

## 1 Introdução

O conceito de “Indústria 4.0” simboliza o início da quarta revolução industrial. Foi apresentada como uma iniciativa estratégica para aumentar a competitividade alemã na indústria de transformação, com o objetivo de transformar a produção industrial por meio da digitalização e aproveitamento do potencial das novas tecnologias (Kropivšek & Grošelj, 2020). Na prática, é um conceito abrangente que envolve soluções para conectar fábricas e componentes por meio de dados (Chiu, Tsai, & Li, 2020).

A Indústria 4.0 combina várias tecnologias como o aprendizado de máquina, análise de *big data*, sistemas ciberfísicos, internet das coisas, realidade virtual e realidade aumentada. Tecnologias essas, que são utilizadas para automatizar o processo de produção, otimizar produtos, reduzir custos e desperdício de energia. Além disso, fornecem informações úteis, analisando os dados coletados de diferentes aspectos, incluindo equipamentos, processos, atividade de trabalho e condições ambientais. (Kotsiopoulou, Sarigiannidis, Ioannidis, & Tzovara, 2021; Zhang, Chen, Chen, & Chong, 2021).

O resultado dessa integração de tecnologias resulta no desenvolvimento de fábricas inteligentes, ou seja, altamente eficientes na utilização de recursos e que se adaptam rapidamente às metas de gestão e aos cenários dinâmicos da indústria (Kamble, Gunasekaran, & Gawankar, 2018; Ortt, Stolwijk, & Punter, 2020). A Indústria 4.0 proporciona melhorias e evidencia novos modelos de negócios para satisfazer demandas emergentes de customização de produtos por meio de controle e gerenciamento de processos inteligentes (Silvestri, Forcina, Introna, Santolamazza, & Cesarotti, 2020).

Entretanto, na interface homem-máquina, os seres humanos ainda atuam de forma predominante e sobressalente, interconectando os ambientes da Indústria 4.0. Capacitados com dispositivos inteligentes, realidade virtual e aumentada, estão aptos a usufruir das vantagens da inteligência artificial e do aporte de aprendizados de máquinas. Assim, a Indústria 4.0 promete beneficiar os *stakeholders* auxiliando os gestores em tomadas de decisões oportunas, reduzir riscos, aumentar a produtividade, personalizar o atendimento aos consumidores e promover a sustentabilidade ambiental (Abdirad & Krishnan, 2020; Angelopoulos et al., 2019).

Desse modo, a Floresta 4.0 foi inserida no cenário mundial, acompanhando a tendência dos demais setores industriais. Caracteriza-se pelo uso de tecnologias para gestão de dados e ativos florestais. Consolida maior eficiência para o processo produtivo florestal em todas as suas etapas. Sobretudo, o avanço tecnológico permite a automação dos equipamentos, geração de dados para o monitoramento e controle, permitindo uma tomada de decisão segura, ágil e assertiva (Santos, 2019).

A Floresta 4.0 é a ênfase da digitalização ponta a ponta de todos os ativos físicos da cadeia de abastecimento florestal, para se tornarem digitalmente conectados e operacionalmente integrados com fornecedores, clientes e parceiros em um ecossistema digital. Portanto, a indústria florestal é direcionada para a digitalização total de seus processos, automatizando com precisão o gerenciamento florestal, tornando-o inteligente e conectado (Feng & Audy, 2020).

## 2 Referencial Teórico

A operação de transporte rodoviário de madeira consiste na movimentação das toras da floresta ou indústria até o local de consumo por meio de veículos pesados e extrapesados (Guimarães, Arce, Fiedler, & Robert, 2016). O custo com transporte de madeira é um dos principais fatores que influenciam economicamente os projetos florestais, em razão de uma grande parte das florestas plantadas estarem situadas distantes dos centros consumidores (Lachini et al., 2018; Schettino, Minette, Schettino, & Reboletto, 2018).

