

## **DADOS DA REDE CAN BUS PARA AVALIAÇÃO DO COMPORTAMENTO DO OPERADOR DE COLHEITA FLORESTAL UTILIZANDO FERRAMENTAS DE DATA SCIENCE**

**DENNIS BERNARDI**

PROGRAMA DE EDUCAÇÃO CONTINUADA EM ECONOMIA E GESTÃO DE EMPRESAS (PECEGE)

**FERNANDO FREIRE VASCONCELOS**

### **Introdução**

O presente estudo teve objetivo avaliar a utilização de dados da rede CAN Bus de Harvesters Florestais, através de técnicas de data mining e machine learning, para obtenção de insights operacionais relacionados ao consumo de diesel. A CAN Bus, nos entregou um total de 59 variáveis dos harvesters. Neste trabalho optamos por avaliar a correlação de Pearson de 15 variáveis com o consumo de diesel, sendo que 5 apresentaram correlação positiva e significativa e foram utilizadas para montar um modelo de redução de consumo de combustível.

### **Contexto Investigado**

O setor de árvores plantadas fornece inúmeros produtos de origem renovável essenciais para o dia a dia das pessoas. Com posição de destaque no desenvolvimento de uma economia de baixo carbono, o setor de base florestal é destacado por sua alta produtividade, melhores práticas de manejo florestal, responsabilidade social e modernas instalações produtivas. A redução do consumo de combustível impacta diretamente na redução do custo da madeira produzida e contribui para a mitigação de gases de efeito estufa, sendo o objetivo deste trabalho montar de modelo de redução de consumo nas máquinas.

### **Diagnóstico da Situação-Problema**

Apresentar uma alternativa para melhorarmos a gestão do consumo de diesel no processo de colheita florestal, utilizando técnicas de data mining e machine learning, sendo que para isso foi feita a leitura dos dados presente na rede CAN Bus de 3 Harvestes, para obtenção do consumo instantâneo e outras variáveis que possam estar relacionadas à sua variação. A importância do estudo decorre da necessidade de avaliar possíveis diferenças de consumos entre máquinas e operadores, servindo para balizar futuros treinamentos.

### **Intervenção Proposta**

Como identificamos algumas variáveis com melhor correlação com o consumo de diesel, buscamos avaliar se seria possível termos equações lineares, capaz de explicar a variação de consumo, todavia devido a multicolinearidade e baixo poder explicativo partimos para utilização de algoritmo de classificação. Assim partimos para a utilização de técnica de Machine Learning, K-NN (K-Nearest Neighbors), para a partir das mesmas 5 variáveis, para classificar os operadores como Operador Ótimo e Operador Oportunidade, onde obtivemos uma acurácia superior a 90%.

### **Resultados Obtidos**

A partir do treinamento efetuado com o K-NN, que apresentou uma alta acurácia, acima de 90%, abrindo a possibilidade de a partir de 1 medição curta de operação, classificar os operadores em relação a sua habilidade técnica com as máquinas, especialmente em relação ao menor consumo de gasolina, para direcionar treinamentos para os operadores que não conseguem economizar tanto combustível.

### **Contribuição Tecnológica-Social**

A leitura dos dados da rede CAN Bus de Harvesters Florestais, é uma grande fonte de informações para identificarmos oportunidades operacionais, permitindo identificar padrões comportamentais de consumo de diesel entre operadores e consequentemente a classificação desses operadores em Operadores Ótimos e Operadores Oportunidade, gerando insights para focarmos os treinamentos operacionais nos operadores com maior consumo de diesel.

### **Palavras Chave**

Colheita Florestal, Machine Learning, CAN Bus

# DADOS DA REDE CAN BUS PARA AVALIAÇÃO DO COMPORTAMENTO DO OPERADOR DE COLHEITA FLORESTAL UTILIZANDO FERRAMENTAS DE DATA SCIENCE

## Introdução

O setor de árvores plantadas atua há anos com produção sustentável, provendo inúmeros produtos de origem renovável essenciais para o dia a dia das pessoas como móveis, livros, pisos laminados, painéis de madeira, papéis higiênicos e embalagens. Além de prover o hoje, essa indústria também está de olho no futuro, investindo em pesquisa e inovação para oferecer cada vez mais bioprodutos ou biomateriais da economia circular, biodegradáveis e recicláveis (IBÁ, 2021).

Com posição de destaque no desenvolvimento de uma economia de baixo carbono, o setor de base florestal é destacado por sua alta produtividade, tecnologia incorporada, melhores práticas de manejo florestal, responsabilidade social e modernas instalações produtivas. Com uma área total de árvores cultivadas somando 9 milhões de hectares, atua, comumente, em áreas anteriormente degradadas pela ação humana. Com um olhar cuidadoso para o meio ambiente, o setor conta com 5,9 milhões de hectares destinados para Áreas de Preservação Permanente [APP], Reserva Legal [RL] e Reservas Particulares do Patrimônio Natural [RPPN] (IBÁ, 2021).

Dentro desses 9 milhões de hectares, vivemos em um momento de grande modernização no sistema de Colheita Florestal, destacando-se dentro os diferentes sistemas cut-to-length, o qual consiste em um sistema de colheita mecanizada no qual as árvores são desgalhadas e processadas em toras atendendo à demanda fabril. Tal sistema é composto do conjunto de máquinas Harvester e Forwarder.

Com cada vez mais essas máquinas de alta capacidade de produção permitem que as operações de corte e baldeio de florestas de eucalipto sejam realizadas de forma sistemática e em alta escala. Entretanto, um ponto de suma importância para termos uma atividade com o menor custo possível e alta disponibilidade é a implantação de sistemas gestão de combustíveis e de manutenção, eliminando-se assim a dependência de apontamentos manuais, que para serem integrados aos sistemas de gestão demandam de ações humanas.

A redução do consumo de combustível impacta diretamente na redução do custo da madeira produzida, bem como contribui para a mitigação de gases de efeito estufa, pontos relacionados as questões de Environmental, Social, and corporate Governance [ESG], cada dia mais presentes na nossa sociedade. Uma economia no consumo de combustível nos harvesters de colheita florestal pode ser conseguida através de capacitação de operadores, a qual está dentro da rotina da equipe de corte e através de conjuntos de equipamentos com melhores performance operacional, litros/m<sup>3</sup> produzido.

## Processo de Colheita Florestal

Foi somente a partir da década de 1990, com a abertura das importações, falta de mão de obra no campo e também a necessidade de se executar o trabalho de forma mais ergonômica e com maior eficiência, que as empresas iniciaram a mecanização das operações de colheita de forma mais intensiva.

Atualmente, os principais métodos de colheita mecanizada são: “árvore completa” ( full-tree [FT]) e o de “corte no comprimento” (cut-to-length [CTL]). O método FT, como o nome diz as áreas são cortadas inteiras, utilizando-se Feller Buncher e depois essas são arrastadas para a borda do talhão e então processadas para transporte. No método CTL, o harvester abate a árvore e processa em diferentes medidas dentro do talhão, as quais são posteriormente baldeada para a borda utilizando-se de Forwarders. É típico para o método CTL o

processamento de diferentes dimensões de toras, que são chamadas sortimentos, derivados de uma mesma árvore (Miolanem, 2021).

