. Sivanandam, and S. Deepa, “Genetic algorithm optimization problems,” *Introduction to genetic algorithms*, pp. 165–209, 2008.
- [14] B. Alhijawi and A. Awajan, “Genetic algorithms: Theory, genetic operators, solutions, and applications,” *Evolutionary Intelligence*, pp. 1–12, 2023.
- [15] A. Shukla, H. M. Pandey, and D. Mehrotra, “Comparative review of selection techniques in genetic algorithm,” in *2015 International Conference on Futuristic Trends on Computational Analysis and Knowledge Management (ABLAZE)*, Feb 2015, pp. 515–519.
- [16] S. Mirjalili and S. Mirjalili, “Genetic algorithm,” *Evolutionary Algorithms and Neural Networks: Theory and Applications*, pp. 43–55, 2019.
- [17] I. De Falco, A. Della Cioppa, and E. Tarantino, “Mutation-based genetic algorithm: performance evaluation,” *Applied Soft Computing*, vol. 1, no. 4, pp. 285–299, 2002.
- [18] A. J. Smola and B. Schölkopf, “A tutorial on support vector regression,” *Statistics and Computing*, vol. 14, no. 3, pp. 199–222, 2004.
- [19] F. Zhang and L. J. O’Donnell, “Chapter 7 - support vector regression,” in *Machine Learning*, A. Mechelli and S. Vieira, Eds.