

UNIVERSIDADE FEDERAL DE SANTA MARIA
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ELETRÔNICA E COMPUTAÇÃO
CURSO DE ENGENHARIA DE TELECOMUNICAÇÕES

Juliano Pereira Silveira

**DETECÇÃO DA OCORRÊNCIA DE DETONAÇÃO EM MOTORES DE
COMBUSTÃO INTERNA DE IGNIÇÃO POR CENTELHA BASEADA
EM REDES NEURAIIS ARTIFICIAIS**

Santa Maria, RS
2022

Juliano Pereira Silveira

**DETECÇÃO DA OCORRÊNCIA DE DETONAÇÃO EM MOTORES DE
COMBUSTÃO INTERNA DE IGNIÇÃO POR CENTELHA BASEADA EM REDES
NEURAIS ARTIFICIAIS**

Trabalho de conclusão de curso apresentado ao
Curso de Engenharia de Telecomunicações, da
Universidade Federal de Santa Maria (UFSM,
RS), como requisito parcial para obtenção do
título de **Engenheiro de Telecomunicações**.

Orientadora: Prof.^a Dr.^a Candice Müller

Santa Maria, RS
2022

Juliano Pereira Silveira

**DETECÇÃO DA OCORRÊNCIA DE DETONAÇÃO EM MOTORES DE
COMBUSTÃO INTERNA DE IGNIÇÃO POR CENTELHA BASEADA EM REDES
NEURAIS ARTIFICIAIS**

Trabalho de conclusão de curso apresentado ao
Curso de Engenharia de Telecomunicações, da
Universidade Federal de Santa Maria (UFSM,
RS), como requisito parcial para obtenção do
título de **Engenheiro de Telecomunicações**.

Aprovado em 24 de fevereiro de 2022:

Candice Müller, Dr.^a (UFSM)
(Presidente/Orientador)

Samuel Tumelero Valduga, Dr. (UFSM)

Thompson Diórdinis Metzka Lanzasova, PhD. (UFSM)

Santa Maria, RS
2022

AGRADECIMENTOS

Primeiramente, agradeço à Universidade Federal de Santa Maria pelo ensino de qualidade e excelência.

Agradeço imensamente a minha orientadora, Professora Candice Müller, por todos os ensinamentos transmitidos durante minha jornada na graduação e pela ajuda iterativa para engrandecer meu conhecimento neste trabalho.

Agradeço ao Grupo de Pesquisa em Motores, Combustíveis e Emissões (GPMOT) e ao meu orientador de iniciação científica Professor Mario Martins pela liderança ímpar frente ao grupo de pesquisas, pela maestria na transmissão do conhecimento e por ter possibilitado a realização deste trabalho. Agradeço aos colegas Geovane Prante, Lincoln Prado, Valdemir Junior, Igor dos Santos, Roberto Garlet e ao professor Roberto Hausen pela ajuda prestada na realização desse trabalho, os quais são importantes componentes da minha formação no GPMOT. Agradeço a FUNDEP por fomentar a pesquisa e minha bolsa de iniciação científica ao longo do período desse trabalho.

Agradeço aos meus pais senhor Rosalvo Silveira e senhora Eva Regina Silveira pelo incentivo, acompanhamento, alicerce para toda a minha formação e ajuda neste trabalho. Agradeço a minha companheira Yasmin Vieira pelo apoio nesta caminhada e constante apoio ao meu trabalho.

RESUMO

DETECÇÃO DA OCORRÊNCIA DE DETONAÇÃO EM MOTORES DE COMBUSTÃO INTERNA DE IGNIÇÃO POR CENTELHA BASEADA EM REDES NEURAIIS ARTIFICIAIS

AUTOR: Juliano Pereira Silveira

ORIENTADORA: Prof^a. Dr^a. Candice Müller

Neste trabalho foram avaliadas técnicas de detecção de detonação utilizando o sinal de pressão de cilindro e o sinal de vibração mecânica em um motor de combustão interna de ignição por centelha. Testes foram realizados para obter um banco de dados com pontos de operação em condições com e sem detonação. Foram adquiridos dois sinais no motor: o sinal de pressão de cilindro e o sinal do sensor de vibração mecânica acoplado ao bloco do motor. O sinal de pressão de cilindro foi aplicado à técnica SEPO (do inglês: *signal energy pressure oscillations*) para referencial de detecção de detonação. O sinal de vibração mecânica foi aplicado às técnicas clássicas adaptadas MAV (do inglês: *maximum amplitude of vibration*) e SEV (do inglês: *signal energy of vibration*). Foi desenvolvida uma técnica com ANN (do inglês: *artificial neural network*) para a melhora da detecção de detonação utilizando o sensor de vibração mecânica. Obteve-se uma taxa de acertos superior pela técnica da ANN sobre o melhor caso das técnicas clássicas MAV e SEV. Foi possível obter uma quantidade percentual de erros de detecção menor na técnica da ANN em relação às outras técnicas MAV e SEV. Obteve-se uma redução de 204% de erros de detecção pela técnica da ANN em relação à técnica MAV e redução de 57% de erro de detecção pela técnica da ANN em relação à técnica SEV. Logo, a abordagem utilizando a ANN obteve resultados com menos erros de detecção em relação às outras técnicas, assim mostrando-se promissora como instrumento de aumento de eficiência em motores de combustão interna de ignição por centelha de pequeno porte.

ABSTRACT

DETECTION OF KNOCK OCCURRENCE IN SPARK IGNITION INTERNAL COMBUSTION ENGINES BASED ON ARTIFICIAL NEURAL NETWORKS

AUTHOR: Juliano Pereira Silveira

ADVISOR: Prof. Dr. Candice Müller

In this work, knock detection techniques were evaluated using the cylinder pressure signal and the mechanical vibration signal in a spark ignition internal combustion engine. Tests were performed to obtain a dataset with operating points in conditions with and without knock. Two signals were acquired on the engine: the cylinder pressure signal and the signal from the mechanical vibration sensor attached to the engine block. To the cylinder pressure signal, it was applied the signal energy pressure oscillations (SEPO) technique for knock detection standardization. To the mechanical vibration signal, it was applied the adapted classical maximum amplitude of vibration (MAV) and signal energy of vibration (SEV) techniques. An artificial neural network (ANN) technique was developed for the improvement of knock detection by employment of the mechanical vibration sensor. A higher agreement rate was reached by the ANN technique over the best case scenario obtained by the classical techniques, where it was possible to obtain a lower percentage of detection errors by the ANN technique in comparison to MAV and SEV. Specifically, the ANN technique obtained a total of 204% reduction in the detection errors over MAV, whereas it reached a 57% reduction over SEV. Therefore, the ANN approach developed in this study is promising as an effective tool for reaching higher agreement rates of detection of knock, thus, increasing the efficiency of spark ignition internal combustion engines.

LISTA DE ILUSTRAÇÕES

Figura 1 – Etapas de funcionamento de um motor ciclo Otto de quatro tempos com preparação de mistura no sistema de admissão.....	15
Figura 2 – Sinais característicos de pressão de um motor ciclo Otto com pontos de referência importantes para o ciclo.....	16
Figura 3 – Sinais característicos de pressão (preto) e vibração (vermelho) em um motor: (a) Sinais no tempo sem detonação; (b) Sinais no tempo com detonação; (c) Sinais na frequência sem detonação; (d) Sinais na frequência com detonação.	17
Figura 4 – Sinais resultantes das técnicas de quantificação de intensidade de detonação: (a) Sinal de pressão de cilindro e sinal de pressão de cilindro filtrado com LPF; (b) Sinal de pressão de cilindro filtrado com BPF; (c) Integral do valor quadrático do sinal de pressão de cilindro filtrado com BPF.....	19
Figura 5 – Neurônio “básico”.....	21
Figura 6 – Rede Neural Perceptron com uma camada oculta e uma camada de saída.....	22
Figura 7 – Descrição da bancada experimental.....	26
Figura 8 – Posição de instalação dos sensores utilizados no motor de combustão interna.	28
Figura 9 – Interface de usuário do software de controle e aquisição de dados da célula de testes.	29
Figura 10 – Interface da interface de usuário do software do sistema de indicação.	30
Figura 11 – Fluxograma do processo de aquisição dos pontos de operação.	32
Figura 12 – Diagrama em blocos da técnica de detecção de detonação utilizando ANN.	34
Figura 13 – Erro médio quadrático no processo de treinamento da rede neural.	35
Figura 14 – Histograma dos valores de saída da ANN para o conjunto de dados de treinamento e validação.	36
Figura 15 – Taxa de acertos por técnica de detecção de detonação.	38
Figura 16 – Taxa de falsos positivo por técnica de detecção de detonação.	39
Figura 17 – Taxa de falso negativo por técnica de detecção de detonação.	40
Figura 18 – Distribuição dos erros de detecção de detonação por técnica.....	41

LISTA DE TABELAS

Tabela 1 – Especificações do Motor.....	25
Tabela 2 – Características do etanol hidratado.....	27
Tabela 3 – Descrição das condições de operação no motor	31
Tabela 4 – Resumo dos dados obtidos pelo comparativo das técnicas clássicas MAV e SEV com a técnica da ANN proposta.	42

LISTA DE ABREVIATURAS E SIGLAS

ANN	<i>Artificial Neural Network</i>
ANP	Agência Nacional do Petróleo, Gás-Natural e Biocombustíveis
ATDC	<i>After Top-Dead-Center</i>
BDC	<i>Bottom-Dead-Center</i>
BPF	<i>Band-Pass Filter</i>
BTDC	<i>Before Top-Dead-Center</i>
CA50	Ângulo de 50% de Massa Queimada
CAD	<i>Crank Angle Degree</i>
ECU	<i>Electronic Central Unit</i>
EVC	<i>Exhaust Valve Closing</i>
EVO	<i>Exhaust Valve Opening</i>
IVC	<i>Intake Valve Closing</i>
IVO	<i>Intake Valve Opening</i>
KODANN	<i>Knock Occurrence Detection using Artificial Neural Network</i>
LPF	<i>Low-Pass Filter</i>
MAPO	<i>Maximum Amplitude Pressure Oscillations</i>
MAV	<i>Maximum Amplitude of Vibration</i>
MBT	<i>Maximum Brake Torque</i>
MFB	<i>Mass Fraction Burned</i>
MSE	<i>Mean Squared Error</i>
SEPO	<i>Signal Energy Pressure Oscillations</i>
SEV	<i>Signal Energy of Vibration</i>
SI	<i>Spark Ignition</i>
SNR	<i>Signal-to-Noise Ratio</i>
TCC	Trabalho de Conclusão de Curso
TDC	<i>Top-Dead-Center</i>
TVE	<i>Threshold Value Exceeded</i>

SUMÁRIO

1	INTRODUÇÃO	11
1.1	OBJETIVO GERAL.....	13
1.2	OBJETIVOS ESPECÍFICOS	13
2	MOTOR DE COMBUSTÃO INTERNA	14
3	TÉCNICAS DE DETECÇÃO DE DETONAÇÃO	18
3.1	REDES NEURAS ARTIFICIAIS	20
3.1.1	Treinamento da Rede Perceptron	22
4	COLETA DOS DADOS EXPERIMENTAIS	25
4.1	MOTOR DE PESQUISAS RICARDO 1200 OTTO.....	25
4.2	SISTEMA DE AQUISIÇÃO DE DADOS	28
4.3	DESCRIÇÃO DAS CONDIÇÕES OPERACIONAIS	31
5	DETECÇÃO DE DETONAÇÃO COM ANN	33
6	RESULTADOS	37
7	CONCLUSÃO	43
8	TRABALHOS FUTUROS	45

1 INTRODUÇÃO

O desenvolvimento da sociedade está fortemente associado ao uso de veículos. Em 2020, por exemplo, a frota veicular brasileira apresentou valores superiores a 57 milhões, acompanhada de um padrão de crescimento linear em anos anteriores, o que indica uma tendência de crescimento ainda maior (DENATRAN, 2020). Apesar de representarem uma fatia do progresso humano, o uso de veículos automotores está associado à emissão de gases do efeito estufa, danosos ao meio ambiente. Mundialmente o setor de transportes é responsável por 25% do consumo total de energia com 75% das emissões de gases de efeito estufa por parte da malha viária (IEA, 2021). Dentro desse grupo, 45% das emissões de dióxido de carbono no setor de transportes são produzidas por veículos de pequeno porte de passageiros (RITCHIE, 2021). Visando evitar maiores impactos ambientais, o uso dos recursos energéticos deve ser bem pensado e otimizado, e a evolução do aumento de eficiência energética para o setor de transporte leve passa a ser imperativa. Os estudos para alcançar uma maior eficiência têm sido cada vez mais impulsionados por uma legislação de emissões mais rígida e necessidades de redução do consumo de combustível, conforme observado na resolução vigente N° 492 que estabelece a fase L7 do Programa de Controle de Emissões Veiculares (PROCONVE) (CONSELHO NACIONAL DO MEIO AMBIENTE, 2018).

