

# Detecção de Adulteração do Etanol Hidratado utilizado nos Veículos de Ciclo Otto por Meio de Aprendizado de Máquina via Interface OBD

André Ricardo Marchezan\*. Mateus Giesbrecht\*\*

\* Faculdade de Engenharia Elétrica e de Computação - UNICAMP  
Campinas – SP - Brasil (e-mail: [marchezan@hotmail.com](mailto:marchezan@hotmail.com)).

\*\* Faculdade de Engenharia Elétrica e de Computação - UNICAMP  
Campinas – SP - Brasil (e-mail: [mateus@fee.unicamp.br](mailto:mateus@fee.unicamp.br)).

---

**Abstract:** According to the Brazilian National Petroleum Agency (ANP), 25% of fuel at gas stations in Brazil did not attend quality policies in 2019. Of this total, 13% has fuel adulteration based on illegal addition of any prohibited substances. It causes problems for final consumers as high consumption and early deterioration of engine components. This paper evaluated fuel quality using real data from engine sensors by interface On-Board Diagnostics (OBD) through low cost electronic device for data acquisition by Bluetooth Low Energy (BLE) with a platform connected to the internet, enabling Internet of Things (IoT) integration. Based on data analysis, using supervised machine learning algorithms k-nearest neighbors (KNN) and Artificial neural network (ANN), the accuracy was over 85% considering almost adulteration level of 5%.

**Resumo:** De acordo com a Agência Nacional de Petróleo (ANP), 25% dos postos de combustíveis no Brasil não atenderam as políticas de qualidade do órgão em 2019. Desse total, 13% tiveram irregularidades relacionadas à adulteração com adição de substâncias ilegais. Esse problema causa muito prejuízo aos consumidores, como aumento de consumo e deterioração precoce dos componentes automotivos. Neste trabalho é avaliada a qualidade do combustível através dos dados reais dos sensores do motor via interface *On-Board Diagnostics* (OBD) obtidos através de um dispositivo eletrônico de baixo custo para aquisição dos dados via *Bluetooth Low Energy* (BLE) com plataforma conectada à internet, possibilitando a integração com soluções de *Internet of Things* (IoT). Através dos dados analisados, usando os algoritmos de aprendizado de máquina k-vizinhos mais próximos (do inglês, *k-Nearest Neighbors* – KNN) e Rede Neural Artificial (RNA), foram obtidos resultados com uma precisão acima de 85% para uma nível de adulteração de aproximadamente 5%.

**Keywords:** Fuel Adulteration, OBD, Supervised Algorithm, Machine Learning, IoT, KNN, ANN

**Palavras-chaves:** Adulteração de combustível, OBD, Algoritmo Supervisionado, Aprendizado de Máquina, IoT, KNN, RNA

---

## 1. INTRODUÇÃO

Em 2018, a Agência Nacional de Petróleo (ANP) emitiu mais 4.500 multas com aproximadamente 18.000 ações de fiscalização nos postos de combustíveis, sendo que 12% dessas infrações referem-se à comercialização de combustível fora das especificações (ANP, 2019).

A agência define a não conformidade quando ocorre qualquer desvio na especificação do produto. Assim, a adição de qualquer substância ao combustível altera as propriedades químicas pré-definidas.

O etanol hidratado obteve o maior número de não conformidades nas fiscalizações. O principal motivo das irregularidades foi encontrado no teor alcoólico de 95,1% a 96% com alteração pela adição de água nas amostras analisadas.

Uma das consequências dessa adulteração, água no Etanol, é um consumo maior de combustível devido à diminuição do poder calorífico e, conseqüentemente, da quantidade de energia que é capaz de ser gerada em sua queima dentro do motor. Além dessa consequência, a água prejudica alguns componentes do sistema de injeção e combustão, diminuindo a vida útil devido corrosão causada pelo cloro (Assis, 2012).

A medição da qualidade do combustível é essencial para o desenvolvimento automotivo. Existem várias técnicas para essa atividade como sensores de velocidade de ondas sonoras, modelo quimiométricos, espectrofotometria infravermelha, entre outras possibilidades. Entretanto, todas essas técnicas são complexas e requerem equipamentos dispendiosos (Bhati, 2021). ANP controla a qualidade dos combustíveis via densímetro, e os dados podem ser acessados pelo consumidor. Entretanto, esse ensaio químico não é prático para o dia a dia ou viável para implementação em todos os veículos automotores movidos a combustão.