O modal de transporte rodoviário é predominante nas indústrias de produtos florestais (Koirala, Kizha, & Roth, 2017). Com isso, pesquisas relacionadas ao transporte de madeira têm se tornado indispensável para o aumento da eficiência operacional e redução dos custos de produção, contribuindo para a melhoria do processo produtivo e maior competitividade das empresas florestais (Tymendorf & Grzegorz, 2020b; Virgens, Freitas, & Silva, 2021).

Existem diversos fatores que influenciam o custo e a eficiência do transporte de cargas pelo modal rodoviário. Dentre eles, destacam-se os tipos de veículos, a capacidade de carga, a distância de transporte, a conservação das estradas, o preço do combustível, impostos, seguros e o valor unitário do frete (Abreu & Schinaider, 2020; Diniz *et al.*, 2019; Endo, Brandalise, & Leismann, 2021).

As características da madeira também impactam na eficiência do transporte rodoviário como a densidade, espécie, tamanho, volume, origem e destino de processamento da madeira (Keramati, Lu, Sobhani, & Esmaeili, 2020; Tymendorf & Grzegorz, 2020a). A umidade da madeira transportada, também influenciada pelo tempo de permanência das toras no campo após a colheita, interfere na eficiência do transporte por ser fator determinante na massa transportada (Rodrigues, 2018; Strandgard, Taskhiri, Acuna, & Turner, 2021).

Um dos gargalos do transporte rodoviário de madeira é a massa líquida das combinações veiculares de carga (CVC). O excesso de carga acarreta na degradação da pavimentação, desgaste precoce do veículo, multas de fiscalização, além de contratempos de remanejamento da carga excedente (Costa, Aguiar, Gama, & Fonseca, 2021; Romeiro *et al.*, 2020). O excesso de carga ainda eleva o gasto de combustível e lubrificante, amplia a necessidade de espaço para frenagem aumentando a probabilidade de acidentes (Rocha, Borba, & Lobo, 2020).

A competitividade do transporte rodoviário tem sido baseada na otimização de altas cargas líquidas de veículos, tornando a CVC em uma variável chave para essa questão (Palander, 2017). Para solucionar essa demanda, a aprendizagem de máquina é uma alternativa viável, pois demonstrou eficiência na elucidação de outras demandas do transporte rodoviário como descritos nos trabalhos de Alomari, Katib, Albeshri, Yigitcanlar e Mehmood (2021); Balster, Hansen, Friedrich e Ludwig (2020); Dai, Chen e Zhou (2021); Ghandour, Hammoud e Al-Hajj (2020); Wu *et al.* (2020).

Os métodos de aprendizado de máquina são técnicas que automatizam o desenvolvimento de modelos analíticos. Utilizando algoritmos que aprendem interativamente, é possível encontrar respostas e ou representações ocultas sem serem explicitamente programados (Machado, Assis, & Pereira, 2020). Esses algoritmos variam nos seus objetivos, na disponibilidade de dados de treinamento, nas estratégias de aprendizagem e na linguagem empregada (Jamal *et al.*, 2021; Lopes & Pereira, 2020).

Dentre os modelos de aprendizagem de máquinas destacam-se: Árvores de Decisão, Redes Neurais Artificiais, Máquinas de Vetores e Algoritmo de Aprendizado (Mascarenhas, Moriel, Gomes, & Mello, 2020). A técnica de aprendizado de máquinas é aplicada principalmente para aproximação de funções, classificação e reconhecimento de padrões (Xu, Saleh, & Hatzopoulou, 2020; Karballaezadeh *et al.*, 2020).

Diante disto, verificamos se a associação entre algoritmos de aprendizado de máquina com um banco de dados de controle de transporte rodoviário de madeira promove a predição da massa líquida de madeiras transportadas por combinações veiculares de carga.