Na maioria dos casos, veículos automotores de pequeno porte de passageiros são equipados com motores de combustão interna de quatro tempos com ignição por centelha (SI, do inglês: *spark ignition*). No entanto, em motores SI, o aumento da eficiência de conversão de combustível (η_f) pode ser limitado pela ocorrência do fenômeno de detonação, também chamado de combustão anormal, que tem potencial de danificar o motor (HEYWOOD, 2018). É possível alcançar pontos de operação próximos ao limite de detonação por meio de um preciso controle eletrônico do ponto de ignição e uma precisa detecção dos ciclos com detonação (HOSEY e POWELL, 1979). Esse problema é mais evidente em motores de tamanho reduzido que operam com uma densidade de potência elevada (do inglês: *downsizing*) (CORRIGAN e FONTANESI, 2022).

Diversos estudos foram realizados para compreender o fenômeno de detonação e como é possível extrair informações a respeito de suas características, conforme demonstrado por (CORRIGAN e FONTANESI, 2022). Nos anos 80, foi observada uma evolução tecnológica que permitiu a análise computacional de sinais de transdutores de pressão.

Técnicas foram desenvolvidas com base nesse sinal para quantificar a intensidade, início e ocorrência da detonação. Em posse de dados contendo ciclos de operação com detonação, observou-se que uma faixa do espectro em torno de 6 kHz continha informações a respeito do fenômeno. Um filtro passa-banda (BPF, do inglês: *band-pass filter*) foi utilizado para capturar o sinal provindo dessa região do espectro do sinal de pressão. Foi observado que, tanto o valor da máxima amplitude das oscilações de pressão de cilindro, a qual foi denominada MAPO (do inglês: *maximum amplitude pressure oscillations*), quanto a integral do sinal quadrático de oscilações da pressão de cilindro, denominado como SEPO (do inglês: *signal energy pressure oscillations*), possuem forte correlação com o evento de detonação e apresentam valores de intensidade que quantificam o fenômeno (LEPPARD, 1982). Uma técnica de valor de limiar excedido pode ser utilizada para determinar e qualificar se há a ocorrência de detonação para tal intensidade, a qual é denominada método TVE (do inglês: *threshold value exceeded*) (WORRET, BERNHARDT, *et al.*, 2002).

Visando as aplicações embarcadas em veículos leves, técnicas para detecção de detonação utilizando sensores de baixo custo, como o sensor de vibração mecânica acoplado no bloco do motor, podem ser úteis para o incremento de eficiência de conversão de combustível. Ao passo que a utilização de transdutores de pressão de cilindro é de custo elevado e baixa durabilidade, os sensores de vibração são mais baratos e mais robustos. Uma desvantagem do sensor de vibração é sua baixa relação sinal-ruído (SNR, do inglês: *signal-to-noise ratio*), tendo em vista a alta complexidade mecânica, o processo dinâmico do ciclo e a medição indireta do fenômeno de detonação. Essas características tornam complexa a análise do sinal proveniente da vibração mecânica para a avaliação do evento de detonação (PLA, BARES, *et al.*, 2022).

O problema de detecção através do sinal do sensor de vibração é evidenciado na detecção de ciclos em detonação de baixa intensidade pela baixa SNR. Neste caso, a SNR refere-se ao sinal de detonação em relação aos ruídos mecânicos do motor. Os erros de detecção podem ter duas causas: a primeira é um falso negativo, o qual é resultado do cálculo da intensidade não alcançar o limiar (do inglês: *threshold*) de detonação em um evento de detonação; o segundo é um falso positivo, o qual é o resultado do cálculo de intensidade ultrapassar o limiar de detonação em um ciclo sem evento de detonação. Esses erros de detecção de detonação de baixa intensidade são acentuados pelo baixo valor de SNR do sinal de vibração mecânica (BI, MA e WANG, 2019).

Tendo em vista o cenário da utilização do sensor de vibração mecânica para detecção embarcada de detonação, faz-se necessário o desenvolvimento de técnicas que consigam extrair informações do fenômeno e diminuam os erros de detecção causados por interferências no sinal. Uma forma de contornar esse problema é adotando técnicas de processamento de sinais que consigam melhorar a SNR e evidenciar as características do fenômeno de detonação (BI, MA e WANG, 2019). Uma possível solução pode ser implementada utilizando uma rede neural artificial (ANN, do inglês: *artificial neural network*), dada à capacidade delas em apresentar um processamento paralelo de sinais, habilidades de aprender e de generalizar (HAYKIN, 1998). As duas últimas características das ANNs são úteis para mapear um sinal de entrada para uma referência.

1.1 OBJETIVO GERAL

Propor uma solução de detecção de detonação utilizando o sinal do sensor de vibração mecânica empregando uma rede neural artificial.

1.2 OBJETIVOS ESPECÍFICOS

Para atingir o objetivo geral do TCC, são definidos os seguintes objetivos específicos:

- a) Estudar as técnicas clássicas de detecção de detonação utilizando o sensor de pressão de cilindro como o MAPO e SEPO e implementar a técnica SEPO para referencial de detecção de detonação;
- b) Coletar dados experimentais, com o motor submetido a diferentes condições operacionais, para a geração de um banco de dados;
- c) Adaptar as técnicas clássicas para o sensor de vibração mecânica (baixo custo e baixa SNR);
- d) Avaliar o desempenho das técnicas clássicas adaptadas ao sensor de vibração mecânica;
- e) Implementar uma solução de detecção de detonação baseada em redes neurais artificiais;
- f) Analisar comparativamente o desempenho da ANN com as demais técnicas envolvendo o sinal do sensor de vibração mecânica.


2 MOTOR DE COMBUSTÃO INTERNA

Um motor de combustão interna é uma máquina térmica capaz de converter a energia química contida em um combustível em energia mecânica. O processo de combustão no motor ocorre em uma câmara através da liberação de energia, que resulta em um aumento de pressão e temperatura. Esse aumento de pressão empurra um embolo produzindo um movimento linear. Um sistema de biela-manivela atua convertendo o movimento linear em rotacional (HEYWOOD, 2018).

A maioria dos motores de combustão interna opera em quatro tempos, o que é compreendido como duas voltas no virabrequim para um *power stroke* (do português curso de potência). Esses motores possuem quatro estágios de funcionamento, admissão, compressão, expansão e exaustão, conforme ilustra a Figura 1. Todos esses estágios compreendem um ciclo de operação. Todos os eventos do ciclo são referenciados pelo ângulo do virabrequim em graus (CAD, do inglês *crank angle degree*). Para um motor SI, que tem seu ciclo ideal teórico de funcionamento representado pelo ciclo Otto, com preparação de mistura no sistema de admissão, o seu funcionamento é descrito a seguir:

- **Admissão:** Este processo ocorre desde o ponto morto superior (TDC, do inglês *top-dead-center*) até o ponto morto inferior (BDC, do inglês *bottom-dead-center*). Nesta etapa, uma mistura de ar e combustível entra no cilindro pela válvula de admissão.
- **Compressão:** Este processo ocorre do BDC até o TDC. Nesta etapa, com as válvulas fechadas, o volume dentro da câmara de combustão diminui. Após a compressão, uma centelha dá início à combustão, a qual fará com que a pressão e temperatura no cilindro aumentem consideravelmente.
- **Expansão:** Este processo ocorre do TDC até o BDC. Nesta etapa, com as válvulas ainda fechadas, o aumento de pressão devido à expansão dos gases da combustão faz com que o pistão seja empurrado para baixo, assim transferindo o trabalho da combustão em movimento.
- **Exaustão:** Este processo ocorre do BDC até o TDC. Nesta etapa, a válvula de exaustão se abre, assim permitindo a saída dos gases residuais da combustão. Após esse processo o motor está preparado para o recebimento de uma mistura fresca, o que permitirá a continuação do seu funcionamento.

Figura 1 – Etapas de funcionamento de um motor ciclo Otto de quatro tempos com preparação de mistura no sistema de admissão.



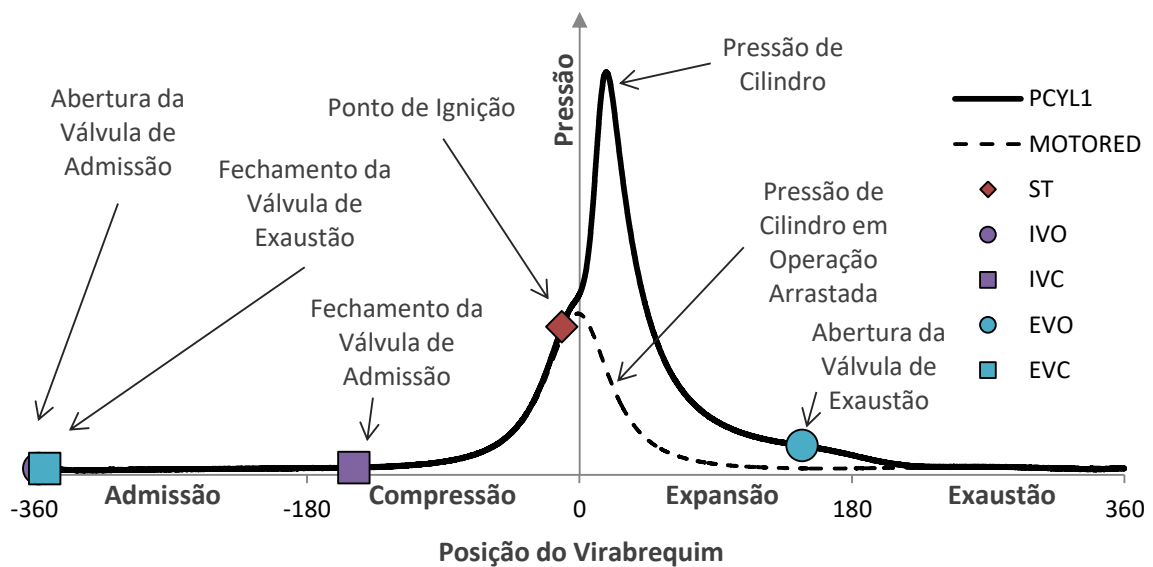
Fonte: adaptado de (HEYWOOD, 2018).

A pressão dentro da câmara de combustão varia conforme são admitidos e exauridos os gases, com a compressão da mistura e conforme ocorre a liberação de energia no processo de combustão. A Figura 2 ilustra o sinal de um sensor de pressão em uma câmara de combustão de um motor de quatro tempos nas quatro fases do ciclo. O sinal varia significativamente do estágio de compressão até o estágio de expansão. Após a etapa de expansão o sinal decresce até um ponto mínimo, que ocorre no estágio de admissão (HEYWOOD, 2018).