Na Suzano, temos os dois sistemas operacionais, FT e CTL, porém o CTL é o predominante no processo, sendo que temos múltiplos sortimento de madeira, variando-se o comprimento da madeira conforme configuração das fábrica que recebem essa madeira, no processo CTL, processamos a madeira sem casca até um diâmetro de 4cm, deixando no interior do talhão os resíduos, cascas, galhos e folhas, os quais são incorporados como adubação verde ao próximo ciclo de produção florestal, otimizando-se assim os custos para formação do próximo ciclo de produção florestal.

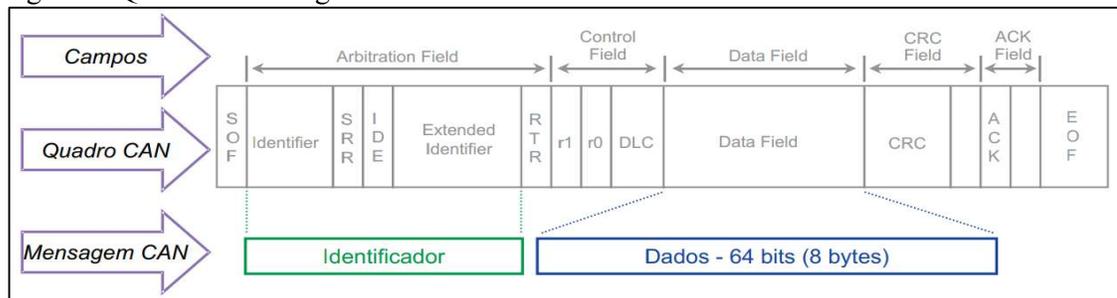
## CAN Bus

A CAN Bus ou Barramento Controller Area Network, foi desenvolvido pela empresa alemã Robert BOSCH e disponibilizado em meados dos anos 80, tendo sua aplicação inicial focada em ônibus e caminhões. Atualmente, é amplamente utilizado na indústria, em veículos automotivos, navios e tratores, entre outros (Alexag, 2021). O CAN é um protocolo de comunicação serial síncrono, sendo que o sincronismo entre os módulos conectados à rede é feito em relação ao início de cada mensagem lançada ao barramento (evento que ocorre em intervalos de tempo conhecidos e regulares) (Alexag, 2021).

Os fundamentos do CAN são especificados por duas normas: a ISO11898 e a ISO11519-2. A primeira, ISO11898, determina as características de uma rede trabalhando com alta velocidade de transmissão de dados, de 125Kbps a 1Mbps. A segunda, ISO11519-2, determina as características de uma rede trabalhando com baixa velocidade, de 10Kbps a 125Kbps (Alexag, 2021).

Toda comunicação das redes CAN é baseada em mensagens, que são transportadas em quadros de bits, que por sua vez são formadas por campos, que são conjuntos de bits com determinada função no quadro (MAPA, 2001). O esquema apresentado na Figura 1, ilustra uma mensagem CAN e dos tipos de quadro de dados do CAN, formado por campos de bits.

Figura 1. Quadro e Mensagens CAN



Fonte: MAPA (2001)

Uma mensagem da CAN é formada pelo **Campo de Dados**, ao qual está associado um campo que caracteriza a mensagem. No caso do CAN, este campo que caracteriza a mensagem é denominado **Identificador**, e define a prioridade de cada mensagem. O valor do identificador para as mensagens de cada nó é exclusivo, e quanto mais baixo o valor de um **Identificador** maior é a prioridade das mensagens desse nó. Utilizando um identificador os vários nós fazem o escalonamento do acesso ao meio. Quando os nós recebem a mensagem transmitida por um determinado nó, realizam o teste de aceitação e verificam se a mensagem tem interesse para esse nó ou não, através do identificador, (MAPA, 2001).

Os dados utilizados foram oriundos de uma Proof of Concept [POC], realizado na Suzano no segundo semestre de 2021, em conjunto com a empresa IoTag (<https://iotag.com.br>), a qual é detentora da tecnologia para leitora de rede CAN Bus dos Harvester da desta empresa.

## Objetivo

O objetivo do presente estudo, é apresentar uma alternativa para melhorarmos a gestão de diesel no processo de colheita florestal, utilizando técnicas de data mining e machine learning, sendo que para isso foi feita a leitura dos dados presente na rede CAN Bus de 3 Harvestes, para obtenção do consumo instantâneo e outras variáveis que possam estar relacionadas à sua variação.

Como objetivos específicos temos:

- Ler a rede CAN das máquinas florestais, Harvester;
- Avaliar a quantidade de informações, periodicidade de informações que são, possível de serem coletadas da rede CAN Bus dos Harvesters;
- Analisar e comparar as variações de faixa de consumo ocorridas nos 3 turnos operacionais;
- Propor um cenário para otimização do consumo de diesel, baseado nos dados coletados;
- Avaliar se podemos através de técnicas de data mining e machine learning, diferenciar os operadores em duas classes, relacionadas ao consumo de combustível.

## Material e Métodos

Esse trabalho foi desenvolvido, utilizando-se dados da leitura da CAN Harvesters, tratores especializados em corte de madeira, que fazem parte do parque de máquinas da Suzano S/A, na unidade SP, a escolha dessas máquinas se deve ao processo de POC (Proof Of Concept) que foi conduzida na Suzano, junto com a empresa IoTag (<https://iotag.com.br>), tem a tecnologia dos leitores de rede CAN Bus.

Para análise dos dados, foi feito uso da estatística descritiva, onde buscamos a comparação da variação do consumo entre máquinas e turnos, nos diferentes dias que temos dados coletados, buscamos uma alternativa para definir o melhor padrão de consumo, bem como uma proposta de como buscar esse padrão nos demais turnos e máquinas.

A partir da análise exploratória dos dados, buscamos através da correlação de Pearson, a qual é uma medida que varia entre -1 e 1, onde por meio do sinal resultante, podemos identificar o tipo de relação linear entre as variáveis analisadas, onde quanto mais próximo dos extremos (-1 e 1) mais forte é a correlação entre as variáveis (Fávero e Belfiore ,2022).

Segundo Fávero e Belfiore (2022), correlação positivas, indicam uma relação diretamente proporcional entre as variáveis, gerando uma correlação linear positiva, já correlações negativas, indicam uma relação inversamente proporcional entre as variáveis, gerando uma correlação linear negativa, valores nulos, demonstram que não existem correlações entre as variáveis.

Como identificamos algumas variáveis com melhor correlação com o consumo de diesel, buscamos avaliar se seria possível termos equações lineares, capaz de explicar a variação de consumo. No caso, optamos pela tentativa de uso de equações múltipla, onde mais de uma variável ( $X_1, X_2, X_n$ ) é utilizada para tentar explicar a variação de consumo de diesel ( $Y$ ).