### 3 Metodologia

#### 3.1 Dataset

O conjunto de dados utilizado foi proveniente de registros de monitoramento de transporte rodoviário de madeira, por uma indústria de base florestal do segmento de celulose branqueada de fibra curta de *Eucalyptus*, localizada no Uruguai.

Faziam parte dos registros, as seguintes variáveis numéricas: idade das florestas plantadas com *Eucalyptus*, o tempo pós corte da madeira em campo e a densidade da madeira. A variável categórica analisada foi para a combinação veicular de carga (CVC) caracterizada por conter um caminhão trator trucado com um semirreboque, a qual transportava madeiras com 4,80m de comprimento. Além disto, o *dataset* avaliado era composto por 1.622 registros.

#### 3.2 Análise de regressão para estimativa da massa líquida

Foram utilizados algoritmos de aprendizado de máquina supervisionado para estimar a massa líquida de madeiras transportadas por combinações veiculares de carga (CVC). Deste modo, em um *dataset* composto por três variáveis regressoras, testou-se a importância relativa das variáveis, por meio do algoritmo de *random forest*, a fim de identificar aquelas que promovem a pureza do nó, ou seja, a precisão do modelo eleito.

Logo, as variáveis que impactaram na formulação do modelo, foram mantidas na análise de regressão. Portanto, os algoritmos relacionados para estimativa da massa líquida das CVC foram o *random forest*, o *support vector machine* e o *K Nearest Neighbor*.

##### 3.2.1 Random Forest

Por sua eficácia amplamente comprovada, o algoritmo de *random forest* apresenta aplicação recorrente como regressor de variáveis *target* (Chen, Zheng, Li, & Huang, 2021). Deste modo, por meio do *software* R (R Development Core Team, 2021), pacote *randomForest*, deu-se a implementação do algoritmo no conjunto de dados, com a geração de 500 árvores aleatórias.

##### 3.2.2 Support Vector Machine

A implementação do algoritmo de *support vector machine* deu-se por meio do *software* R (R Development Core Team, 2021), pacote *e1071*, atributo de *Kernel* radial. O algoritmo mapeou os dados em um espaço dimensional superior, isto é, espaço futuro e construiu um hiperplano de separação ideal neste espaço (Kaytez, 2020). Destarte, isto faz com que problemas de *overfitting* e *underfitting* sejam minimizados.

##### 3.2.3 K Nearest Neighbor

O algoritmo de *K nearest neighbor* (KNN) foi implementado por meio do pacote *caret*, no *software* R (R Development Core Team, 2021), com a ponderação da distância euclidiana.

Conforme descrito por Lubis, Lubis e Khowarizmi (2020), o algoritmo atuou na base em dados de aprendizagem que estão mais próximos do objeto com base na comparação entre dados anteriores e atuais, sendo que, no processo de aprendizagem. Logo, o KNN norteou-se por meio de distâncias dos vizinhos mais próximos, aplicando a distância euclidiana.

#### 3.3 Particionamento dos dados e performance dos algoritmos

Utilizando-se do método *hold-out*, o conjunto de dados foi particionado em 80% para treinamento e 20% para teste. Contudo, a fim de evitar *overfitting* e *underfitting*, promoveu-se a técnica de validação cruzada no conjunto de dados de treinamento, por meio de 10

subconjuntos, mutuamente exclusivos de igual tamanho. Destarte, a validação cruzada permitiu uma melhor análise de desempenho (Agostini & Sampaio, 2020).

Consequente, para avaliação dos algoritmos implementados no conjunto de dados e ainda, eleição do que melhor performou os dados, estimou-se a capacidade preditiva dos algoritmos por meio de métricas de desempenho. Logo, foi obtido o erro médio absoluto (MAE), a raiz quadrada do erro médio (RMSE), e o coeficiente de determinação ( $R^2$ ).

#### 4 Análise dos resultados

O algoritmo de *random forest* promoveu a classificação da importância relativa das três variáveis regressoras ponderadas nos modelos, mediante o aumento da precisão, conseguinte, diminuição da variação inexplicada (*IncNodePurity*) dos modelos desenvolvidos.