A sintonia da combustão permite melhorar a transferência de trabalho para o pistão. Essa sintonia é realizada de modo a alterar o instante central da combustão pelo avanço de ignição. O instante central da combustão é definido na ocorrência de 50% de fração de massa queimada dentro do cilindro (MFB, do inglês: *mass fraction burned*). Coincidir o ângulo de 50% de MFB com o ângulo de máximo torque (MBT, do inglês: *maximum brake torque*) faz com que seja possível alcançar a máxima eficiência de conversão de combustível. Realizando esse processo é possível otimizar as características operacionais do motor como aumento de

torque e redução de consumo de combustível. Um dos limites para o aumento de eficiência pelo avanço de ignição é a combustão anormal. O processo de combustão anormal pode ser influenciado por diversos fatores, dentre eles: a composição do combustível, o formato da câmara de combustão, os fatores operacionais, entre outros. (HEYWOOD, 2018).

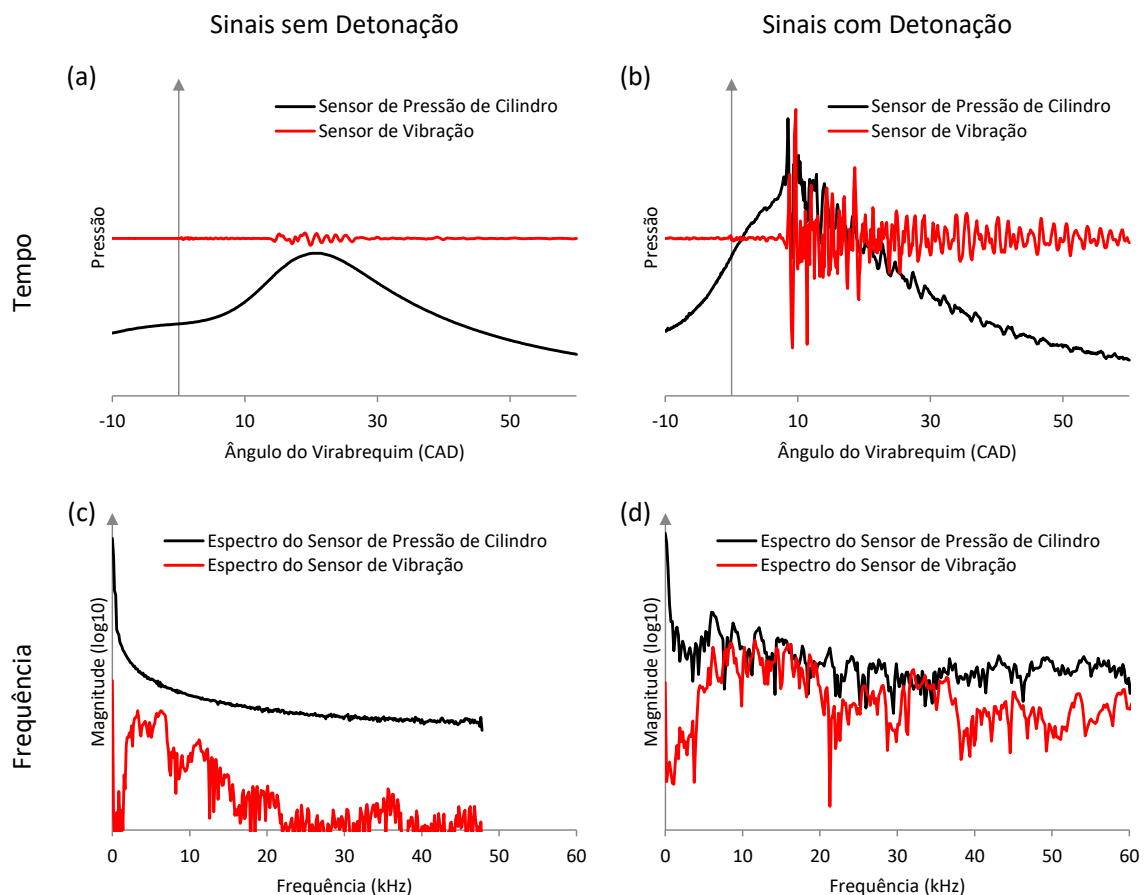
Figura 2 – Sinais característicos de pressão de um motor ciclo Otto com pontos de referência importantes para o ciclo.



O processo de uma combustão normal com chama pré-misturada é descrito com uma propagação de chama dentro da câmara de combustão que consome a mistura ar-combustível em direção ao gás não queimado liberando energia de forma progressiva. Dependendo da condição termodinâmica do gás não queimado dentro da câmara de combustão, pode ocorrer um processo de autoignição local dentro desta zona, a qual caracteriza uma combustão anormal. O fenômeno mais importante em uma combustão anormal é a detonação (do inglês: *knock*). O processo de detonação gera ondas ressonantes de alta frequência que ocorrem pelo choque de uma o mais frentes de chama provindas da autoignição da mistura não queimada com a frente de chama já existente, assim apresentando uma rápida combustão dentro do cilindro, a qual pode ser de 5 a 25 vezes mais rápida que uma combustão normal característica. Essas ondas ressonantes transferem parte de sua energia cinética para o bloco do motor causando vibrações de alta frequência. Essas vibrações de alta frequência geram um som característico semelhante a um ruído de batida de peças metálicas (do inglês: *ringing*

noise) (HEYWOOD, 2018). O resultado desse fenômeno é a erosão e o desgaste nos componentes internos do motor, que pode levar a falha quando exposto por períodos prolongados (FITTON e NATES, 1996) (NATES e YATES, 1994). Na Figura 3 é possível ver o comparativo entre um sinal de uma combustão normal e uma combustão anormal. A combustão normal apresenta uma variação suave de pressão, com espectro contido nas baixas frequências e o sensor de vibração apresenta uma baixa amplitude com um espectro apenas demonstrando os ruídos causados pelos mecanismos do motor. Na ocorrência de detonação, o sinal de pressão apresenta rápidas variações no traço e amplitudes mais elevadas, assim como um espectro demonstrando as frequências componentes dos modos de vibração do gás. O sensor de vibração assume um comportamento ruidoso e oscilatório amortecido, com espectro evidenciando picos nas frequências dos modos de vibração conforme as características construtivas do motor (PLA, BARES, *et al.*, 2022).

Figura 3 – Sinais característicos de pressão (preto) e vibração (vermelho) em um motor: (a) Sinais no tempo sem detonação; (b) Sinais no tempo com detonação; (c) Sinais na frequência sem detonação; (d) Sinais na frequência com detonação.



3 TÉCNICAS DE DETECÇÃO DE DETONAÇÃO

Diversas técnicas foram desenvolvidas para avaliar como a combustão anormal se comporta e como é possível extrair informações a partir do sinal de pressão de cilindro do motor. Duas das técnicas mais consolidadas de análise de detonação utilizam o sinal de pressão de cilindro com uma filtragem. A pressão de cilindro filtrada P_{filt} é obtida através da passagem do sinal de pressão por um filtro passa banda (BPF), com banda de passagem de 6 a 25 kHz. Essa região compreende a melhor relação sinal-ruído para a observação do fenômeno de detonação (SHEN, ZHANG e SHEN, 2019). O objetivo dessa etapa de filtragem é remover o sinal que compõe a banda de combustão normal, geralmente definida de 0 a 3 kHz, deixando passar a banda onde são observados os modos ressonantes resultantes da combustão anormal, geralmente de 6 a 25 kHz. O sinal de pressão filtrado é usado como entrada das técnicas MAPO e SEPO.

A técnica MAPO é uma técnica implementada no domínio do tempo, baseada no máximo valor do sinal de pressão de cilindro filtrado P_{filt} , como mostra a Equação (1). O valor do MAPO é proporcional à intensidade da detonação, porém esse valor pode ser afetado por ruídos no sinal (SHAHLARI e GHANDHI, 2012).

$$MAPO = \max\{P_{filt}\} \quad (1)$$

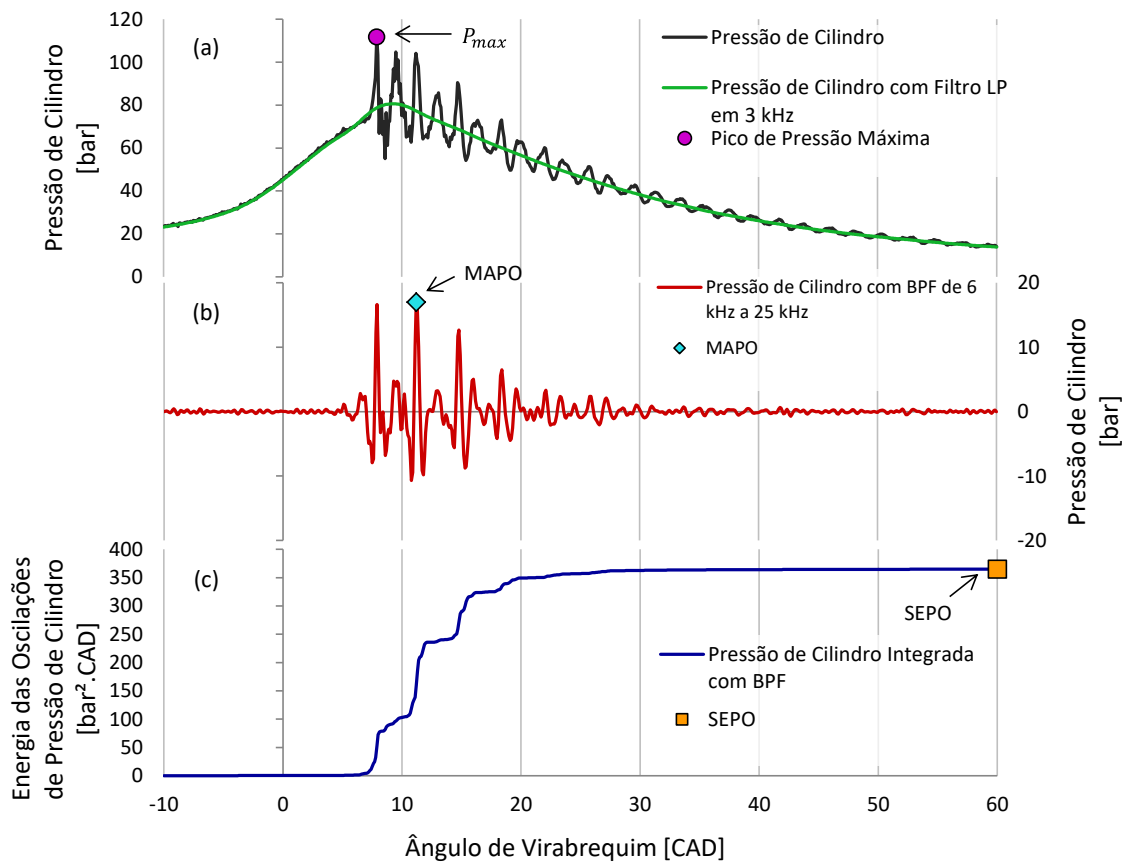
Para mitigar o efeito da influência do ruído no ponto de máximo na técnica MAPO, foi desenvolvida outra solução, denominada SEPO (SHAHLARI e GHANDHI, 2012). O método SEPO integra a pressão filtrada P_{filt} quadrática dentro de uma janela de integração, a qual é escolhida de acordo com o período que se deseja observar a energia contida nas oscilações. A janela de observação é composta pelo ponto de início da ocorrência da detonação θ_0 e a faixa de observação $\Delta\theta$, as quais são baseadas no período que ocorre a detonação. Estendendo a visualização dessa janela para uma faixa que cubra toda e qualquer região sensível a detonação, é escolhido o período de -10 a 60 CAD. O método SEPO é descrito na Eq. (2).

$$SEPO = \int_{\theta_0}^{\theta_0 + \Delta\theta} P_{filt}^2 d\theta \quad (2)$$

Para ambas as abordagens, MAPO e SEPO, a detonação é detectada caso o valor MAPO ou SEPO supere um valor de limiar, o qual é calibrado de acordo com as características do motor na fronteira da ocorrência de detonação.