Fávero e Belfiore (2022), comentam que o conceito *ceteris paribus* (mantidas as demais condições constantes), deve ser utilizado na análise da regressão múltipla, uma vez que a interpretação do parâmetro de cada variável será feita isoladamente. Assim um modelo com

duas variáveis explicativas,  $X_1$  e  $X_2$ , os respectivos coeficientes serão analisados de forma a considerar todos os outros fatores constantes.

Como temos dados com alta multicolinearidade, entre as possíveis variáveis explicativas para o consumo de Diesel, a alternativa para identificar melhor os padrões de comportamento, foi trabalharmos com análise de agrupamentos, a qual segundo Fávero e Belfiore (2022), são muito úteis e que podem ser aplicadas quando há a intenção de se verificar a existência de comportamentos semelhantes entre as observações, em relação a determinadas variáveis e o objetivo de se criar grupos ou clusters, em que prevaleça a homogeneidade interna.

No nosso caso, essa homogeneidade tem o objetivo de identificarmos os melhores operadores, visando não citar nomes, iremos trabalhar com os dados agrupados por turno operacional, onde criaremos duas classes, que chamaremos neste trabalho de Operador Ótimo (1) e Operador Oportunidade (0), respectivamente associados à operadores com média de consumo menor ou igual a média do Harvester no período e operadores com média de consumo maior que a média do Harvester no período.

Buscando identificar padrões, utilizamos um método relativamente simples, porém com excelentes resultados, K-Nearest Neighbors [K-NN], o qual permite com baixo poder de processamento, análise e inferência em grandes volumes de dados. É um dos muitos algoritmos, de aprendizagem supervisionada, usado no campo de data mining e machine learning, ele é um classificador onde o aprendizado é baseado “no quão similar” é um dado (um vetor) do outro. O treinamento é formado por vetores de “n” dimensões.

Segundo Rocha Neto e Menezes Jr (2019), o K-NN é um classificador sub-ótimo que cria fronteiras de decisões complexas a partir de um conjunto de padrões de treinamento com classes conhecidas a priori. Mais precisamente, para um dado vetor característico no conjunto teste, os vetores de K mais próximos no conjunto de treino são selecionados de acordo com alguma medida de distância e o vetor de características de teste é atribuído ao rótulo mais representado na classe dos K vizinhos.

Classificar um exemplo desconhecido com o algoritmo K-NN pode ser resumido nos seguintes passos (Rocha Neto e Menezes Jr, 2019), (Figura 2):

- Calcular a distância entre o exemplo desconhecido e os outros exemplos do conjunto de treinamento;
- Identificar os K vizinhos mais próximos;
- Utilizar o rótulo da classe de vizinhos mais próximos para determinar o rótulo de classe do exemplo desconhecido em uma espécie de votação.

## Resultados e Discussão

Durante a POC, conseguimos ler a rede CAN Bus de 3 Harvesters Komatsu PC200F com cabeçote processador, conforme Tabela 1 e no Anexo 1 onde estão listadas as variáveis lidas.

Tabela 1. Lista de Harvester, dias com dados coletados e horas trabalhadas

Nome Equipamento	Dias de Leitura da Rede CAN Bus	Horas Totais Trabalhadas
HV – Estrovenga		942h 25min 00seg
HV – Relâmpago	55 (7/out a 30/nov/2021)	1.007h 44min 11seg
HV - Magnata		1.061h 34min 06seg
Total		3.011h 43min 17 seg

Fonte: Resultados da pesquisa

Buscando uma análise inicial dos dados, fizemos uso da estatística descritiva a qual fornece resumos simples sobre as amostras, segregadas por Harvester, sobre as observações que foram feitas, durante a coleta de dados. Tabela 2.

Vale aqui explicar como funcionam os turnos na Suzano S/A, são todos de 8 horas sendo que o primeiro turno, inicia-se as 00:00 horas, o segundo turno inicia-se as 08:00 horas e o terceiro turno inicia-se as 16:00 horas.

Analisando a Tabela 2, podemos notar que uma variação considerável entre os Harvesters, sendo o HV – Estrovenga com o pior consumo médio, também temos variações, menores, mas não menos importantes entre os turnos em um mesmo Harvester, lembrando que como estamos olhando para todos os dados coletados, temos uma variação de operadores, sendo que um mesmo operador pode ter trabalhado em mais de um turno, aqui não vamos entrar no detalhe a nível de operador.

Analisando-se a média dos três turnos, o melhor Harvester, foi o HV – Relâmpago, com consumo médio de 21,50 litros/hora trabalhada, seguido pelo HV – Magnata com 21,68 litro/hora trabalhada, já o HV – Estrovenga, teve o pior consumo médio de 23,22 litro/hora, sendo estes harvesters, respectivamente, 0,79% e 7,40% acima do HG - Relâmpago.

Tabela 2. Análise descritiva dos dados

Harvester	Turno	Variação Consumo (L/H)		
		Mínimo	Médio	Máximo
HV - Estrovenga	Primeiro	5,14	23,14	45,00
	Segundo	5,07	23,11	45,00
	Terceiro	5,10	23,41	47,37
	Média	5,07	23,22	47,37
HV - Relâmpago	Primeiro	5,14	21,21	45,00
	Segundo	5,14	21,55	45,00
	Terceiro	5,14	21,78	45,00
	Média	5,14	21,50	45,00
HV - Magnata	Primeiro	5,14	21,41	45,00
	Segundo	5,10	21,79	45,00
	Terceiro	5,08	21,84	45,00
	Média	5,08	21,68	45,00

Fonte: Resultados da pesquisa

Olhando o alto consumo do HV – Estrovenga, as possíveis explicações para a grande variação de consumo, seria comportamento dos operadores que trabalham neste Harvester, porém pela leitura da rede CAN Bus, o HV – Estrovenga é o equipamento com mais horas trabalhadas, 19.619 horas contra 3.143 e 8.429 horas respectivamente dos HV – Magnata e do HV – Relâmpago (Tabela 3). Baseado nesta variação do horímetro, não podemos inferir somente com dados da rede CAN Bus, que somente os operadores são responsáveis pela variação de consumo, precisaríamos avaliar também as condições de manutenção das máquinas.

Tabela 3. Variação do Horímetro dos Harvesters durante a POC

Harvester	Horímetro Final POC
HV Estrovenga	19.619
HV Relâmpago	8.429
HV Magnata	3.143

Fonte: Resultados da pesquisa

No Anexo 2, apresentamos a variação de consumo diária por máquina, assim podemos ter um melhor detalhamento da variação média, o que nos permite demonstrar que trabalhar com uma média diária é muito mais eficiente do que trabalhar com uma média de um período, Anexo 2 comparado com a Tabela 2.