Outra forma possível de detecção de adição de água no etanol é através da análise dos dados disponíveis, via interface On-Board Diagnoses (OBD) configurada para esse fim com adição de sensores específicos (Pasupuleti, 2018). No Brasil, os dados OBD são públicos e estão disponíveis, obrigatoriamente, nos veículos brasileiros desde 2010, podendo ser acessados através do protocolo padronizado (ISO 15765-4:2016).

A avaliação dos dados de OBD para detecção de adulteração do combustível não é uma tarefa simples devido diversas formas de condução gerando uma grande quantidade de informação e de variáveis a serem monitoradas. Uma possível solução seria a utilização do aprendizado de máquina (AM), pois se apresenta como uma boa ferramenta para encontrar padrões de uso (Barreto, 2018).

A técnica de AM pode ser definida como a prática de usar algoritmos para coletar e interpretar dados, fazendo previsões sobre fenômenos. Ainda que o AM seja uma ferramenta poderosa para a aquisição automática de conhecimento, deve ser observado que não existe um único algoritmo que apresente o melhor desempenho para todos os problemas. Dessa forma, é importante entender os pontos positivos e negativos dos algoritmos de AM de uma forma sistêmica avaliando os conceitos induzidos por esses algoritmos (Baranauskas, 2021).

O objetivo desse artigo é comparar 02 diferentes algoritmos de AM supervisionados: o algoritmo dos vizinhos mais próximos (KNN do Inglês) e as redes neurais artificiais (ANN do inglês) para avaliar a melhor performance para a detecção da adulteração do etanol hidratado no veículos automotores. O desafio, diferentemente de Pasupuleti (2018), é utilizar apenas os dados disponíveis via interface OBD, para monitorar níveis de emissões, na previsão e classificação da adulteração sem novos dispositivos, evitando custos adicionais.

## 2. ON-BOARD DIAGNOSES (OBD)

Atualmente, as funções básicas do veículo dependem dos sistemas eletrônicos, que são desenvolvidos seguindo requerimentos automotivos exigentes com objetivo de manter a confiabilidade durante a vida útil do motor, além de gerenciar os níveis de emissões de acordo com os limites aprovados pelas legislações locais (Bosch, 2005). Os dados para monitorar os níveis de emissões devem estar disponíveis

para uma possível fiscalização, de acordo com os valores limítrofes aprovados pelos países aplicados.

O motor e outros componentes vitais para o funcionamento do sistema devem ser monitorados ao longo da vida útil do veículo para manter as emissões dentro dos parâmetros estabelecidos pela lei. (Bosch, 2005). Esse gerenciamento é realizado através de uma unidade central eletrônica (ECU) onde chegam diversos sinais de vários sensores. Esses sinais são tratados e processados pela unidade para controle, monitoramento e diagnóstico do motor. Parte desses dados deve ser obrigatoriamente disponibilizada no conector padronizado OBD (ISO 15031-3:2016). Na Fig. 1 é apresentado o conector.




Fig. 1 Conector OBD padronizado.

O sistema OBD foi desenvolvido em 1988 pela CARB (Agencia de Recursos do Ar da Califórnia) como primeiro objetivo de monitorar as emissões conforme os limites estabelecidos pelas leis locais. O Segundo objetivo foi padronizar os protocolos de diagnósticos entre os diversos modelos de veículos (Barreto, 2018). No Brasil, esse sistema está regulamentado desde 2007 pelo CONAMA PROCONVE L-4 – 2007 (OBD-BR).

Além dos dois principais objetivos do Sistema OBD, controle de emissões e diagnose veicular, é possível realizar uma análise mais detalhada dos dados disponíveis para avaliar o uso e comportamento do motorista através da análise de alguns sinais como posição do acelerador, movimento da direção, velocidade, etc (Kumagai, 2006).

## 3. ESCOLHA DAS VARIÁVEIS RELEVANTES

Quando os dados não podem ser entendidos e/ou combinados para a criação de relações matemáticas capazes de prever algum resultado esperado, pode ser utilizado um tipo de modelo genérico, adaptável a qualquer conjunto de dados, denominado modelo caixa preta. Para simplificar esse modelo, uma boa prática é avaliar quais variáveis são mais relevantes utilizando, por exemplo, o método de correlação de Person. Essas variáveis então são escolhidas como entradas dos algoritmos de aprendizado de máquina.