Um resumo das técnicas apresentadas é visto na Figura 4. Verifica-se na Figura 4 que o pico de pressão máxima P_{max} não está localizado no mesmo ângulo do ponto de MAPO. É observada a diferença da curva de pressão com filtro passa-baixa (LPF, do inglês: *low-pass filter*), a qual representa o sinal referente à região de combustão normal isoladamente (traço verde), e o sinal sem filtro algum (traço preto), o qual é possível ver a concatenação da curva de pressão da combustão normal com as oscilações causadas pela combustão anormal. O valor de SEPO tem crescimento proporcional à amplitude absoluta das oscilações do sinal de pressão filtrada e seu valor é definido no final da integração. O sinal de SEPO instantâneo não varia significativamente antes e depois das oscilações de detonação entre os ângulos de -10 a 5 CAD e 25 a 60 CAD, no caso deste exemplo.

Figura 4 – Sinais resultantes das técnicas de quantificação de intensidade de detonação: (a) Sinal de pressão de cilindro e sinal de pressão de cilindro filtrado com LPF; (b) Sinal de pressão de cilindro filtrado com BPF; (c) Integral do valor quadrático do sinal de pressão de cilindro filtrado com BPF.




No caso deste TCC, as técnicas MAPO e SEPO, baseadas no sensor de pressão de cilindro, foram adaptadas para o sinal de vibração mecânica. Deste modo, a técnica denominada MAV (do inglês: *maximum amplitude of vibration*) faz analogia a técnica MAPO, enquanto que a técnica denominada SEV (do inglês: *signal energy of vibration*) faz analogia a técnica SEPO. Nessas técnicas análogas MAV e SEV, o sinal de pressão de cilindro $P(\theta)$ é substituído pelo sinal do sensor de vibração mecânica $a(\theta)$. Do mesmo modo que nas técnicas MAPO e SEPO, ao sinal do sensor de vibração $a(\theta)$ é aplicado a um filtro BPF, com banda de passagem de 6 a 25 kHz, resultando no sinal $a_{filt}(\theta)$. Após essa etapa, as técnicas MAV e SEV são aplicadas, de forma análoga a das técnicas MAPO e SEPO, respectivamente. Essa analogia entre técnicas é válida pela correlação positiva entre os sinais (NABER, BLOUGH, *et al.*, 2006).

3.1 REDES NEURAIS ARTIFICIAIS

Uma ANN é uma estrutura de processamento de informações com um sistema não linear, complexo e paralelo (HAYKIN, 1998). Ela é composta por elementos de processamento denominados neurônios ou células que se comunicam através de sinapses ou ligações com pesos ponderados. Cada neurônio é constituído de uma função somatório, a qual realiza uma combinação linear das entradas com os pesos sinápticos, e uma função de ativação, que dá alguma característica para esse elemento, inserindo não linearidade ao neurônio. A Figura 5 demonstra um “neurônio básico”, onde pode-se ver os dendritos (do inglês *dendrites*), o núcleo ou corpo da célula (do inglês *cell body*), o axônio (do inglês *axon*) e os terminais sinápticos (do inglês *synaptic terminal*). Os neurônios funcionam com a transmissão de impulsos elétricos. Os dendritos representam as entradas ponderadas pelos pesos sinápticos ao núcleo do neurônio. O núcleo representa o processo de combinação de todos os estímulos captados na entrada pelos dendritos. O axônio é responsável por controlar o impulso elétrico resultante do núcleo para as saídas das ramificações terminais sinápticas. As ligações entre uma célula e outra é definida como uma sinapse (HAYKIN, 1998).

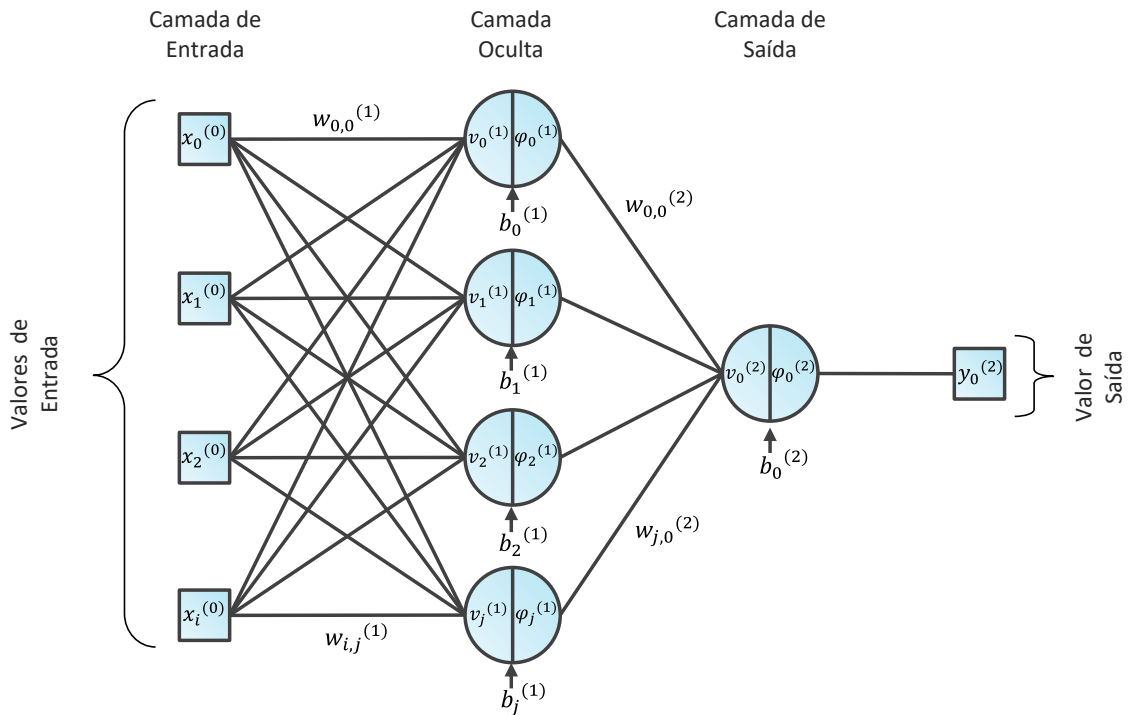
Figura 5 – Neurônio “básico”.



Fonte: (ARBIB, 2003).

A rede possui entradas e saídas. As entradas representam os dados que alimentam a rede e são computados pelos neurônios. As saídas apresentam o resultado de todas as interações na rede (KRÖSE e SMAGT, 1996). Para obter os valores dos parâmetros livres da rede, como por exemplo, os valores dos pesos sinápticos, é necessário realizar um processo de treinamento da rede. Esse processo consiste em gerar um conjunto de dados de entrada/saída que satisfaçam alguma condição e assim, modificar os parâmetros livres da rede, visando obter o menor erro possível. Ressalta-se a capacidade de generalização das redes neurais, a qual permite que ela gere uma saída adequada para entradas que não foram utilizadas no treinamento (HAYKIN, 1998). Um tipo comumente encontrado de redes neurais é o com propagação para frente (do inglês *feed-forward*), o qual apresenta uma estrutura em que as camadas seguintes recebem os valores das camadas anteriores, procedendo da entrada até a saída (RAUBER, 2005). As redes neurais podem possuir nenhuma, uma ou mais camadas ocultas, as quais recebem esse termo por estarem escondidas entre as camadas de entrada e saída da rede. A camada oculta permite um grau estatístico maior, assim podendo extrair mais informações para as camadas de saída (HAYKIN, 1998). Um exemplo de rede multicamada com propagação para frente é a rede perceptron, a qual pode ser vista na Figura 6.

Figura 6 – Rede Neural Perceptron com uma camada oculta e uma camada de saída.



Para realizar o treinamento de uma rede perceptron de múltiplas camadas, a qual é um tipo simples de rede de propagação para frente, é comumente utilizado um algoritmo de propagação para trás (do inglês *back-propagation*). Esse algoritmo utiliza uma estrutura supervisionada para alcançar o menor erro de saída por meio do cálculo da influência dos pesos nesse resultado (KRÖSE e SMAGT, 1996).

3.1.1 Treinamento da Rede Perceptron

Conforme a Figura 6, para realizar o treinamento da rede perceptron é necessário saber o valor de saída $y_0^{(2)}$. O cálculo para obtenção desse valor é mostrado na Eq. (3). Os componentes dessa equação são: a função de ativação do neurônio da camada de saída $\varphi_0^{(2)}$; as funções de ativação da camada oculta $\varphi_j^{(1)}$; os pesos sinápticos da camada de saída $w_{j,0}^{(2)}$; os pesos sinápticos da camada oculta $w_{i,j}^{(1)}$; o valor de ajuste da camada de saída $b_0^{(2)}$; os valores de ajuste da camada oculta $b_j^{(1)}$; as entradas da rede $x_i^{(0)}$. O resultado do somatório do produto dos valores de entrada do neurônio com os pesos sinápticos, com adição do valor

de ajuste, é entendido como $v_j^{(1)}$ para a camada oculta e $v_0^{(2)}$ para a camada de saída. O parâmetro i e j representam o índice do valor da camada de entrada e do neurônio da camada oculta, respectivamente. Os parâmetros n e m representam o número de entradas e o número de neurônios na camada oculta, respectivamente. A camada de saída possui apenas um neurônio e, conseqüentemente, uma saída, nesse caso, é dada por:

$$y_0^{(2)} = \varphi_0^{(2)} \left(\sum_{j=0}^{m-1} w_{j,0}^{(2)} \cdot \varphi_0^{(1)} \left(\sum_{i=0}^{n-1} x_i^{(0)} \cdot w_{i,j}^{(1)} + b_j^{(1)} \right) + b_0^{(2)} \right) \quad (3)$$

O processo de treinamento da rede perceptron pode ser dado pela Regra Delta. Essa regra define como é caracterizado o ajuste dos parâmetros livres da rede a cada iteração do *back-propagation*. Esse fator é composto por um coeficiente de taxa de aprendizagem η , um gradiente local do erro $\delta_j(n)$, associado a cada parâmetro, e a saída da camada $y_i(n)$ correspondente a iteração (HAYKIN, 1998). Essa equação é dada por:

$$\Delta w_{ji}(n) = \eta \cdot \delta_j(n) \cdot y_i(n) \quad (4)$$

O cálculo do gradiente local $\delta_j(n)$ varia dependendo da camada e pode assumir dois casos: o caso em que o cálculo é realizado na camada de saída (Eq. (5)) e o caso em que o cálculo é realizado nas camadas ocultas (Eq. (6)). Na camada de saída, um erro $e_0^{(2)}(n)$ é computado pela diferença entre um valor alvo (do inglês *target*) e o valor de saída da rede neural. O erro é multiplicado pela derivada da função de ativação do neurônio $\varphi_0'^{(2)}(v_0^{(2)}(n))$. Essa derivada representa a proporcionalidade de correção que é necessária aplicar aos pesos (HAYKIN, 1998).

$$\delta_0^{(2)}(n) = e_0^{(2)}(n) \varphi_0'^{(2)}(v_0^{(2)}(n)) \quad (5)$$

Nas camadas ocultas o gradiente é expandido para uma combinação linear com os pesos sinápticos das ligações para a camada posterior, que no caso de uma rede de duas camadas é a camada de saída, por exemplo.

$$\delta_j(n) = \varphi_0'^{(1)}(v_0^{(1)}(n)) \sum_k \delta_0^{(2)}(n) \cdot w_{j,0}^{(2)} \quad (6)$$

A função $\varphi(v_j(n))$ representa a função de ativação do neurônio j . Essa função tem o papel de estabelecer uma característica não linear para a rede. Comumente é utilizada a

função sigmoide, a qual pode ser vista na Eq. (7), como função de ativação. Valores muito altos resultantes da combinação linear do neurônio são computados dentro de uma faixa estreita de 0 a 1 pela função sigmoide para valores de $x \rightarrow -\infty$ e $x \rightarrow +\infty$, respectivamente.

$$\varphi(v_j(n)) = \frac{1}{1 + \exp(-v_j(n))} \quad (7)$$

A derivada dessa função de ativação é dada em (8).

$$\varphi'(v_j(n)) = \frac{\exp(-v_j(n))}{[1 + \exp(-v_j(n))]^2} \quad (8)$$

O resumo do algoritmo de *back-propagation* é:

1. Propaga-se para frente às entradas da rede até a saída;
2. Calcula-se o erro em relação a uma referência ou alvo;
3. Propaga-se o erro para trás em direção à saída calculando a influência de cada peso no erro através do gradiente local e aplica-se na regra Delta;
4. Calculam-se os novos pesos com a adição de Δw_{ji} .