Já na Tabela 4, demonstramos a melhor e pior média de cada um dos Harvesters segregados por Turno, bem como o percentual de oportunidade que temos na variação dessas duas métricas. Sendo que o HV – Estrovenga no primeiro turno apresentou a maior variação de média diária, 18,86 litros/hora no melhor dia contra 24,95 litros/hora no pior dia, uma variação de 32,3% já o HV – Magnata, teve a menor variação percentual, a qual ocorreu no segundo turno, mesmo assim sendo um valor bastante considerável, 13,8%, 20,05 litros/hora no melhor dia contra 22,80 litros/hora no pior dia.

Parte dessas variações podem ser explicadas devido as diferenças de produtividade (m<sup>3</sup>), relevo do terreno, nas áreas trabalhadas no período da POC, porém podemos notar que o HV – Magnata, que é o mais novo de todos apresentou-se a menor variação dentro os 3 HV, evidenciando aqui que temos alguma oportunidade na manutenção e regulação das máquinas com o avanço na sua utilização (horímetro).

Tabela 4. Resumo do consumo por turno e Harvesters

Métrica	HV - Estrovenga			HV - Relâmpago			HV - Magnata		
	1° Turno	2° Turno	3° Turno	1° Turno	2° Turno	3° Turno	1° Turno	2° Turno	3° Turno
Melhor Média	18,86	20,37	20,33	18,78	18,60	18,94	19,54	20,05	20,02
Pior Média	24,95	24,15	24,69	22,66	23,98	23,53	22,81	22,80	23,23
% Variação									
Melhor vs Pior Média	32,3%	18,6%	21,5%	20,6%	28,9%	24,2%	16,8%	13,8%	16,0%

Fonte: Resultados da pesquisa

Analisando-se a variação da melhor média, entre os turnos, notamos que o HV-Estrovenga tem uma variação média do melhor turno com os outros dois de 7,9%, já o HV-Relâmpago tem uma variação de 1,4% entre o melhor turno e os demais e finalmente o HV-Magnata tem uma variação média de 2,5% entre o melhor turno e os demais. Mais uma evidência que temos oportunidades na manutenção e regulagens do HV-Estrovenga, melhorando assim sua variação de consumo.

Considerando uma hipótese, de melhorarmos o desempenho entre os turnos em cada HV de permitirmos uma variação da média de até +10%, utilizando-se a melhor média de cada HV, temos as seguintes hipóteses:

- HV-Estrovenga, 18,86 litros/hora, no primeiro turno, temos um limite operacional de 20,75 litros/hora;
- HV-Relâmpago, 18,60 litros/hora, no primeiro turno, temos um limite operacional de 20,46 litros/hora.
- HV-Magnata, 19,54 litros/hora, no primeiro turno, temos um limite operacional de 21,49 litros/hora.

Também podemos considerar que deveríamos buscar uma meta de consumo para todas as máquinas, sendo essa meta definida pelo melhor consumo registrado, que é do HV-Relâmpago, 18,60 litros/hora + 10% = 20,46 litros/hora. Com base neste limite operacional,

simulamos a oportunidade de redução de diesel, se todo consumo acima dessa média independente do Harvester e/ou turno, for evitado.

Nas tabelas 5 e 6, demonstramos respectivamente o total de horas trabalhadas acima da meta de consumo, 20,46 litros/hora, evidenciando qual seria o ganho potencial de litros de diesel se trabalhássemos para atingir essa meta.

Tabela 5. Horas trabalhadas acima da meta definida (20,46 litros/hora) de consumo

Turnos	HV Estrovenga	HV Relâmpago	HV Magnata	Total Geral
Primeiro	246h 56min 08seg	163h 12min 18seg	183h 43min 09seg	593h 51min 35seg
Segundo	236h 51min 58seg	161h 58min 01seg	201h 06min 54seg	599h 56min 53seg
Terceiro	253h 23min 24seg	190h 39min 24seg	220h 05min 50seg	664h 08min 38seg
Total Geral	737h 11min 30seg	515h 49min 43seg	604h 55min 53seg	1.857h 57min 06seg

Fonte: Resultados da pesquisa

Considerando que temos aproximadamente 3.012 horas efetivamente trabalhadas registradas (Tabela 1), contamos pela análise da tabela 5, que em mais de 60% do tempo trabalhamos com acima da meta.

Tabela 6. Oportunidade de redução de consumo de Diesel, baseado na meta definida

Turnos	HV Estrovenga	HV Relâmpago	HV Magnata	Total Geral
Primeiro	864	437	476	1.777
Segundo	825	454	521	1.801
Terceiro	923	520	562	2.005
Total Geral	2.612	1.411	1.559	5.583

Fonte: Resultados da pesquisa

Analisando-se os dados da Tabela 5, temos para o período analisado, quase 1.860 horas trabalhadas acima da meta definida para o consumo de diesel (+10%), o que gerou um consumo extra de diesel de 5.583 litros (Tabela 6) para os 3 Harvesters durante os 55 que tivemos monitoramento das atividades.

O grande desafio é como tornar esse monitoramento sistemático e efetivo para que possamos realmente termos ganhos operacionais com a redução do consumo de diesel, sendo que se atingirmos esse objetivo teríamos um ganho de 8,23% no total de litros consumidos.

Assim sendo, baseando-se nos dados coletados da Rede CAN Bus, quais seriam as variáveis monitoradas, apresentam melhor correlação ao consumo de combustível. Começamos pela análise do Engine Speed, mais conhecido como RPM. A Tabela 7, apresenta 5 classes de RPM que estratificamos os dados e sua média de consumo por turno para cada um dos HV. Assim podemos demonstrar que conforme aumenta o giro do motor diesel, maior é o consumo médio, sendo que acima de 1.800 RPM temos uma variação média superior a 20% quando comparado à operação na faixa de 1.650 até 1.800 RPM.

Tabela 7. Variação do consumo (litro/hora) por faixa de RPM

Faixa RPM	Turnos	HV Estrovenga	HV Relâmpago	HV Magnata	Total Geral
menor a 1.200	Primeiro	12,2	13,7	11,9	12,4
	Segundo	11,6	13,0	12,6	12,3

RPM	Terceiro	14,3	15,1	13,5	14,1
1.200	Primeiro	12,9	12,0	13,8	12,7
a 1.650	Segundo	12,7	12,1	13,3	12,6
RPM	Terceiro	13,3	11,9	13,4	12,8
1.650	Primeiro	21,2	17,1	17,8	19,4
a 1.800	Segundo	19,2	17,5	18,5	18,5
RPM	Terceiro	18,7	17,9	18,5	18,4
1.800	Primeiro	23,5	21,6	21,8	22,3
a 1.900	Segundo	23,6	22,0	22,1	22,6
RPM	Terceiro	23,8	22,1	22,1	22,7
acima	Primeiro	24,0	21,3	20,9	21,6
1.900	Segundo	24,4	21,9	22,3	22,5
RPM	Terceiro	24,5	22,1	22,0	22,6

Fonte: Resultados da pesquisa

Podemos notar que a maior parte do tempo, os 3 Harvesters operam na faixa de 1.800 a 1.900 RPM. Uma avaliação futura da faixa de RPM ótima operacional, pode apresentar oportunidades aqui não avaliadas, relacionando a faixa de RPM capaz de atender a demanda hidráulica do cabeçote de processamento.