O  $\rho$  de Pearson mede o grau da correlação entre duas variáveis assumindo valores entre -1 e 1, onde  $\rho=1$  significa uma correlação perfeita positiva,  $\rho=-1$  uma correlação negativa perfeita entre as duas variáveis e  $\rho=0$  que

as duas variáveis não dependem linearmente uma da outra. O cálculo do coeficiente é dado pela eq. 1 (Bisquerria, 2004):

$$\rho = \frac{n \cdot \sum x_i \cdot y_i - (\sum x_i) \cdot (\sum y_i)}{\sqrt{(n \cdot \sum x_i^2 - (\sum x_i)^2) \cdot (n \cdot \sum y_i^2 - (\sum y_i)^2)}} \quad (1)$$

Em que:

$n$  é a quantidade de dados,  $x_i$  é a variável independente e  $y_i$  a variável dependente.

Uma vez que as variáveis são selecionadas, o fenômeno em questão pode ser avaliado utilizando os algoritmos supervisionados, que serão discutidos na próxima seção.

#### 4. ALGORITMOS SUPERVISIONADOS

Em algoritmos de aprendizado de máquina supervisionados, os dados de entrada são rotulados e usados para treinamento com objetivo de categorizar/classificar os resultados em classes. Normalmente parte dos dados não treinados são utilizados para avaliar a performance desses aprendizados.

Para esse AM, os dados de entrada serão as 5 variáveis mais relacionadas pela correlação de Pearson e a saída apenas 1 variável com 2 classes: Adulterado e Não Adulterado.

##### 4.1 Algoritmo KNN

O algoritmo KNN avalia a distância entre uma instância de teste, que é um vetor no espaço de atributos, e os  $k$  vizinhos mais próximos no conjunto de dados de treinamento, sendo  $k$  um metaparâmetro que pode ser escolhido pelo usuário. Dessa forma, a classificação dessa instância é dada pela classe que ocorrer com maior frequência entre os  $k$  vizinhos.

Na Fig 2, são mostrados os três vizinhos mais próximos da instância de teste  $In$ , onde dois são da classe “X” e um da classe “0”. Ao aplicar o kNN, com  $k=3$ , a instância  $In$  é classificada como sendo da classe “X”, pois essa classe possui mais representantes na vizinhança de  $In$ .




Fig. 2 Exemplo da aplicação do algoritmo KNN.

A distância Euclidiana é a métrica mais utilizada para avaliar a distância entre os vizinhos, apesar de haver outras opções. Nesse trabalho a métrica utilizada foi Mahalanobis (Eq.2) por não depender das escalas de medição além de utilizar a covariância nos cálculos.

$$D^2 = (x - m)^T \cdot C^{-1} \cdot (x - m) \quad (2)$$

Onde:

$D$  é a distância ao quadrado,  $x$  é vetor de observação,  $m$  é a média das variáveis independentes e  $C$  é a matriz covariância das variáveis independentes.

##### 4.2 Rede Neural Artificial (RNA)

As RNAs são algoritmos computacionais inspirados na rede neural biológica que evoluem baseada em experiências. Dessa forma, esse modelo pode aprender através de exemplos e/ou ampliar o conhecimento adquirido.

O modelo RNA foi estudado neste artigo por resolver problemas com muitos dados, modelar sistemas não-lineares complexos e ser útil em processos físicos não completamente entendidos. As redes neurais, em geral, executam muito bem as tarefas como: reconhecimento de padrões, identificação de funções, previsões de séries temporais e classificações.

A RNA Perceptron multicamadas é a topologia mais conhecida. Esse sistema é composto por múltiplas camadas de neurônios conectadas diretamente entre si, conforme é mostrado Fig. 3.




Fig. 3 Exemplos de Redes Neurais (Haykin, 1994).

Em muitas aplicações, as unidades dessas redes podem utilizar várias funções de ativação como sigmoide, tangente hiperbólica e linear retificada para normalizar atributos contínuos. Neste trabalho a função de ativação escolhida foi Sigmoide como mostrado na Fig. 4.




Fig. 4 Função de ativação sigmoide.

Existem algumas técnicas de aprendizado que normalmente se diferem de como os pesos são corrigidos. A técnica utilizada nesse trabalho é a retro propagação ou *backpropagation*.

O objetivo desse aprendizado é otimizar os pesos ( $W_i$ ) para que a rede neural possa aprender a mapear corretamente as entradas para as saídas e vice-versa.