Logo, foi possível perceber (Figura 1) que em ordem de importância para os modelos, têm-se a densidade da madeira, a idade mensal das florestas plantadas de *Eucalyptus* e, por fim, o tempo pós corte da madeira em campo.

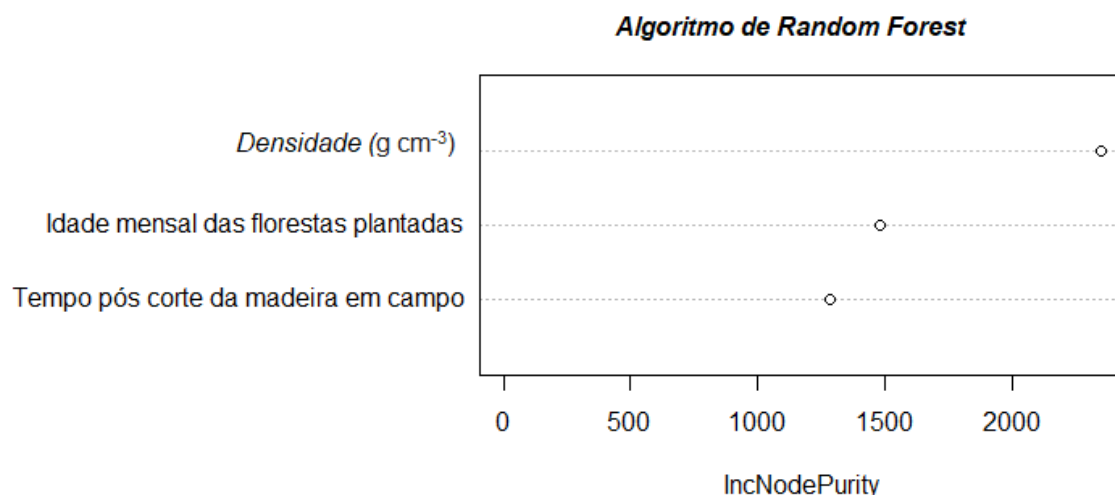


Figura 1. Importância relativa das variáveis regressoras densidade, idade mensal das florestas plantadas e tempo pós corte da madeira em campo.

Além disto, após a modelagem da massa líquida de madeiras transportadas pela CVC por meio dos algoritmos relacionados, resultante das métricas que avaliaram a performance dos modelos, foi possível inferir a superioridade do algoritmo de *support vector machine* na predição da variável *target* (Tabela 1).

Tabela 1. Comparação da performance dos algoritmos de predição.

Algoritmo	RMSE	MAE	$R^2$
<i>random forest</i>	1,93	1,45	0,48
<i>support vector machine</i>	1,88	1,40	0,50
<i>K nearest neighbor</i>	1,98	1,49	0,46

Consequente, com o conjunto de dados para teste, a obtenção do melhor ajuste foi evidenciada por meio do algoritmo de *support vector machine*. Em consonância à Li, Zhao, Tseng e Tan (2020), este algoritmo é referenciado como um dos modelos mais promissores na estatística para modelagem não lineares de alta dimensão.

A Figura 2, apresenta a correlação entre a massa líquida da madeira transportada pela CVC, obtida do conjunto de dados para teste, com a massa líquida da madeira transportada predita por meio do algoritmo, seguida do intervalo de confiança gerado.