Na Tabela 9, verificamos o consumo em litro, para cada uma das faixas de RPM criadas, onde podemos notar que trabalhando acima de 1.900 RPM temos o consumo de 7.797,0 Litros, correspondente à 11,5% do total consumido durante a POC, bastante significativo.

Tabela 9. Consumo (Litros Totais) para nas faixas de RPM por HV

Faixa RPM	HV Estrovenga	HV Relâmpago	HV Magnata	Total Geral
< 1.200	118,5	73,0	120,5	312,0
1.200 – 1.650	599,5	709,0	448,5	1.757,0
1.650 – 1.800	616,5	377,5	373,5	1.367,5
1.800 – 1.900	18.641,5	19.014,0	18.935,0	56.590,5
> 1.900	1.452,0	3.017,5	3.327,5	7.797,0
Total Geral	21.428,0	23.191,0	23.205,0	67.824,0

Fonte: Resultados da pesquisa

Separamos então, 15 variáveis para avaliarmos a correlação de Pearson entre elas, como uma forma de identificar potenciais oportunidades de atuação operacional. Nas Tabelas 10, 11 e 12, temos a matriz de correlação de Pearson, para cada um dos HV analisados, para esse grupo de variáveis. Podemos notar que com o consumo de combustível (L/hora) somente 4 variáveis apresentaram correlação superior a 20% nos três HV estudados.

Sendo que 2 variáveis têm correlação superior a 50% nos três HV estudados, sendo elas, **Engine Percent Load At Current Speed** – 59,2%, 56,6% e 52,3%, **Actual Engine - Percent Torque** – 60,8%, 59,1% e 55,1% nos respectivos HV – Estrovenga, HV – Relampago e HV – Magnata.

A variável **Accelerator Pedal Position 1** apresentou correlação de 50,3%, 50,3% e 45,4% nos respectivos HV – Estrovenga, HV – Relampago e HV - Magnata. Enquanto que variável **Engine Speed** apresentou correlação de 45,7%, 44,2% e 39,9% nos respectivos HV – Estrovenga, HV – Relampago e HV – Magnata.

Finalmente a última variável com correlação superior a 20% foi a **Engine Torque Mode**, tem uma correção de 22,2%, 29,1% e 27,6 nos respectivos HV – Estrovenga, HV – Relampago e HV – Magnata, as demais variáveis tem correlações abaixo de 20% com o consumo de combustível (L/hora).

Tabela 10. Correlação de Pearson para as variáveis selecionadas – HV Estrovenga

	Engine Total Idle Hours	Nominal Friction - Percent Torque	Engine Total Hours of Operation	Engine Total Revolutions	Engine Coolant Temperature	Engine Oil Temperature 1	Engine Oil Pressure	Accelerator Pedal Position 1	Engine Percent Load At Current Speed	Engine Torque Mode	Actual Engine Percent Torque	Engine Speed	Engine ECU Temperature	Total ECU Run Time	L/hora
Engine Total Idle Hours	100,0%														
Nominal Friction	0,4%	100,0%													
Engine Total Hours of Operation	98,0%	0,6%	100,0%												
Engine Total Revolutions	97,8%	0,6%	100,0%	100,0%											
Engine Coolant	-16,8%	3,8%	-19,4%	-19,5%	100,0%										
Engine Oil Temperature	-17,0%	3,7%	-19,7%	-19,8%	99,9%	100,0%									
Engine Oil Pressure	-0,8%	15,7%	-1,1%	-1,1%	1,1%	1,1%	100,0%								
Accelerator Pedal	-4,1%	10,4%	-3,5%	-3,5%	16,1%	16,0%	1,5%	100,0%							
Engine Percent Load	12,1%	8,6%	11,9%	11,9%	16,2%	15,9%	2,3%	71,2%	100,0%						
Engine Torque Mode	-2,5%	1,9%	-2,7%	-2,7%	3,8%	3,9%	1,5%	43,9%	21,3%	100,0%					
Actual Engine Percent	12,1%	8,8%	11,9%	11,9%	16,5%	16,2%	2,4%	73,2%	96,5%	21,3%	100,0%				
Engine Speed	-7,7%	11,3%	-7,1%	-7,0%	15,7%	15,6%	1,3%	97,6%	65,4%	97,4%	67,7%	100,0%			
Engine ECU Temperature	20,8%	22,6%	18,8%	18,6%	50,5%	50,2%	2,8%	10,5%	26,1%	-2,8%	26,4%	7,5%	100,0%		
Total ECU Run Time	97,8%	0,6%	100,0%	100,0%	-19,5%	-19,8%	-1,1%	-3,5%	11,8%	-2,7%	11,8%	-7,6%	18,6%	100,0%	
L/hora	9,2%	5,3%	8,9%	8,9%	7,8%	7,6%	2,3%	50,3%	59,2%	22,2%	60,8%	45,7%	15,6%	8,9%	100,0%

Fonte: Resultados originais da pesquisa

Tabela 11. Correlação de Pearson para as variáveis selecionadas – HV Relâmpago

	Engine Total Idle Hours	Nominal Friction - Percent Torque	Engine Total Hours of Operation	Engine Total Revolutions	Engine Coolant Temperature	Engine Oil Temperature 1	Engine Oil Pressure	Accelerator Pedal Position 1	Engine Percent Load At Current Speed	Engine Torque Mode	Actual Engine Percent Torque	Engine Speed	Engine ECU Temperature	Total ECU Run Time	L/hora
Engine Total Idle Hours	100,0%														
Nominal Friction	-1,7%	100,0%													
Engine Total Hours of Operation	99,2%	-1,4%	100,0%												
Engine Total Revolutions	99,1%	-1,4%	100,0%	100,0%											
Engine Coolant	8,3%	6,0%	8,7%	8,7%	100,0%										
Engine Oil Temperature	8,5%	6,0%	8,9%	8,9%	99,8%	100,0%									
Engine Oil Pressure	5,0%	17,7%	5,3%	5,3%	0,9%	0,9%	100,0%								
Accelerator Pedal	1,4%	8,3%	1,1%	1,0%	20,2%	20,3%	0,6%	100,0%							
Engine Percent Load	21,0%	6,1%	21,2%	21,2%	26,8%	27,0%	3,8%	66,0%	100,0%						
Engine Torque Mode	4,7%	2,3%	4,2%	4,2%	8,5%	8,5%	-0,1%	46,3%	30,0%	100,0%					
Actual Engine Percent	22,4%	6,4%	22,6%	22,6%	28,2%	28,4%	3,7%	69,0%	94,1%	30,7%	100,0%				
Engine Speed	-5,8%	9,2%	-6,2%	-6,2%	17,8%	17,8%	0,3%	97,1%	57,7%	38,8%	60,8%	100,0%			
Engine ECU Temperature	4,1%	15,8%	4,9%	5,0%	68,9%	69,0%	3,5%	7,2%	23,9%	-1,9%	24,8%	3,9%	100,0%		
Total ECU Run Time	99,1%	-1,4%	100,0%	100,0%	8,7%	8,9%	5,3%	1,1%	21,2%	4,2%	22,6%	-6,2%	5,0%	100,0%	
L/hora	14,4%	3,4%	14,3%	14,3%	13,4%	13,5%	2,4%	50,3%	56,6%	29,1%	59,1%	44,2%	13,2%	14,3%	100,0%