O treinamento do algoritmo *backpropagation* consiste em apresentar um padrão a todas as camadas da rede usando pesos iniciais, até obter a resposta da última camada. Esta resposta é comparada ao valor ótimo desejado. Se esse valor estiver dentro da variação de erro desejada o processo para, caso contrário o erro é calculado, e os pesos são novamente recalculados das camadas de saída para entrada (retro propagação), e o processo se repete, conforme é apresentado na Fig. 5.




Fig. 5 Rede Neural com Retro propagação (Kovacs, 1996).

A forma utilizada para calcular o erro na rede foi o erro quadrático médio, ou em inglês MSE (*mean squared error*), conforme Equação 3.

$$MSE = \frac{1}{m} \sum_{i=1}^m (t_i - y_i)^2 \quad (3)$$

$m$  número dados

$t_i$  valor real

$y_i$  valor calculado

Assim se  $MSE_2 < MSE_1$ , pode-se dizer que desempenho da segunda rede é melhor que a primeira para o conjunto de dados utilizados no treinamento.

A variação de correção dessas redes, normalmente, é calculada pelo Gradiente Descendente que usa a função do mínimo erro para ajustar os pesos.

#### 4.3 Avaliação dos algoritmos

Para avaliar a performance dos algoritmos KNN e RNA e compará-los, utilizou-se dos seguintes indicadores:

- AUC (*Area under ROC*) é a área sob a curva de entrada;

- CA (*Classification accuracy*) é a proporção de classificações corretas;

- Precision é a proporção de positivos verdadeiros entre as amostras positivas;

- Recall é a proporção de negativos verdadeiros entre todas as amostras negativas;

- F1 é um peso médio entre a Precision e Recall (Eq. 4)

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

Essa última variável indica a performance do classificador através de uma média. O cálculo facilita o entendimento de comparação da eficiência entre os algoritmos classificadores.

#### 5. OBTENÇÃO DE DADOS/MÉTODO PROPOSTO

No diagrama macro da Fig. 6 é representado como o sistema de aquisição de dados foi desenvolvido para obtenção, análise e validação dos dados para ambas condições com e sem adulteração do Etanol (100 e 95%).



Fig. 6 Sistema de aquisição de dados.

O fluxo de dados do sistema desenvolvido segue o que está representado na Fig. 7. O micro controlador (STM32F103C8T6) é programado com os dados que serão monitorados e então faz requisições periódicas. A informação de requisição é enviada no protocolo CAN através da porta OBD, chegando até a central de processamento do veículo.

Após receber a informação de requisição de dados a central responde com os dados desejados. O módulo CAN decodifica a mensagem recebida e então o micro controlador encaminha a mensagem para o módulo *bluetooth*. No celular um aplicativo é conFig.do para receber dados do módulo BLE HM-10 e salvar os dados recebidos no *Google Firebase Real*.

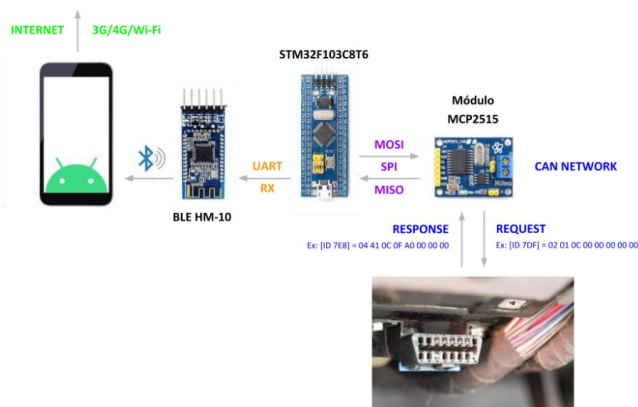


Fig. 7 Fluxo de dados do sistema dedicado para aquisição de dados.

Para aquisição de dados foi utilizado o veículo, Ford Ká 1.5L Flex Fuel (ciclo otto) com 3 cilindros. Esses dados foram obtidos com a mesma taxa de amostragem de 1s para diversas janelas de uso, como rodovia, uso urbano, em dias distintos e dirigibilidade variada (normal/agressiva). Em todas as condições de obtenção de dados foi utilizado como combustível etanol hidratado 100% (0% água) ou 95% (5% de água). A água foi escolhida com agente adulterante por ser amplamente utilizado no mercado brasileiro devido ao baixo custo.