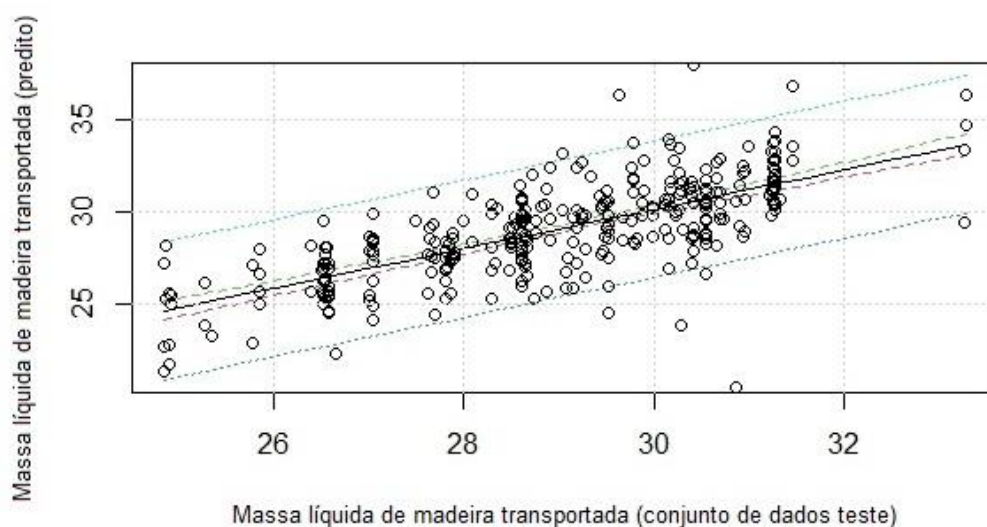


Figura 2 – Ajuste do algoritmo de *support vector machine* para massa líquida de madeira transportada real vs predita.

Além disto, o modelo construído por meio do algoritmo de *random forest*, resultou em uma performance ligeiramente inferior à obtida por meio do algoritmo de *support vector machine* (Figura 3). Assim como o algoritmo *support vector machine* o *random forest* é um aprendizado de máquina supervisionado, isto é, aplicado em conjunto de amostras rotuladas e atua por meio da concatenação de árvores de decisão (Wolff, O'Donncha, & Chen, 2020).




Figura 3 – Ajuste do algoritmo de *random forest* para massa líquida de madeira transportada real vs predita.

Finalmente, o modelo que resultou em uma menor performance, quando comparado aos demais, foi o obtido por meio do algoritmo de *K nearest neighbor* (Figura 4). No entanto, o algoritmo apresenta uma dinâmica não linear, capaz de reconstruir propriedades dinâmicas de uma evolução, conseguindo estipular previsões (Cai, Zhang, Song, Xiong, & Zhou 2020; Kück & Freitag, 2021).




Figura 4 – Ajuste do algoritmo de *K nearest neighbor* para massa líquida de madeira transportada real vs predita.

No intuito de aprimorar o sistema de transporte de madeira rodoviário, os algoritmos de aprendizado de máquina foram aplicados para solucionar um gargalo. Sobretudo, em consonância à Li, Guo, Sivakumar, Dong e Krishnan (2021), os algoritmos auxiliam no processamento de dados em decorrência de sua eficiência computacional e robustez.

## 5 Conclusões

A partir das variáveis idade mensal das florestas plantadas com *Eucalyptus*, tempo pós corte da madeira em campo (em dias) e a densidade da madeira ( $\text{g cm}^{-3}$ ) foi possível estimar a massa líquida de madeira transportada por combinações veiculares de carga.

A associação entre algoritmos de aprendizado de máquina com um banco de dados de controle de transporte rodoviário de madeira promoveu a predição da massa líquida de madeira transportada por combinações veiculares de carga.

O algoritmo *support vector machine* foi o que melhor performou os modelos de predição da massa líquida de madeira transportada por combinações veiculares de carga em rodovias.

## Referências

Abdirad, M., & Krishnan, K. (2020). Industry 4.0 in logistics and supply Chain management: A systematic literature review. **Engineering Management Journal**, 1-15.

Abreu, A. M., & Schinaider, A. D. (2020). A economia compartilhada no transporte rodoviário de cargas. **Facit Business and Technology Journal**, 18(4), 38-59.