Fonte: Resultados originais da pesquisa

Tabela 12. Correlação de Pearson para as variáveis selecionadas – HV Magnata

	Engine Total Idle Hours	Nominal Friction - Percent Torque	Engine Total Hours of Operation	Engine Total Revolutions	Engine Coolant Temperature	Engine Oil Temperature 1	Engine Oil Pressure	Accelerator Pedal Position 1	Engine Percent Load At Current Speed	Engine Torque Mode	Actual Engine Percent Torque	Engine Speed	Engine ECU Temperature	Total ECU Run Time	L/hora
Engine Total Idle Hours	100,0%														
Nominal Friction	5,1%	100,0%													
Engine Total Hours of Operation	97,4%	5,5%	100,0%												
Engine Total Revolutions	97,3%	5,5%	100,0%	100,0%											
Engine Coolant	-2,3%	12,0%	6,0%	6,1%	100,0%										
Engine Oil Temperature	-2,4%	12,1%	6,0%	6,1%	99,3%	100,0%									
Engine Oil Pressure	-0,2%	9,5%	-0,9%	-1,0%	2,9%	2,8%	100,0%								
Accelerator Pedal	-4,0%	9,5%	-3,9%	-3,9%	33,9%	34,1%	3,0%	100,0%							
Engine Percent Load	-11,1%	3,8%	-10,5%	-10,4%	31,4%	31,7%	3,7%	69,2%	100,0%						
Engine Torque Mode	0,1%	-0,5%	-0,1%	-0,1%	11,6%	11,5%	1,0%	46,7%	30,0%	100,0%					
Actual Engine Percent	-11,5%	5,0%	-10,9%	-10,8%	33,9%	34,2%	3,7%	72,9%	93,2%	30,2%	100,0%				
Engine Speed	-1,9%	12,2%	-2,0%	-2,0%	34,4%	34,6%	3,0%	97,1%	61,4%	39,1%	66,0%	100,0%			
Engine ECU Temperature	-6,0%	6,5%	-1,5%	-1,8%	52,2%	52,2%	-0,1%	4,9%	13,4%	-0,2%	14,1%	2,9%	100,0%		
Total ECU Run Time	97,5%	5,5%	100,0%	100,0%	6,0%	6,0%	-0,9%	-3,9%	-10,4%	-0,1%	-10,8%	-2,0%	-1,4%	100,0%	
L/hora	-8,2%	1,4%	-7,6%	-7,6%	10,8%	10,9%	2,4%	45,4%	52,3%	27,0%	55,3%	39,9%	9,4%	-7,6%	100,0%

Fonte: Resultados originais da pesquisa

Baseando-se nestas correlações, avaliamos construir uma equação multivariada, por mínimos quadrados para o consumo (L/hora), apresentadas na Tabela 13, com as 5 viáveis com as melhores correlações, citadas acima.

Tabela 13. Equações multivariadas elaboradas

Harvester	Equações Geradas
HV Estrovenga	$L/hora = 15.602 + 0.15108*APP + 0.015704*EPLCS + 0.23714*ETM + 0.18262*AEPT + -0.010406*RPM$
HV Relampago	$L/hora = 14.183 + 0.16907*APP + 0.019056*EPLCS + 0.27512*ETM + 0.15403*AEPT + -0.0097075*RPM$
HV Magnata	$L/hora = 16.11 + 0.14927*APP + 0.0085225*EPLCS + 0.3293*ETM + 0.18078*AEPT + -0.010432*RPM$

Fonte: Resultados originais da pesquisa

Os resultados de todas as equações apresentaram R<sup>2</sup> abaixo de 40%, indicando que podem existir outros fatores que determinam o consumo de combustíveis (L/hora), não podendo ser explicado satisfatoriamente com as 5 variáveis com melhor correlação de Pearson, coletadas pela rede CAN Bus, com o consumo (L/hora).

Também é possível identificar pelos resultados, que existe forte multicolinearidade entre as variáveis independentes, como temos um grande volume de dados, a sugestão é que existe realmente um relacionamento entre as variáveis analisadas, visto que todas são provenientes da rede CAN Bus das máquinas.

Figura 3. Resultado da OLS

HV Estrovenga						HV Relâmpago						HV Magnata					
OLS Regression Results						OLS Regression Results						OLS Regression Results					
Dep. Variable:	L/hora	R-squared:	0.384	Dep. Variable:	L/hora	R-squared:	0.375	Dep. Variable:	L/hora	R-squared:	0.322						
Model:	OLS	Adj. R-squared:	0.384	Model:	OLS	Adj. R-squared:	0.375	Model:	OLS	Adj. R-squared:	0.322						
Method:	Least Squares	F-statistic:	5204.	Method:	Least Squares	F-statistic:	4982.	Method:	Least Squares	F-statistic:	4282.						
Date:	Fri, 22 Apr 2022	Prob (F-statistic):	0.00	Date:	Fri, 22 Apr 2022	Prob (F-statistic):	0.00	Date:	Fri, 22 Apr 2022	Prob (F-statistic):	0.00						
Time:	12:36:25	Log-Likelihood:	-1.0763e+05	Time:	13:13:12	Log-Likelihood:	-1.0404e+05	Time:	12:37:02	Log-Likelihood:	-1.0893e+05						
No. Observations:	41731	AIC:	2.153e+05	No. Observations:	41510	AIC:	2.081e+05	No. Observations:	44273	AIC:	2.179e+05						
Df Residuals:	41725	BIC:	2.153e+05	Df Residuals:	41504	BIC:	2.081e+05	Df Residuals:	44267	BIC:	2.179e+05						
Df Model:	5			Df Model:	5			Df Model:	5								
Covariance Type:	nonrobust			Covariance Type:	nonrobust			Covariance Type:	nonrobust								
	coef	std err	t	P> t	[0.025	0.975]											
const	15.6018	0.067	17.988	0.000	13.902	17.302	const	14.1829	0.797	17.794	0.000	12.621	15.745				
x1	0.1511	0.009	15.985	0.000	0.132	0.170	x1	0.1691	0.009	19.572	0.000	0.152	0.186				
x2	0.0157	0.006	2.782	0.005	0.005	0.027	x2	0.0191	0.004	4.418	0.000	0.011	0.028				
x3	0.2371	0.021	11.511	0.000	0.197	0.278	x3	0.2751	0.020	13.523	0.000	0.235	0.315				
x4	0.1826	0.006	30.878	0.000	0.171	0.194	x4	0.1540	0.005	32.711	0.000	0.145	0.163				
x5	-0.0104	0.001	-12.874	0.000	-0.012	-0.009	x5	-0.0097	0.001	-13.307	0.000	-0.011	-0.008				
Omnibus:	37250.789	Durbin-Watson:	2.256	Omnibus:	42535.014	Durbin-Watson:	2.134	Omnibus:	46229.399	Durbin-Watson:	2.150						
Prob(Omnibus):	0.000	Jarque-Bera (JB):	1637425.867	Prob(Omnibus):	0.000	Jarque-Bera (JB):	2658356.105	Prob(Omnibus):	0.000	Jarque-Bera (JB):	3207516.291						
Skew:	4.219	Prob(JB):	0.00	Skew:	5.165	Prob(JB):	0.00	Skew:	5.291	Prob(JB):	0.00						
Kurtosis:	32.504	Cond. No.	1.03e+05	Kurtosis:	40.819	Cond. No.	1.03e+05	Kurtosis:	43.333	Cond. No.	1.04e+05						