Durante o processo de treinamento, considera-se uma época a apresentação do conjunto completo de dados de treinamento à entrada da rede. Ao final de cada época, o conjunto de treino é embaralhado para evitar que a ANN aprenda a sequência de dados aplicada à sua entrada.

A condição de parada desse algoritmo pode ocorrer quando

- A norma Euclidiana do vetor gradiente é suficientemente pequena;
- O máximo erro médio quadrático é atingido por um número mínimo de épocas;
- A variação do erro médio quadrático é suficientemente pequena (HAYKIN, 1998);
- O número máximo de épocas é atingido.

4 COLETA DOS DADOS EXPERIMENTAIS

Este Capítulo apresenta a bancada experimental utilizada para a coleta do conjunto de dados experimentais. Inicialmente serão apresentados o motor de combustão interna e os sistemas componentes do conjunto experimental, bem como os sistemas de aquisição de dados. Na sequência são apresentadas as condições operacionais do motor nas quais os dados foram adquiridos.

4.1 MOTOR DE PESQUISAS RICARDO 1200 OTTO

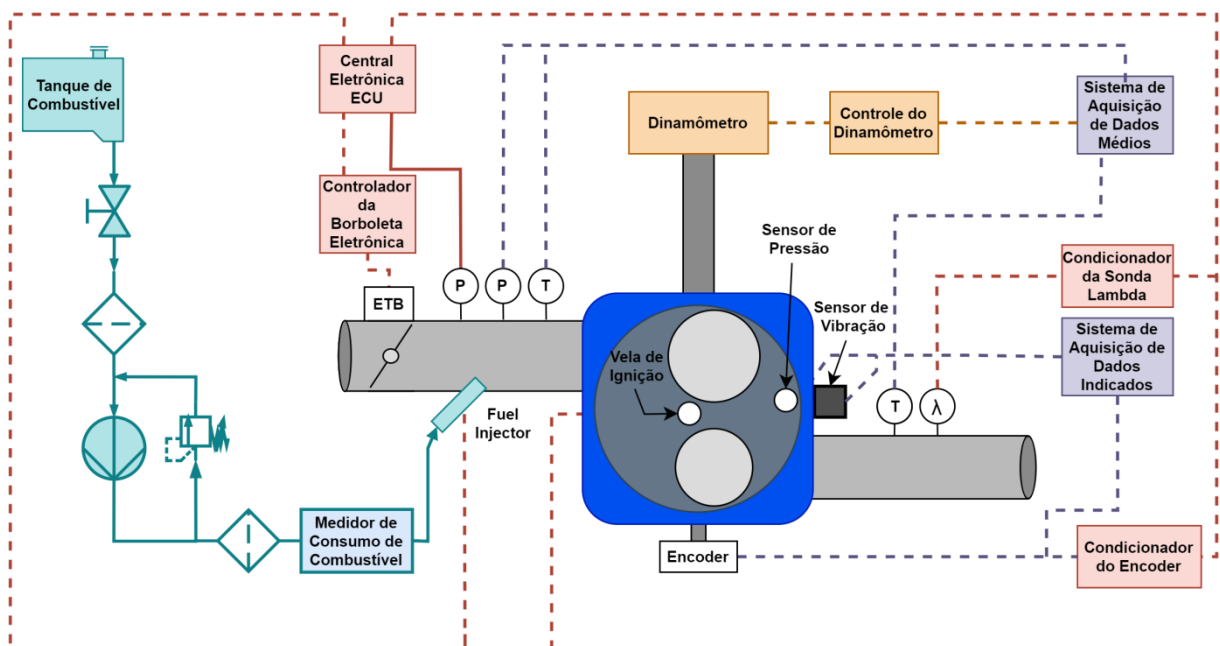
A coleta dos dados experimentais foi realizada no Grupo de Pesquisa em Motores, Combustíveis e Emissões (GPMOT), na Universidade Federal de Santa Maria (UFSM), conduzida em um motor de pesquisa monocilíndrico de ignição por centelha. O motor foi instalado em uma célula de testes com sistemas de aquisição, dinamômetro controlado eletronicamente e condicionamento de fluídos. As características do motor podem ser vistas na Tabela 1.

Tabela 1 – Especificações do Motor

Parâmetro	Descrição
Volume Deslocado	1194 cm ³
Número de Cilindros	1
Curso do Pistão	128 mm
Diâmetro do Cilindro	109 mm
Comprimento da Biela	220 mm
Razão de Compressão	11.7:1
Número de Válvulas por Cilindro	2
Instante de Abertura da Válvula de Exaustão (EVO)	33° BBDC @ 0.5 mm de deslocamento
Instante de Fechamento da Válvula de Exaustão (EVC)	3° ATDC @ 0.5 mm de deslocamento
Instante de Abertura da Válvula de Admissão (IVO)	7° ATDC @ 0.5 mm de deslocamento
Instante de Fechamento da Válvula de Admissão (IVC)	31° ABDC @ 0.5 mm de deslocamento
Sistema de Injeção de Combustível	Injeção na Porta
Tipo da Câmara de Combustão	<i>Bowl-in-piston</i>

A Figura 7 apresenta as ligações dos módulos, sensores e atuadores da bancada experimental. O motor foi instrumentado com sensores de temperatura termopar tipo K, sensor de pressão de baixa frequência MPX5700AP e sensor de oxigênio dos gases de exaustão (sonda lambda) Bosch de banda larga LSU 4.2. O condicionador de sonda lambda utilizado foi um FuelTech WB-O2 nano. A medição da vazão mássica de combustível foi realizada em um medidor Endress+Hauser Promass A Coriolis. O encoder para referência da posição do virabrequim utilizado foi um Dynapar de 3600 pulsos por revolução, com saída em dois canais defasados de 90 graus para referenciamento da direção de giro e com um canal de referência de volta completa. O condicionador de encoder foi um conversor de 3600 pulsos para 60-2 pulsos, o qual é um dos padrões de pulsos para roda fônica. A central eletrônica do motor (ECU) utilizada foi uma FuelTech FT450, o dinamômetro foi um Frenelsa Retarder F12-40 EL com operação por correntes parasitas, arrefecido a ar e com capacidade de freio de até 400 Nm e o controlador de dinamômetro foi um conversor estático operando em *half-bridge*, com capacidade de até 7 A e com malha de controle de rotação constante. O controle da entrada de ar na admissão do motor foi feito por uma válvula borboleta com movimento controlado eletronicamente por um módulo FuelTech ETC.

Figura 7 – Descrição da bancada experimental



O combustível utilizado durante a coleta de dados foi o etanol hidratado comercial, com distribuição em postos de combustíveis regidos pela ANP (Agência Nacional de Petróleo, Gás-Natural e Biocombustíveis). Esse combustível tem suas características descritas na Tabela 2.

Tabela 2 – Características do etanol hidratado

Propriedade	Etanol Hidratado E95
Densidade a 15 °C (kg/L)	0.805-0.811
Razão Ar-Combustível Estequiométrica	8.8
RON/MON/AKI	109/90/99.5
Poder Calorífica Inferior (MJ/kg)	29.58
Quantidade percentual de água (v/v)	5%


Fonte: (FAGUNDEZ, GOLKE, *et al.*, 2019).

Os dados de pressão foram obtidos do sensor piezoelétrico de pressão de cilindro para análise de combustão AVL GH14D. Esse sensor responde a variação de pressão imposta no transdutor, convertendo esse sinal de pressão em cargas elétricas. As cargas elétricas são amplificadas por um amplificador de carga AVL FLEXIFEM Piezo 2P2E, convertendo-as para um valor analógico de tensão e enviado para o sistema de aquisição. A sensibilidade média considerada pela especificação do fabricante é de $18,83 \pm (0,11\%)$ pC/bar (0-150 bar).

Os dados de vibração do motor foram obtidos do sensor de vibração Bosch piezoelétrico 0 261 231 006. Foi utilizado um amplificador linear para adequar o nível de sinal do sensor para o sistema de aquisição a fim de reduzir o erro de quantização. O valor de ganho definido é de 2.066 V/V e a sensibilidade média considerada é de $28,24 \pm 2,95$ mV/g.

Na Figura 8 é mostrado o posicionamento de cada um dos sensores utilizados na coleta de dados. O encoder é fixado na ponta do eixo de virabrequim. O sensor de pressão foi posicionado rente à face do cabeçote, voltado para a câmara de combustão e fixado com um torque conforme especificado pelo fabricante. O sensor de detonação foi posicionado na lateral da camisa, com proximidade do TDC e com torque de montagem de 20 Nm.

Figura 8 – Posição de instalação dos sensores utilizados no motor de combustão interna.