Agostini, C. E., & Sampaio, M. A. (2020). Probabilistic Neural Network with Bayesian-based, spectral torque imaging and Deep Convolutional Autoencoder for PDC bit wear monitoring. **Journal of Petroleum Science and Engineering**, 193(107434), 1-11.

Alomari, E., Katib, I., Albeshri, A., Yigitcanlar, T., & Mehmood, R. (2021). Iktishaf+: a big data tool with automatic labeling for road traffic social sensing and event detection using distributed machine learning. **Sensors**, **21**(2993), 1-33.

Angelopoulos, A., Michailidis, E. T., Nomikos, N., Trakadas, P., Hatziefremidis, A., Voliotis, S., & Zahariadis, T. (2020). Tackling faults in the Industry 4.0 era-a survey of machine-learning solutions and key aspects. **Sensors**, **20**(109), 1-33.

Balster, A., Hansen, O., Friedrich, H., & Ludwig, A. (2020). An ETA prediction model for intermodal transport networks based on machine learning. **Business & Information Systems Engineering**, **62**, 403-416.

Cai, L., Yu, Y., Zhang, S., Song, Y., Xiong, Z., & Zhou, T. (2020). A sample-rebalanced Outlier-Rejected k -Nearest Neighbor regression model for short-term traffic flow forecasting. **IEEE Access**, **8**, 22686-22696.

Chen, Y., Zheng, W., Li, W., & Huang, Y. (2021). Large group activity security risk assessment and risk early warning based on random forest algorithm. **Pattern Recognition Letters**, **144**, 1-5.

Chiu, M.-C., Tsai, C.-D., & Li, T.-L. (2020). An integrative machine learning method to improve fault detection and productivity performance in a cyber-physical system. **Journal of Computing and Information Science in Engineering**, **20**(021009), 1-12.

Costa, S. P., Aguiar, E. G. S., Gama, L. C. S., & Fonseca, L. F. S. (2021). Impactos gerados pela fiscalização do excesso de peso em veículos comerciais na rodovia BR-153 em Gurupi – TO. **Research, Society and Development**, **10**(6), 1-9.

Dai, X., Chen, M., & Zhou, Y. (2021). Optimal logistics transportation and route planning based on fpga processor real-time system and machine learning. **Microprocessors and Microsystems**, **80**(103621), 1-7.

Diniz, C. C. C., Valerius, J., Cerqueira, C. L., Timofeiczky Jr, R. Silva, J. C. G. L., & Costa, M. F. (2020). Análise técnica e de custos do transporte de biomassa florestal com carreta piso móvel. **ACSA**, **16**(1), 34-38.

Endo, G. Y., Brandalise, L. T., & Leismann, E. L. (2021). Análise dos aspectos da sustentabilidade do transporte rodoviário de cargas das organizações do oeste do Paraná. **Revista de Empreendedorismo e Inovação Sustentáveis**, **6**(1), 15-32.

Feng, Y., & Audy, J.-F. (2020). Forestry 4.0: a framework for the forest supply chain toward Industry 4.0. **Gestão & Produção**, **27**(4), 1-21.

Ghandour, A. J., Hammoud, H., & Al-Hajj, S. (2020). Analyzing factors associated with fatal road crashes: a machine learning approach. **International Journal of Environmental Research and Public Health**, **17**(4111), 1-13.

Guimarães, P. P., Arce, J. E., Fiedler, N. C., & Robert, R. C. G. (2016). O transporte rodoviário florestal. **Enciclopédia Biosfera**, **13**(24), 780-794.

Jamal, A., Zahid, M., Rahman, M. T., Al-Ahmadi, H. M., Almoshaogeh, M., Farooq, D., & Ahmad, M. (2021). Injury severity prediction of traffic crashes with ensemble machine learning techniques: a comparative study. **International Journal of Injury Control and Safety Promotion**, **1**, 1-20.