Fonte: Resultados originais da pesquisa

Baseando-se nestes resultados, devido a multicolinearidade dos dados, onde as variáveis explicativas tem alta correlação entre si, o que pode ser observado analisando-se as tabelas de correlações, buscamos alternativas para trabalhar a informação, sendo que para tal, vamos trabalhar somente com os dados do HV – Magnata, por esse ser o HV mais novo, menor horímetro, onde se espera, eliminar com isso, pontos que não são abordados nesse estudo como por exemplo, diferenças na manutenção preventiva das máquinas ou mesmo desgastes de componentes do motor devido ao avanço do uso dos equipamentos.

A primeira abordagem feita, foi classificar os dados do HV – Magnata, baseando-se na média do consumo por dia e turno em duas classes, **Operador Ótimo** e **Operador Oportunidade**, dados apresentados no Anexo 2. Assim consideramos **Operador Ótimo** (1) os que tiverem a média de consumo menor ou igual a média geral do Harvester no período analisado e **Operador Oportunidade** (0) os que tiverem a média superior a média geral no período.

Com essa separação, utilizando-se as 5 variáveis com melhor correlação de Pearson, (Tabela 12), buscamos avaliar a utilização o algoritmo K-NN para avaliar quanto ele seria assertivo nessa separação, a sua avaliação inicial deve-se principalmente pela simplicidade de sua utilização e baixa demanda computacional.

Na Tabela 14 e Figura 6, são apresentados os resultados obtidos com o K-NN, para o HV- Magnata variando-se somente o número de vizinhos.

Tabela 14. Resultados da classificação K-NN

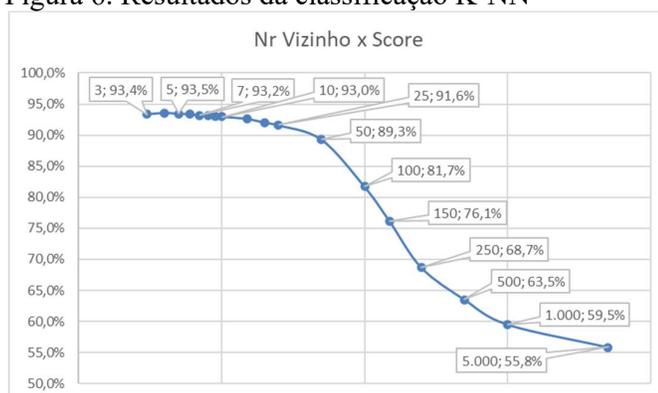
Nr. Vizinho n_neighbors	Cross Validation - Score Obtido
3	93,37%
4	93,59%
5	93,45%
6	93,40%
7	93,17%
8	93,10%
9	93,07%
10	92,99%
15	92,62%
20	92,03%
25	91,58%
50	89,29%
100	81,71%
150	76,12%
250	68,66%
500	63,50%
1.000	59,49%
5.000	55,84%

Fonte: Resultados originais da pesquisa

Notamos que a melhor acurácia do K-NN, Figura 6, foi conseguida com 4 vizinhos, 94,8%, com precisão para **Operador Ótimo** e **Operador Oportunidade**, foi de 94,2% e 95,6% respectivamente, com f-score de 95,4% e 94,0% para **Operador Ótimo** e **Operador Oportunidade** respectivamente.

Pelos resultados, notamos que o K-NN, apresentou melhores resultados com poucos vizinhos, demonstrando os dados tem baixa similaridade entre os dados da rede CAN Bus, quando passamos de 10 vizinho, já temos uma perda considerável no Score obtido. Assim sendo, avaliamos a acurácia, via matriz de confusão para identificar qual a melhor escolha para o Nr. de vizinhos (Figura 7).

Figura 6. Resultados da classificação K-NN



Fonte: Resultados originais da pesquisa

O uso do algoritmo classificador K-NN para diferenciar um **Operador Ótimo** de um **Operador Oportunidade**, teve um alto poder de previsão.

A partir do treinamento efetuado com o K-NN, que apresentou uma alta acuraria, acima de 90%, abrindo a possibilidade de a partir de 1 medição curta de operação, classificar os operadores em relação a sua habilidade técnica com as máquinas, especialmente em relação ao menor consumo de gasolina, para direcionar treinamentos para os operadores que não conseguem economizar tanto combustível.

Figura 7. Matrizes de confusão para 3 até 10 vizinhos dos resultados do K-NN

Matriz Nr Vizinho = 3				Matriz Nr Vizinho = 4			
Classes	Operador Oportunidade	Operador Ótimo	Recall	Classes	Operador Oportunidade	Operador Ótimo	Recall
Operador Oportunidade	4607	290	94,1%	Operador Oportunidade	4728	169	96,5%
Operador Ótimo	251	3670	93,6%	Operador Ótimo	292	3629	92,6%
Precision	94,8%	92,7%		Precision	94,2%	95,6%	
f-score	94,5%	93,1%		f-score	95,4%	94,0%	
Acurácia	93,9%			Acurácia	94,8%		

Matriz Nr Vizinho = 5				Matriz Nr Vizinho = 6			
Classes	Operador Oportunidade	Operador Ótimo	Recall	Classes	Operador Oportunidade	Operador Ótimo	Recall
Operador Oportunidade	4617	280	94,3%	Operador Oportunidade	4675	222	95,5%
Operador Ótimo	208	3713	94,7%	Operador Ótimo	270	3651	93,1%
Precision	95,7%	93,0%		Precision	94,5%	94,3%	
f-score	95,0%	93,8%		f-score	95,0%	93,7%	
Acurácia	94,5%			Acurácia	94,4%		

Matriz Nr Vizinho = 7				Matriz Nr Vizinho = 8			
Classes	Operador Oportunidade	Operador Ótimo	Recall	Classes	Operador Oportunidade	Operador Ótimo	Recall
Operador Oportunidade	4577	320	93,5%	Operador Oportunidade	4583	314	93,6%
Operador Ótimo	202	3719	94,8%	Operador Ótimo	223	3698	94,3%
Precision	95,8%	92,1%		Precision	95,4%	92,2%	
f-score	94,6%	93,4%		f-score	94,5%	93,2%	
Acurácia	94,1%			Acurácia	93,9%		