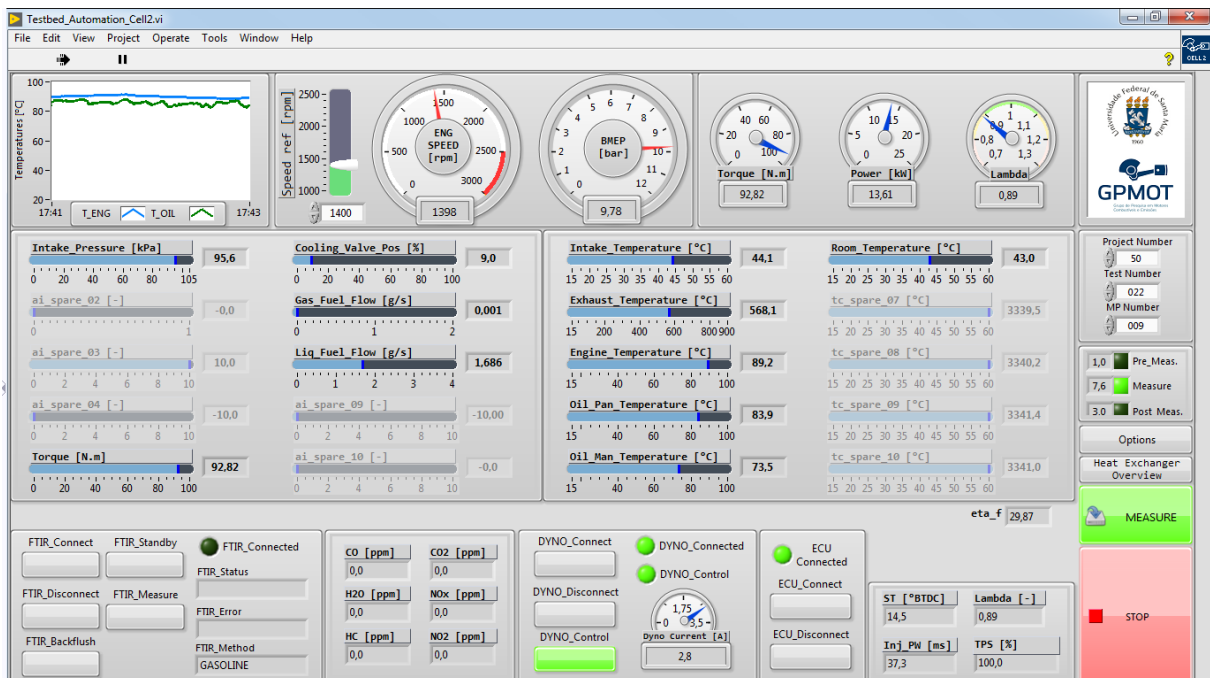
4.2 SISTEMA DE AQUISIÇÃO DE DADOS

A bancada foi equipada com dois sistemas de aquisição de dados, que são classificados em duas categorias: de aquisição de dados médios e de aquisição de dados indicados. O sistema de aquisição de dados médios é composto por um chassi de aquisição de dados National Instruments (NI) SCXI-1001, com capacidade para 12 módulos. Foi utilizado um gerenciador de comunicações USB NI SCXI-1600, uma placa de aquisição de sinais analógicos SCXI-1100, uma placa de aquisição de sinais de termopares SCXI-1102 e uma placa de saída de tensão analógica SCXI-1124. A resolução desse conjunto é de 16 bits e capacidade de amostragem de 200 kS/s (mil amostras por segundo). O software LabVIEW™ foi utilizado para gerenciar todas as medidas dos sensores, controle da placa de aquisição,

comando da placa de controle do dinamômetro, controle de temperatura do sistema de arrefecimento do motor e salvamento dos valores em tabelas.

Na Figura 9 é possível visualizar a interface de usuário desenvolvida para o gerenciamento da célula de testes. Observam-se indicadores de rotação, potência, torque, consumo, temperaturas e pressões na interface de usuário. Também verifica-se os controles disponíveis para o gerenciamento dos sistemas da bancada experimental, bem como os controles de aquisição de dados.

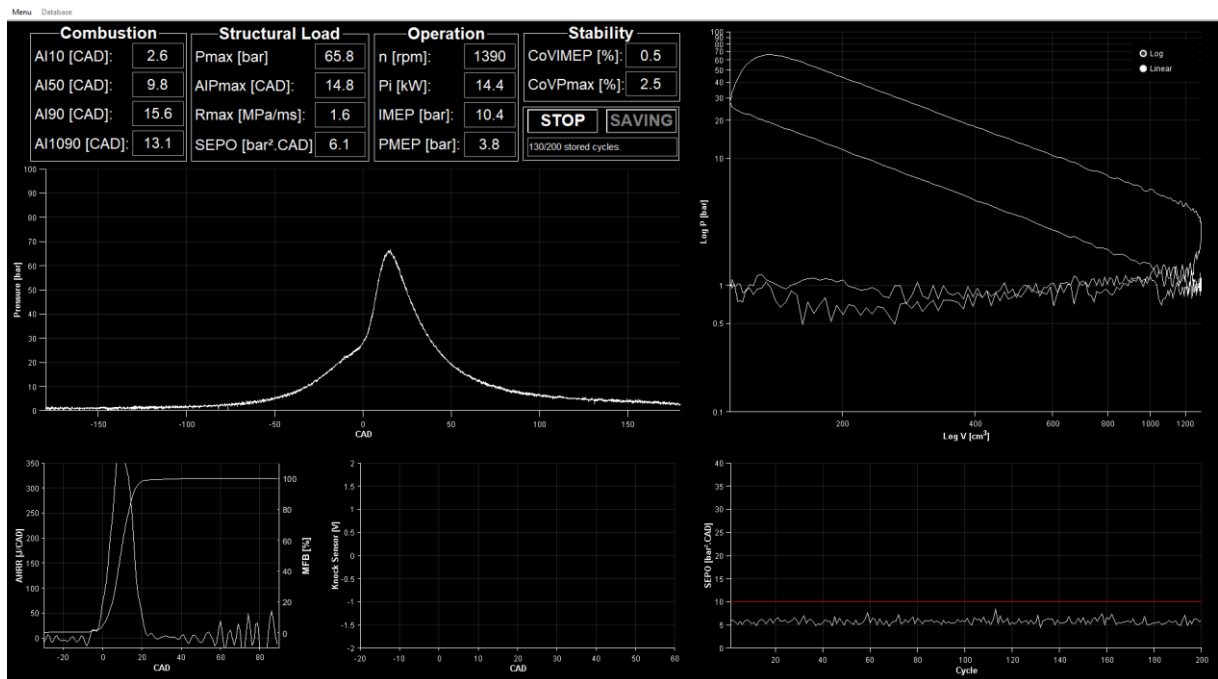
Figura 9 – Interface de usuário do software de controle e aquisição de dados da célula de testes.



O sistema de aquisição de dados indicados foi composto por uma placa de aquisição NI USB-6351 de 16 bits e capacidade de amostragem para 1.25 MS/s (um milhão de amostras por segundo). A frequência de amostragem é compartilhada para todos os canais. Os sinais do sensor de pressão de cilindro e do sensor de vibração são roteados para a placa de aquisição, com momento de disparo de aquisição pelos pulsos do encoder em uma resolução de 0.1 CAD. Esse tipo de aquisição de dados é do tipo não periódico, pois o ciclo é referenciado pela posição do virabrequim, assim o tempo entre os instantes de aquisição é variável com os pulsos do encoder pela ação da variação de aceleração no eixo virabrequim.

A Figura 10 apresenta a interface de usuário do sistema de indicação e análise de combustão. Observa-se os valores apresentados de combustão, como o ponto de início (AI10 ou CA10) da combustão, o ponto central da combustão (AI50 ou CA50) e o ponto final da combustão (AI90 ou CA90), bem como a duração de combustão (AI1090 ou CA1090). Também observam-se as curvas de pressão de cilindro instantânea, o gráfico de liberação de calor pela combustão e o diagrama pressão-volume indicativo do trabalho realizado no ciclo termodinâmico.

Figura 10 – Interface da interface de usuário do software do sistema de indicação.



4.3 DESCRIÇÃO DAS CONDIÇÕES OPERACIONAIS

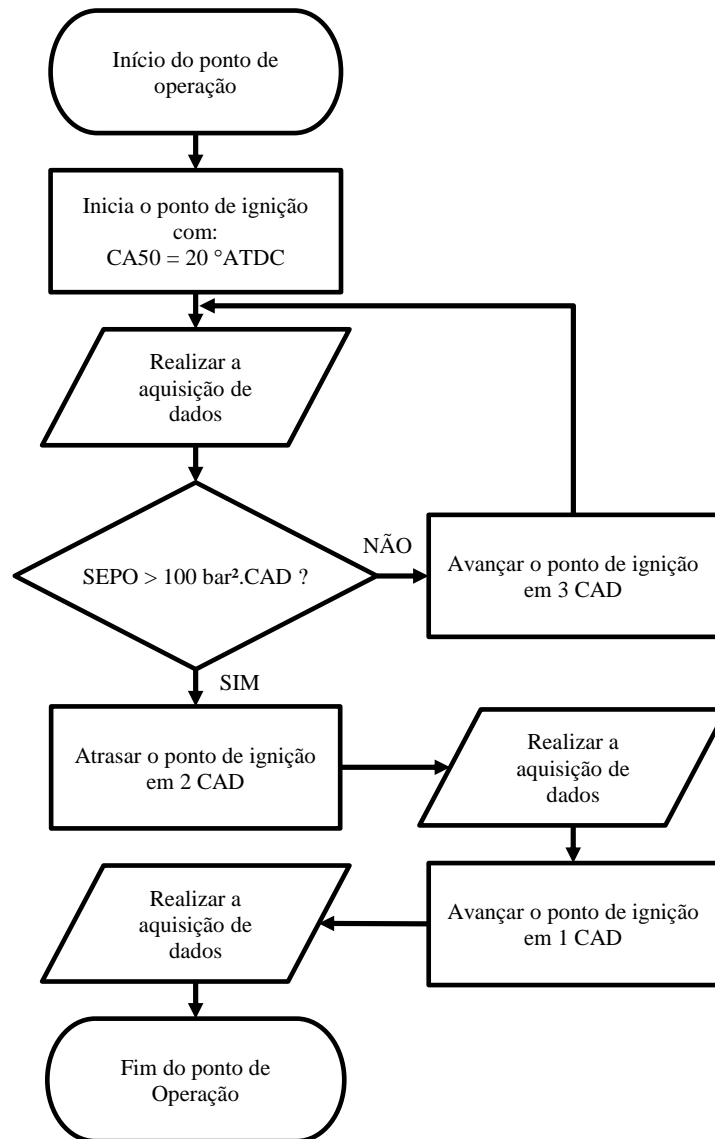
A rotina de testes adotada durante a coleta dos dados experimentais permitiu capturar várias fases de operação no motor, conforme apresentado na Tabela 3. Foi variada a rotação de 1200 a 2400 rpm com incrementos de 200 rpm. A mistura ar-combustível foi alterada de modo a obter um valor de lambda de 0,75, 0,85, 0,95 e 1,015. Manteve-se plena carga para todos os pontos de operação, o que significa uma pressão no coletor de admissão igual à pressão atmosférica. A temperatura da água do motor foi mantida constante a $89,73 \pm 2,3$ °C. A temperatura do óleo foi mantida constante a $87,2 \pm 5,6$ °C. O avanço de ignição foi definido com base no parâmetro de quantidade de massa queimada no processo de combustão. O instante de 50% de massa queimada (ou CA50) define o centro da combustão. Foi adotado um valor inicial de CA50 de 20 °ATDC (do inglês *after top-dead-center*), com base no software de indicação, e com avanços sucessivos de ponto de ignição de 3 CAD, foi chegando-se próximo ao ponto de detonação. O avanço é cessado quando o valor de SEPO ultrapassa 100 bar².CAD. Quando o limite é ultrapassado, o ponto é adquirido e o avanço de ignição atrasado, de modo à discretizar a região de detonação em 1 CAD. O fluxograma da metodologia de aquisição de dados no ponto de operação pode ser visto na Figura 11.

Ao total, foram adquiridos 137 pontos de operação válidos, com 200 ciclos em cada ponto.

Tabela 3 – Descrição das condições de operação no motor

Condições de Varredura		
Rotação do Motor [rpm]	Ponto de Ignição [°BTDC]	λ
1200	ST (CA50 → 20 °ATDC)	1,015
1400	avanço +3°	0,95
1600	avanço +6°	0,85
1800	avanço +9°	0,75
2000	avanço +12°	
2200	avanço +15°	
2400	:	

Figura 11 – Fluxograma do processo de aquisição dos pontos de operação.



Os dados coletados no procedimento experimental foram verificados e armazenados em um banco de dados, os quais servem para alimentar os métodos de detecção de detonação.