Total 2614 de registros de dados para treinar os algoritmos, sendo 1403 com 5% de adulteração com descrição de “1” no campo AGUA e “0” para etanol hidratado puro.

Do total de dados, foram selecionados aleatoriamente 66% para fazer o aprendizado e o restante foi utilizado para avaliação dos algoritmos. Para a análise dos dados e resultados utilizou-se o software Orange 3.26.0 por ser uma plataforma gratuita e de fácil utilização para discussão inicial.

A principal variável disponível no OBD utilizada para os cálculos de correção de injeção de combustível é a *Fuel Long Term* (FLT). Essa variável foi desenvolvida para avaliar a qualidade do sistema de emissões do motor, pois com o tempo e/ou alguns problemas, como injetor travado, sensor com problema, baixa qualidade de combustível ou desgastes do motor, essa variável tende a aumentar, sendo um motivo plausível de multa caso esteja além de certo valor definido para cada país. Além disso, esse valor é memorizado na PCM (*Power Control Module*) como padrão para as mesmas condições de uso do motor como rotação, carga do motor, velocidade, entre outras, desde que essa alteração não persista por longo tempo.

Assim, o FLT pode manter, aumentar e diminuir os valores aprendidos previamente. Dessa forma, se todas as condições forem mantidas, o valor ficará constante para a janela analisada. Entretanto, se o valor mudar nas mesmas condições avaliadas, pode-se afirmar, dentro de uma margem de tolerância, que o combustível pode estar diferente e/ou adulterado.

Além do FLT foi calculado o índice de correlação de Pearson entre a ocorrência ou não de adulteração de combustível e as seguintes variáveis, que têm uma forte relação com o consumo como:

- Ambient air temp (°C) – Temperatura ambiente
- Actual Engine torque (%) – Torque em %
- Engine RPM (rpm) – Indica a rotação do motor por minuto;
- Engine Load(Absolute)(%) – Massa de ar em % dentro do cilindro;
- Intake Air Temperature (°C) – Temperatura na entrada do motor;
- Absolute Throttle Position B(%) – Posição do pedal acelerador em (%);
- Speed (OBD)(Km/h) – Velocidade do veículo em Km/h.

Apenas cinco variáveis mais correlacionadas com a presença de combustível adulterado foram utilizadas no algoritmo classificador. A avaliação de performance seguiu os critérios da seção 4.3.

## 5. RESULTADOS

Os resultados mostrados na Tab. 1, calculados pela correlação de Pearson, indicam quais variáveis devem utilizadas como entrada (atributos) nos algoritmos KNN e RNA.

Tab. 1 Correlação de Pearson x Adulteração (AGUA).

$\rho$	variável independente	variável dependente
+0.631	AGUA	Fuel Trim Bank 1 Long Term(%)
+0.357	AGUA	Intake Air Temperature(°C)
-0.112	AGUA	Engine RPM(rpm)
-0.065	AGUA	Engine Load(Absolute)(%)
-0.055	AGUA	Speed (OBD)(km/h)

Na Tab. 2 é possível comparar os resultados dos algoritmos KNN, com metaparâmetro igual a 5, e RNA, com 3 camadas de neurônios, através dos indicadores. A performance dos dois modelos esta próxima para todos os indicadores. Entretanto, o tempo de processamento do KNN foi aproximadamente 30% menor que o RNA.

Tab. 2 Avaliação dos algoritmos KNN e RNA.

Model	AUC	CA	F1	Precision	Recall
kNN	0,9122	0,8627	0,8626	0,8626	0,8627
RNA	0,9473	0,8569	0,8571	0,8576	0,8569

Outra forma de avaliar o desempenho dos algoritmos de classificação é pela curva de ROC (*Receiver Operating Characteristic*) Fig. 8. A curva ROC é um gráfico bidimensional que mostra a probabilidade de um resultado positivo verdadeiro no eixo Y (TP = Positivos Verdadeiros / Positivos Totais) e a probabilidade de um resultado falso positivo no eixo X (FP = Positivos Falsos / Negativos Totais).

Como tratam das médias para cada ponto plotado, a forma mais simples de avaliar o desempenho dos classificadores é através do cálculo da área abaixo da curva de cada algoritmo.

Nesse caso, pode-se concluir que tanto KNN, quanto RNA, se comportam bem na análise da adulteração, com uma pequena vantagem para rede neural, mas ambas com áreas acima de 0,9.