Matriz Nr Vizinho = 9				Matriz Nr Vizinho = 10			
Classes	Operador Oportunidade	Operador Ótimo	Recall	Classes	Operador Oportunidade	Operador Ótimo	Recall
Operador Oportunidade	4541	356	92,7%	Operador Oportunidade	4598	299	93,9%
Operador Ótimo	191	3730	95,1%	Operador Ótimo	250	3671	93,6%
Precision	96,0%	91,3%		Precision	94,8%	92,5%	
f-score	94,3%	93,2%		f-score	94,4%	93,0%	
Acurácia	93,8%			Acurácia	93,8%		

Fonte: Resultados originais da da pesquisa

## Conclusões

A leitura dos dados da rede CAN Bus de Harvesters Floretais, é uma grande fonte de informações para identificarmos oportunidades operacionais, permitindo identificar padrões comportamentais de consumo de diesel entre operadores e conseqüentemente a classificação desses operadores em **Operadores Ótimos** e **Operadores Oportunidade**, gerando insights para focarmos os treinamentos operacionais nos operadores com maior consumo de diesel.

A quantidade de informações presentes na rede CAN Bus dos Harvesters avaliados, foi muito boa, também foi excelente a repetibilidade com que conseguimos coletar tais informações, utilizando a solução apresentada pela empresa IoTag.

Podemos também notar que entre máquinas e também entre os turnos operacionais nos mesmos Harvesters, tivemos uma grande variação no consumo de diesel, o que demonstra que temos oportunidades operacionais para serem trabalhadas.

No presente estudo acabamos utilizando somente de 5 variáveis, das presentes na CAN, futuramente temos oportunidades de estudas as demais variáveis e seu comportamento, talvez relacionado a hora exata de fazer a manutenção preventiva dos Harvesters, partindo-se assim para a tão desejada manutenção preditiva.

A utilização de equações multivariadas, para tentar explicar o consumo de diesel, não apresentou um bom  $R^2$ , uma das hipóteses, é a alta multicolinearidade das variáveis explicativas que propusemos usar neste trabalho, avaliar outras informações pode ser uma oportunidade para futuros trabalhos.

Já a utilização do classificador K-NN para diferenciar um **Operador Ótimo** de um **Operador Oportunidade**, utilizando-se para tal dados coletados da rede CAN Bus, tem um alto poder de previsão, com baixo consumo computacional para treinar o algoritmo K-NN o treinamento é executado em segundos, utilizando um computador I5-8265U CPU 1.6GHz e 16Gb de RAM.

A partir do treinamento efetuado com o K-NN, que apresentou uma alta acuraria, acima de 90%, mesmo com poucos dados processados, temos uma oportunidade de a partir de 1 medição curta de operação, exemplo 2 horas de trabalho operacional, classificar quais operadores tem ou não mais habilidade operacional, com foco no menor consumo de diesel, elencando assim os operadores que deveriam ter prioridade no treinamento operacional, auxiliando as equipe de Treinamento a focarem realmente nos operadores com maior necessidade.

Futuramente, com o avanço da leitura da CAN Bus dos joysticks dos Harvesters, incluir tais dados neste processo de classificação de operadores, podem gerar novos insights interessantes para o processo de treinamento e capacitação, possibilitando uma redução no consumo de combustível e até mesmo o desgaste prematura das peças.

## Referências

Alexag. CAN Bus – Barramento Controller Area Network. Disponível em: [http://www.alexag.com.br/CAN\\_Bus\\_Parte\\_2.html](http://www.alexag.com.br/CAN_Bus_Parte_2.html), - Acesso em: 04 out. 2021.

Fávero, L.P.; Belfiore, P. Manual de Análise de Dados. Reimpressão. Rio de Janeiro, LTC. 2022.

Indústria Brasileira de Árvores [IBÁ]. 2020 Relatório Anual. Disponível em: <https://iba.org/datafiles/publicacoes/relatorios/relatorio-iba-2020.pdf> Acesso em: 15 nov. 2021.

Ministério da Agricultura, Pecuária e Abastecimento [MAPA]. Circular Técnica 123. CAN (Controller Area Network): Um Padrão Internacional de Comunicação de Transdutores Inteligentes para Máquinas Agrícolas. São Carlo, SP – Out/2001.

Miolanem, T. O uso efetivo do método de colheita cut-to-length. Revista Opiniões. Março-Maio 2017: 46-47. Disponível em: <https://florestal.revistaopinioes.com.br/revista/detalhes/16-o-uso-efetivo-do-metodo-de-colheita-cut-length/> Acesso em: 11 abr. 2021.

Rocha Neto, W. B. da; Menezes Jr, J. M. P. Perfil de condução de motoristas: análise por meio de algoritmos de reconhecimento de padrões. Anais do Congresso Brasileiro de Automática, 2019.

Soeiro, V. M. N. Manutenção de máquinas florestais na colheita mecanizada: a busca para obter a melhor disponibilidade mecânica, TCC. UFPR, 2012.

## Anexos

### Anexo 1. Lista de variáveis que foram possíveis de ler da rede CAN Bus

<b>Lista de variáveis lidas</b>	<b>Qtde</b>
Data/Hora, Nome Máquina (HV), Lamp. Proteção, Lamp. Alarme, Lamp. Parada, timestamp, Source, Protect Lamp, Amber Warning Lamp, Red Stop Lamp, Malfunction Indicator Lamp, Failure Mode Identifier, Occurrence Count, SPN Conversion Method, Suspect Parameter Number, Accelerator Pedal Kickdown Switch, Road Speed Limit Status, Accelerator Pedal Position 1, Engine Percent Load At Current Speed, Remote Accelerator Pedal Position, Engine Torque Mode, Drivers Demand Engine - Percent Torque, Actual Engine - Percent Torque, Source Address of Controlling Device for Engine Control, Engine Speed, Auxiliary Temperature 1, Auxiliary Pressure #1, Engine ECU Temperature, Total ECU Run Time, Estimated Percent Fan Speed, Fan Drive State, Engine Total Idle Fuel Used, Engine Total Idle Hours, Nominal Friction - Percent Torque, Engines Desired Operating Speed Asymmetry Adjustment, Engines Desired Operating Speed, Total Power Takeoff Hours, Engine Trip Fuel, Engine Total Fuel Used, Engine Coolant Temperature, Engine Fuel Temperature 1, Engine Oil Temperature 1, Engine Oil Pressure, Engine Coolant Pressure, Engine Coolant Level, Engine Total Hours of Operation, Engine Total Revolutions, Engine Alternate Rating Select, Engine Alternate Droop Accelerator 1 Select, Engine Idle Shutdown Timer Function, Engine Wait to Start Lamp, Engine Protection System Configuration, Freeze Frame Length, Seconds, Minutes, Hours, Month, Day, Year, Compass Bearing, Navigation-Based Vehicle Speed, Latitude, Longitude, Altitude	59

Fonte: Resultados da pesquisa