Kamble, S. S., Gunasekaran, A., & Gawankara, S. A. (2018). Sustainable Industry 4.0 framework: A systematic literature review identifying the current trends and future perspectives. **Process Safety and Environmental Protection**, **117**, 408–425.

Karballaezadeh, N., Zaremotekhas, F., Shamshirband, S., Mosavi, A., Nabipour, N., Csiba, P., & Várkonyi-Kóczy, A. R. (2020). Intelligent road inspection with advanced machine learning, hybrid prediction models for smart mobility and transportation maintenance systems. **Energies**, **13**(1718), 1-22.

Kaytez, F. (2020). A hybrid approach based on autoregressive integrated moving average and least-square support vector machine for long-term forecasting of net electricity consumption. **Energy**, **197**(117200), 1-12.

Keramati, A., Lu, P., Sobhani, A., & Esmaili, S. A. H. (2020). Impact of forest road maintenance policies on log transportation cost, routing, and carbon-emission trade-offs: oregon case study. **Journal of Transportation Engineering**, **146**(5), 1-12.

Koirala, A., Kizha, A. R., & Roth, B. E. (2017). Perceiving major problems in forest products transportation by trucks and trailers: a cross-sectional survey. **European Journal of Forest Engineering**, **3**(1), 23-34.

Kotsiopoulos, T., Sarigiannidis, P., Ioannidis, D., & Tzovaras, D. (2021). Machine learning and deep learning in smart manufacturing: The smart grid paradigm. **Computer Science Review** **40**(100341), 1-25.

Kropivšek, J., & Grošelj, P. (2020). Digital development of slovenian wood industry. **Drvena Industrija**, **71**(2), 139-148.

Kück, M., & Freitag, M. (2021). Forecasting of customer demands for production planning by local -nearest neighbor models. **International Journal of Production Economics**, **231**(107837), 1-22.

Lachini, E., Fiedler, N. C., Silva, E. F., Vieira, G. C., Souza, L. A., & Carmo, F. C. A. (2018). Pesquisa operacional na minimização de custos de transporte florestal. **Revista Brasileira de Biometria**, **36**(2), 473-488.

Li, J., Guo, F., Sivakumar, A., Dong, Y., & Krishnan, R. (2021). Transferability improvement in short-term traffic prediction using stacked LSTM network. **Transportation Research**, **124**(102977), 1-18.



Li, L. L., Zhao, X., Tseng, M. L., & Tan, R. R. (2020). Short-term wind power forecasting based on support vector machine with improved dragonfly algorithm. **Journal of Cleaner Production**, **242**(118447), 1-12.

Lopes, A. S. B., & Pereira, M. M. (2020). Exploração de espaço de projeto para multicores heterogêneos com o uso aprendizado de máquina: o estado da arte. **Brazilian Journal of Development**, **6**(5), 26730-26749.

Lubis, A. R., Lubis, M., & Khowarizmi, A. (2020). Optimization of distance formula in K-Nearest Neighbor method. **Bulletin of Electrical Engineering and Informatics**, **9**, 326-338.

Machado, E. J., Assis, C. A. S., & Pereira, A. C. M. (2020). Modelagem, implementação e avaliação de estratégias de negociação baseadas em algoritmos de aprendizado de máquina para o mercado financeiro. **Revista Brasileira de Computação Aplicada**, **12**(1), 16–31.

Machado, C. C., Lopes, E. S., Birro, M. H. B., & Machado, R. R. (2011). **Transporte rodoviário florestal** (2a ed.) Viçosa: UFV.

Mascarenhas, T. A. T, Moriel Jr, J. G., Gomes, R. S. R., & Mello, G. J. (2020). Aplicação de algoritmos de aprendizado de máquina na classificação de conhecimentos especializados de professores de física. **Research, Society and Development**, **9**(11), 1-35.