Fig. 8 Curva ROC KNN e RNA.

## 6. CONCLUSÕES

A obtenção de dados de forma aleatória, sem ambientes controlados: como motorista, dirigibilidade, temperatura e percurso, foi um requisito desse estudo. O objetivo é se aproximar do uso real de um veículo.

Os resultados obtidos pelos algoritmos de aprendizado de máquina KNN e RNA, usando os dados reais, obtidos pelo dispositivo BLE, demonstraram a possibilidade de avaliar a qualidade do combustível etanol hidratado nos automóveis utilizando apenas o OBD sem a necessidade de instalar novos dispositivos dedicados no sistema dos motores de ciclo otto.

Ambos algoritmos tiveram precisão acima de 85% para um nível de adulteração de aproximadamente 5%. A tendência é obter uma performance menor quando a adulteração diminuir. A determinação desses números é uma sugestão para futuros trabalhos. Outro ponto importante para os próximos estudos seria avaliar a utilização de um sistema não supervisionado para detecção de adulteração em vários modelos de veículos, sem a necessidade de dados rotulados, uma vez que existem diversos tipos de motores.

## AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

## REFERÊNCIAS

- Anuário Estatístico ANP, 2019 – Agência Nacional de Petróleo, disponível em : <https://www.gov.br/anp/pt-br/centrais-de-conteudo/publicacoes/anuario-estatistico/anuario-estatistico-2019>
- Assis, C. M. *Avaliação da Corrosividade do Etanol Combustível Utilizando Arranjo de Microeletrodos*. Dissertação Mestrado Faculdade Engenharia Mecânica-FEM/UNICAMP, Campinas, 2012.
- Bhati, A., Acharya PV., Ezekoye OA., Bahadur, V. *Estimation of Fuel Quality Using Statistical Regression-Based Analysis of Leidenfrost Droplets*. 15th International Conference on Energy Sustainability. ASME 2021
- ISO 15765-4:2016(en) *Road vehicles — Diagnostic communication over Controller Area Network (DoCAN) — Part 4: Requirements for emissions-related systems* em: <https://www.iso.org/obp/ui/#iso:std:iso:15765:-4:ed-3:v1:en> (acessada em: 20/01/2021)
- Pasupuleti, S. R., Apurv, J., Jatin, B., Harsh, K., Arvind, K. c., Tushar, K., Vivek, K., Roushan, K., Surajit, M. , Prashant, S., *On-Board Diagnostic System to Detect Adulterants in Gasoline and Provide a Quantified Value of Adulterants* - Patent No. 14/2018
- Barreto, C. A., Xavier, J. , Canuto, A., Silva, I., *A Machine Learning Approach Based on Automotive Engine Data Clustering for Driver Usage Profiling Classification* - XV Encontro Nacional de Inteligência Artificial e Computacional, 2018
- CARB – *Califórnia Air Resources Board*, disponível em: <https://ww2.arb.ca.gov/> (acessada em: 18/01/2021)
- IBAMA - *Programa de controle de emissões veiculares (Proconve)*, disponível em: <http://www.ibama.gov.br/emissoes/veiculos-automotores/programa-de-controle-de-emissoes-veiculares-proconve>
- ISO 15031-3:2016 *Road vehicles — Communication between vehicle and external equipment for emissions-related diagnostics — Part 3: Diagnostic connector and related electrical circuits: Specification and use*, disponível em: <https://www.iso.org/standard/64636.html>
- Baranauskas, J. A., Monard, M. C., *Reviewing some machine learning concepts and methods*. Technical Report 102, Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos. Disponível em: [ftp://ftp.icmc.usp.br/pub/BIBLIOTECA/rel\\_tec/RT\\_102.ps.zip](ftp://ftp.icmc.usp.br/pub/BIBLIOTECA/rel_tec/RT_102.ps.zip) (acessada em: 15/02/2021)
- Bosch, R. GmbH., *Manual de Tecnologia Automotiva – Tradução 25 edição*: Edgar Bluncher 2005
- Kumagai, T., Akamatsu, M., *Prediction of Human Driving Behavior Using Dynamic Bayesian Networks* - IEICE TRANSACTIONS on Information and Systems Vol.E89-D No.2 pp.857-860, 2006
- Bisquerra, R.; Sarriera, J. C.; Martinez, F. *Introdução à estatística: enfoque informático com o pacote estatístico SPSS*. Porto Alegre: Artmed, 2004.