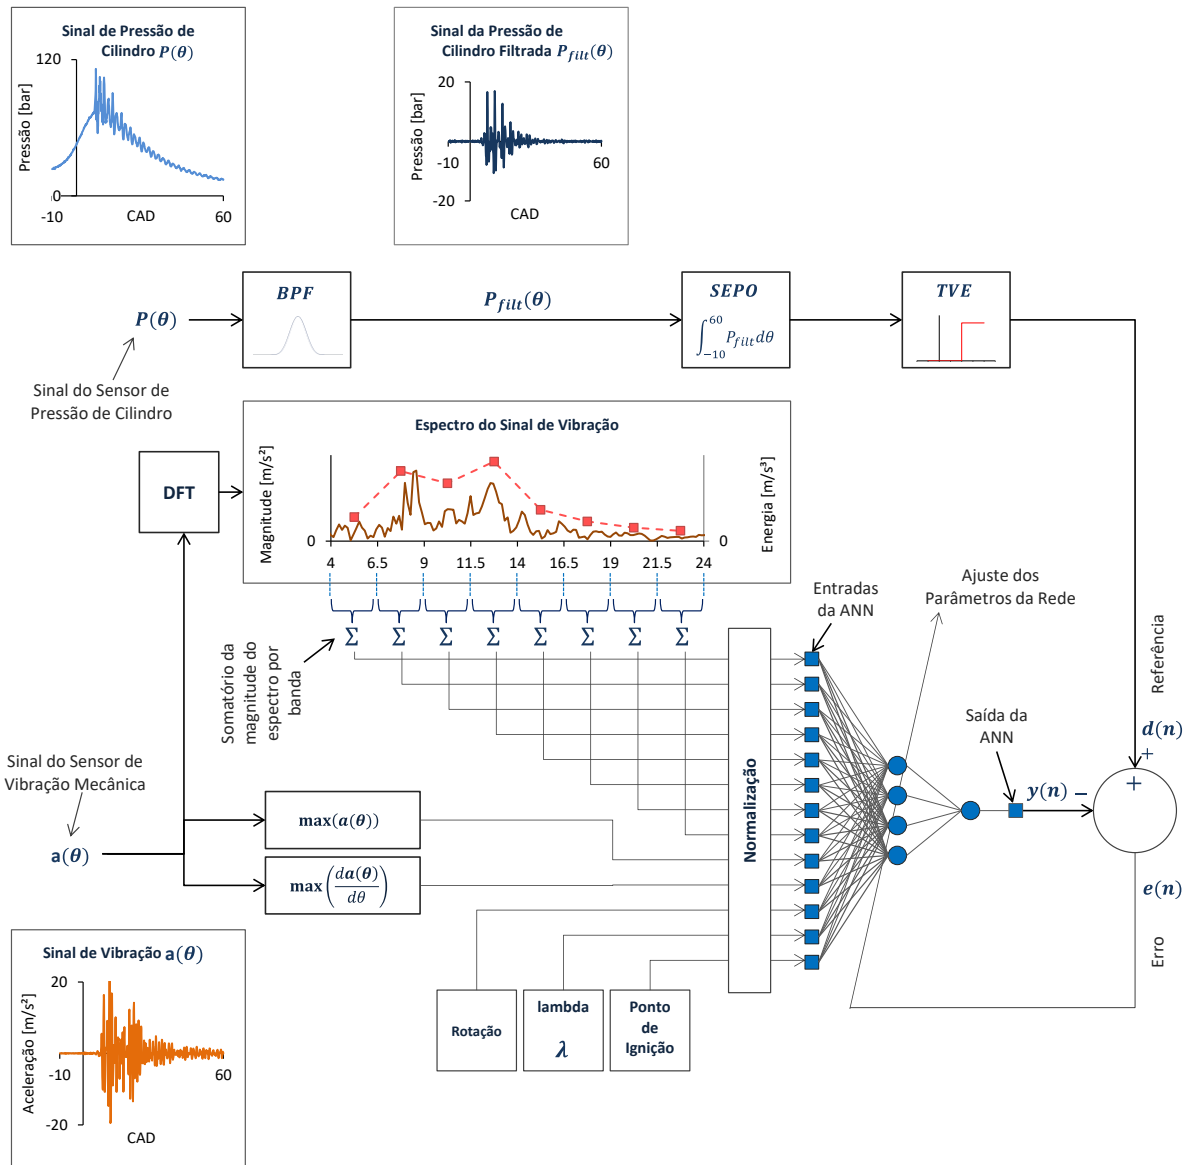
5 DETECÇÃO DE DETONAÇÃO COM ANN

A Figura 12 apresenta o diagrama em blocos da técnica para a detecção de detonação baseada em ANN proposta neste trabalho, denominada KODANN (do inglês: *Knock Occurrence Detection using Artificial Neural Network*). A ANN utilizada é uma rede perceptron de uma camada oculta, com função de ativação sigmoide, conforme descrito na Seção 3.1. A ANN possui 4 neurônios na camada oculta e um neurônio na camada de saída. Esses parâmetros de números de camadas e quantidades de neurônios foram obtidos por tentativa e erro, assim visando um menor tempo computacional e um menor erro de assertividade. A rede possui 13 entradas e uma saída. Dez entradas da rede recebem informação proveniente do resultado de um pré-processamento no sinal do sensor de vibração. As demais entradas recebem o valor de rotação do motor, a relação ar-combustível por ar-combustível estequiométrica (λ) e o ponto de ignição. Na etapa de pré-processamento, o sinal do sensor de vibração é transformado do domínio do tempo para o domínio da frequência (bloco DFT), de modo a obter o seu espectro. Neste ponto, são definidas 8 bandas espectrais de interesse, de 4 a 25 kHz, cada uma com largura banda de 2,5 kHz. O somatório do módulo das componentes espectrais de cada banda alimenta uma entrada da ANN.

O treinamento da ANN é supervisionado. Para guiar o treinamento da rede neural o sinal do sensor de pressão é aplicado à técnica clássica SEPO. O resultado do SEPO é avaliado em relação ao limiar de decisão na técnica TVE, servindo de referência durante a fase de treinamento da rede neural artificial. Optou-se pelo treinamento da ANN baseado no resultado da técnica SEPO por esta ser uma técnica clássica de detecção de detonação e por utilizar o sinal de um sensor com alta relação sinal ruído e alta imunidade a interferências externas no estímulo captado (SCHOLL, BARASH, *et al.*, 1997).

O banco de dados foi dividido em duas partes, uma para treino e outra para validação: 83,33% dos ciclos foram utilizados durante o treinamento e 16,67% durante a validação. O banco de dados utilizado contempla 12,04% de ciclos com detonação, considerando 10 bar².CAD de limiar para a detecção utilizando o valor de SEPO. Para dividir o banco de dados, o mesmo foi ordenado de forma crescente, com base no valor do SEPO. O conjunto de dados de validação foi retirado do banco de dados com equidistância de 6 ciclos, pois o objetivo é compor um grupo de dados de validação que percorresse boa parte dos cenários de intensidade de detonação. O restante dos ciclos foi agrupado no conjunto utilizado no treinamento da rede.


Figura 12 – Diagrama em blocos da técnica de detecção de detonação utilizando ANN.



O passo-a-passo do treinamento pode ser descrito por algumas etapas. Primeiramente, são iniciados os pesos sinápticos com valores aleatórios entre -1 e 1. Em seguida, são definidos alguns parâmetros como a taxa de aprendizagem, o valor de decaimento da taxa de aprendizagem e o número de épocas. A taxa de aprendizagem η utilizada para o treinamento foi de 0,1 para a primeira época e calculado um decaimento de 99,8% a cada época seguinte. Foi estabelecido um treinamento com a passagem total de 1000 épocas. A cada época o conjunto de dados de treinamento é reordenado aleatoriamente e todo o conjunto de treino é aplicado à entrada da rede. Ao final de cada época de treino, o erro médio quadrático (MSE, do inglês: *mean squared error*) é calculado e armazenado e os pesos sinápticos resultantes do

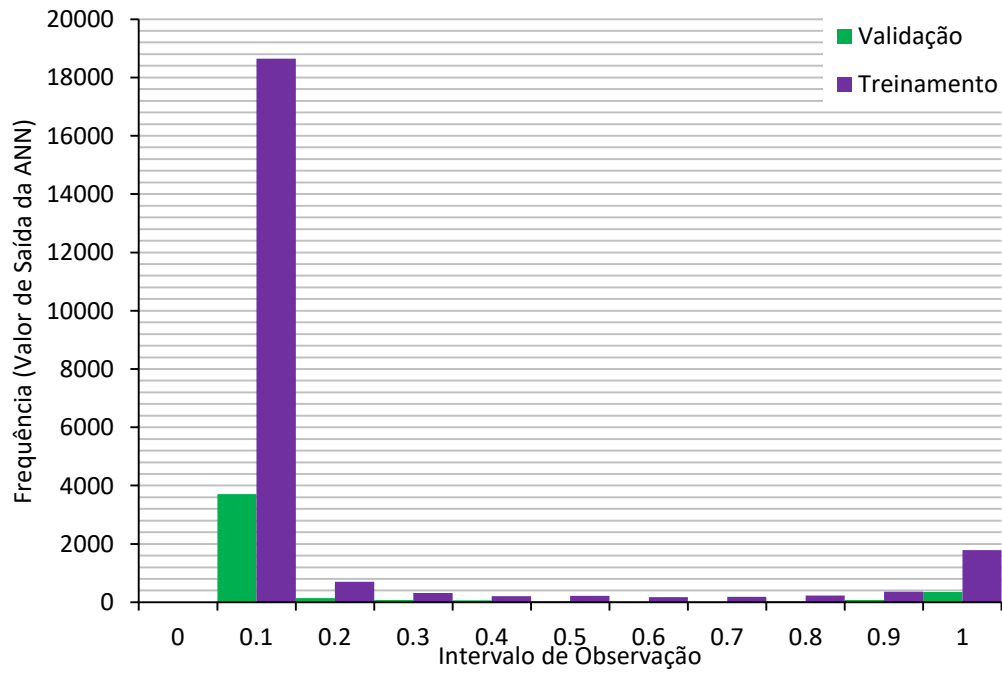
treinamento são utilizados para obter a saída da rede do conjunto de validação. O MSE de validação é então calculado e armazenado. Este processo se repete por 1000 épocas, quando se considera que o treinamento está concluído. O valor época-a-época do MSE de treino e validação pode ser visto na Figura 13. O treino apresenta erro residual de aproximadamente $2,15 \times 10^{-2}$, enquanto que para a validação o erro é de aproximadamente $2,28 \times 10^{-2}$. Note que, após apenas 400 épocas o treino atinge MSE inferior a $2,4 \times 10^{-2}$. As curvas do MSE de treino e validação demonstram que a ANN conseguiu generalizar, uma vez que, mesmo para um conjunto de dados não apresentado à rede durante a etapa de treino, ela conseguiu produzir valores na saída próximos aos desejados.

Figura 13 – Erro médio quadrático no processo de treinamento da rede neural.



O resultado de saída da ANN para os dados de entrada de treino e validação pode ser visto na Figura 14. Este gráfico apresenta o histograma dos valores de saída da rede em intervalos de observação. Em um cenário ideal, os dados estariam concentrados nos extremos, o que indica uma classificação binária perfeita pela rede neural, porém o resultado observado é um gradiente de valores que contempla toda a faixa regida pela referência de 0 a 1. Observa-se que o vale das duas distribuições de frequência se dão próximas ao valor de 0,5.

Figura 14 – Histograma dos valores de saída da ANN para o conjunto de dados de treinamento e validação.