Ortt, R., Stolwijk, C., & Punter, M. (2020). Implementing Industry 4.0: Assessing the current state. **Journal of Manufacturing Technology Management**, **31**(5), 825-836.

Palander, T. (2017). The environmental emission efficiency of larger and heavier vehicles: A case study of road transportation in Finnish forest industry. **Journal of Cleaner Production**, **155**, 57-62.

Penumuru, D. P., Muthuswamy, S., & Karumbu, P. (2019). Identification and classification of materials using machine vision and machine learning in the context of Industry 4.0. **Journal of Intelligent Manufacturing**, **31**, 1229–1241.

R Development Core Team. (2021). (Version 3.3.3.) [Software]. R: A language and environment for statistical computing. Reference index R Foundation for Statistical Computing, Vienna, Austria. ISBN 3-900051-07-0. <http://www.r-project.org/>.

Rocha, J. P., Borba, F. V., & Lobo, V. G. C. (2020). Benefícios obtidos através da implantação de um posto integrado automatizado de fiscalização (PIAF) na BR-135/MA. **Enciclopédia Biosfera**, **17**(32), 564-576.

Romeiro Jr, C. L. S., Brito, L. A. T., Heller, L. F., Schreinert, G. G., Núñez, W. P., Ceratti, J. A. P., & Merighi, C. (200). Impact on pavement deterioration due to overload vehicle regulation in Brazil. **Transportation Research Procedia**, **45**, 842-849.

Santos, A. (2019). Floresta 4.0: Como os conceitos da Indústria 4.0 estão revolucionando o setor florestal. **B Forest**, **59**(5), 12-19.

Schettino, S., Minette, L. J., Schettino, C. F., & Reboleto, I. D. (2018). Feasibility analysis of the use of light and medium trucks in timber transport in rural properties. **Revista Árvore**, **42**(6), 1-9.

Silvestri, L., Forcina, A., Introna, V., Santolamazza, A., Cesarottic, V. (2020). Maintenance transformation through Industry 4.0 technologies: Asystematic literature review. **Computers in Industry**, **123**(103335), 1-16.

Strandgard, M., Taskhiri, M. S., Acuna, M., & Turner, P. (2021). Impact of roadside drying on delivered costs for *Eucalyptus globulus* logging residue and whole trees supplying a hypothetical energy plant in western Australia using a linear-programming model. **Forests**, **12**(455), 1-19.

Tymendorf, Ł., & Trzciński, G. (2020a). Czas trwania etapów dostawy wielkowymiarowego drewna sosnowego do tartaku. **Sylwan**, **164**(7), 549–559.

Tymendorf, Ł., & Trzciński, G. (2020b). Przejazdy po drogach leśnych i publicznych przy dostawach wielkowymiarowego drewna sosnowego do tartaku. **Sylwan**, **164**(8), 651-662.

Virgens, A. P., Freitas, L. C., & Silva, M. L. (2021). Avaliação financeira e gerenciamento de risco para diferentes distâncias de transporte de madeira pelo modal rodoviário. **Ciência Florestal**, **31**(2), 880-897.

Wolff, S., O'Donncha, F., & Chen, B. (2020). Statistical and machine learning ensemble modelling to forecast sea surface temperature. **Journal of Marine Systems**, **208**(103347), 1-12.

Wu, C., Wang, Z., Hu, S., Lepine, L., Na, X., Ainalis, D., & Stettler, M. (2020). An automated machine-learning approach for road pothole detection using smartphone sensor data. **Sensors**, **20**(5564), 1-23.

Xu, J., Saleh, M., & Hatzopoulou, M. (2020). A machine learning approach capturing the effects of driving behaviour and driver characteristics on trip-level emissions. **Atmospheric Environment**, **224**(117311), 1-14.

Zhang, C., Chen, Y., Chen, H., & Chong, D. (2021). Industry 4.0 and its implementation: A review. **Information Systems Frontiers**, 1-11.