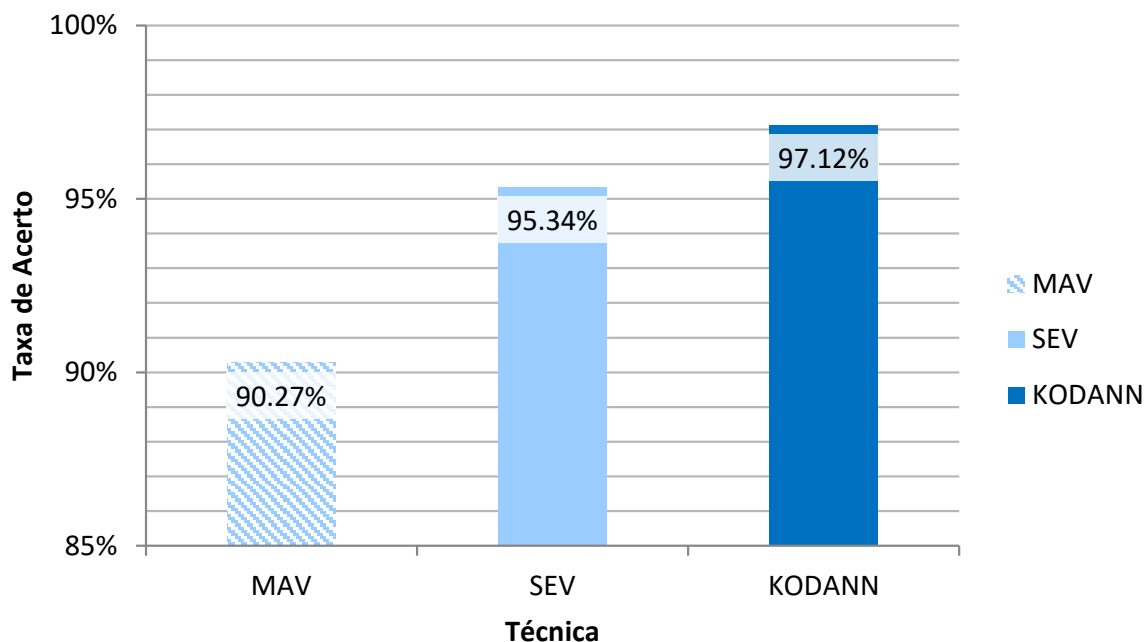
6 RESULTADOS

Este Capítulo apresenta os resultados e faz uma análise comparativa das técnicas de detecção de detonação utilizando o sinal do sensor de vibração MAV, SEV, KODANN, esta última proposta neste trabalho.

Os limiares do TVE para as técnicas MAV e SEV foram calibrados, sendo adotado o valor de $2,48 \text{ m/s}^2$ para o MAV e $14,01 \text{ m}^2/\text{s}^4$. CAD para o SEV. Como dito anteriormente, o limiar do TEV adotado para a KODANN é de 0,5.

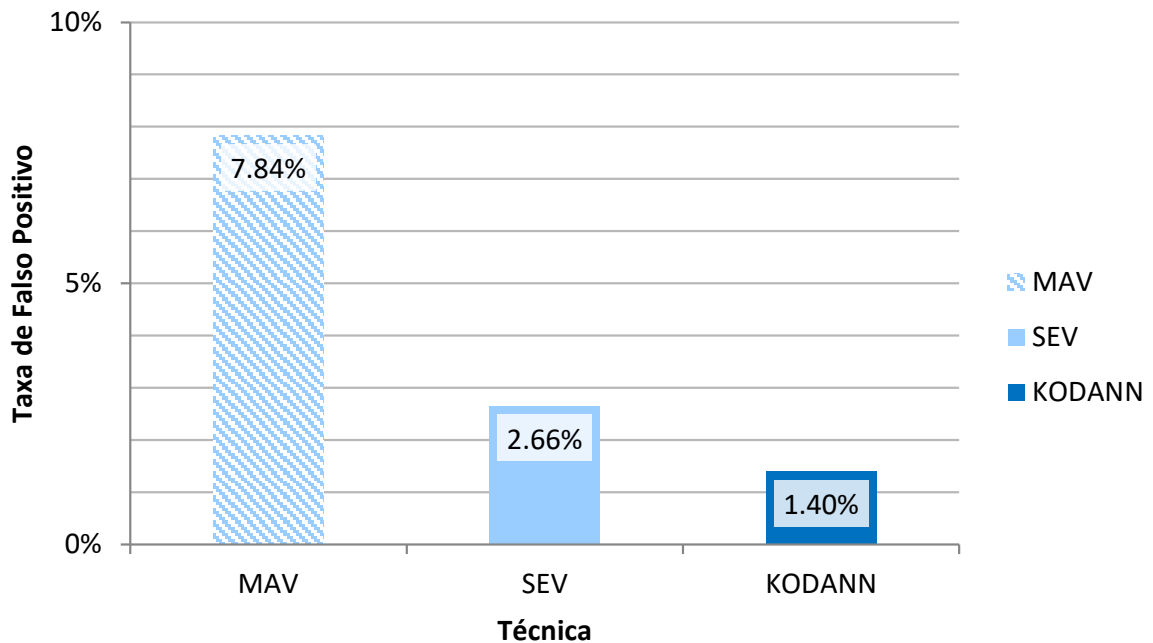
A Figura 15 apresenta o resultado da taxa de acerto para as técnicas de MAV, SEV e ANN. O método MAV obteve taxa de acerto de 90,27%, sendo este o pior resultado entre as três técnicas avaliadas. Esse valor baixo no comparativo pode ser explicado pela baixa SNR do sinal de vibração mecânica, que influencia nos valores de máxima amplitude do sinal do sensor, fazendo com que o valor máximo varie significativamente para intensidades de detonação próximas. A técnica SEV apresenta taxa de acerto de 95,34%, apresentando desempenho intermediário no comparativo das três. Esta taxa um pouco superior em relação à técnica MAV pode ser explicada pela menor susceptibilidade ao ruído no resultado do cálculo da energia do sinal. Para a técnica da KODANN, a taxa de acertos observada é de 97,12%, obtendo o melhor desempenho entre as três técnicas avaliadas. Diversos fatores podem contribuir para este aumento de aproximadamente 2% e 7% no desempenho da KODANN em comparação a SEV e a MAV, respectivamente. Um fator é a capacidade de adaptação e de generalização das redes neurais. Outro fator é a adição das informações rotação, lambda e ponto de ignição. O treinamento baseado na técnica SEPO, utilizando o sinal do sensor de pressão de cilindro, agrega as características de alta SNR e estabilidade deste método, o que pode ter contribuído no bom desempenho apresentado pela KODANN.

Figura 15 – Taxa de acertos por técnica de detecção de detonação.




A Figura 16 apresenta a taxa de falsos positivos para as técnicas MAV, SEV e ANN. O falso positivo indica a detecção de detonação em ciclos que não apresentam detonação, representando uma falsa detecção. Um falso positivo ocorre quando, para determinado ciclo, a técnica SEPO (utilizada como referência neste trabalho) não detecta detonação e técnica em análise (MAV, SEV ou KODANN) detecta detonação. O falso positivo é ruim para o sistema, pois a falsa ocorrência de detonação indica que o ponto de ignição deve ser retardado para evitar o *spark knock*, o que resulta no decréscimo de eficiência devido ao afastamento do ponto de MBT. A técnica MAV apresentou uma taxa de falso positivo de 7,84%, obtendo o pior desempenho nesta métrica entre todas as técnicas avaliadas. O desempenho do SEV foi superior ao MAV, ficando com uma taxa de 2,66%. A menor taxa de falso positivo foi obtida pela ANN, que apresentou 1,40% de falsos positivos.

Figura 16 – Taxa de falsos positivo por técnica de detecção de detonação.



A Figura 17 mostra os resultados de falso negativo para as técnicas de MAV, SEV e KODANN. O falso negativo indica a não detecção de detonação em ciclos que apresentam detonação. Um falso negativo ocorre quando, para determinado ciclo, a técnica SEPO detecta detonação e técnica em análise não detecta detonação. Nesta situação, o sistema de controle do motor considera que o motor está em uma condição normal de operação, enquanto que, na realidade, detonações estão ocorrendo, podendo levar o motor a falha mecânica. A técnica MAV apresenta taxa de 1,89% de falso negativo, enquanto que para a técnica SEV a taxa é de 2,00%. A KODANN apresentou a menor taxa de falso negativo, ficando em 1,49%.


Figura 17 – Taxa de falso negativo por técnica de detecção de detonação.



A Figura 18 apresenta uma análise comparativa que possibilita identificar os intervalos de intensidade de detonação em que mais ocorrem erros de detecção de detonação para cada uma das técnicas avaliadas. É possível observar que há uma clara variação da distribuição dos erros de detecção para baixas intensidades de detonação, em relação aos intervalos superiores a 10, entre as três técnicas. No intervalo de SEPO de 4 a 6, o erro é mais evidente para a técnica MAV, pois se distanciou do padrão de erro para os outros intervalos. Isso pode ser explicado pela baixa SNR e pelas variações nos valores de máxima amplitude no sinal do sensor de vibração. A técnica SEV apresentou um erro distribuído praticamente igual ao longo de todos os intervalos de observação. A técnica KODANN desenvolvida apresentou uma grande melhora para a região de baixa intensidade, entre 4 e 6, região em que fica evidente a diferença de erros de detecção para as demais técnicas. Para os outros intervalos, a distribuição do erro de detecção de detonação acompanhou um padrão de pouca variação. Logo, verifica-se a KODANN obteve desempenho significativamente superior às demais técnicas na região de valores baixos de SEPO, região onde não ocorrem detonações. Isso justifica a redução significativa na taxa de falso positivo obtida pela KODANN em comparação com o MAV e SEV.

Cabe salientar que a ANN utilizada é uma rede simples, com uma única camada escondida com apenas 4 neurônios, que adota a função de ativação sigmoide, de modo que os únicos parâmetros livres da rede são os pesos sinápticos.

Figura 18 – Distribuição dos erros de detecção de detonação por técnica.



Um resumo dos resultados obtidos pode é apresentado na Tabela 4. No total, foram observadas 2398, 1240 e 790 ocorrências de erro de detecção pelas técnicas MAV, SEV e ANN, respectivamente. Isso representa um erro de 8,75%, 4,53% e 2,88% do total de ciclos do banco de dados utilizado, para as técnicas MAV, SEV e KODANN, respectivamente. Foi observada uma redução nos erros de detecção pela técnica KODANN em até 204% no comparativo com a técnica MAV e 57% no comparativo com a técnica SEV. Isso indica que a KODANN apresenta um ganho significativo na detecção de detonação utilizando o sensor de vibração.

Tabela 4 – Resumo dos dados obtidos pelo comparativo das técnicas clássicas MAV e SEV com a técnica da ANN proposta.

Parâmetro	MAV	SEV	ANN
Taxa de acertos	90.27%	95.34%	97.12%
Taxa de falso positivo	7.84%	2.66%	1.40%
Taxa de falso negativo	1.89%	2.00%	1.49%
Total de ocorrência de erros de detecção	2398	1240	790
Percentual da quantidade de erros em relação ao banco de dados	8.75%	4.53%	2.88%
Razão de redução de erros pela ANN	204%	57%	-

7 CONCLUSÃO

Este Trabalho de Conclusão de Curso apresentou um estudo sobre técnicas de detecção de detonação clássicas em um motor de combustão interna de ignição por centelha, como o MAPO e o SEPO, ambas baseadas no sensor de pressão de cilindro. Visando obter uma solução mais econômica, as técnicas clássicas foram adaptadas para o sensor de vibração mecânica do motor, resultando nas técnicas MAV e SEV. Porém, dada a característica de baixa relação sinal-ruído do sinal do sensor de vibração, as técnicas MAV e SEV apresentam desempenho consideravelmente inferior a técnica SEPO. Deste modo, uma solução para o problema de detecção de detonação em um motor de combustão interna de ignição por centelha baseado no sensor de vibração mecânica do motor foi proposta através do uso de uma ANN.

A ANN utilizada foi uma rede perceptron de uma camada oculta, composta por 13 entradas, 1 saída e 4 neurônios na camada oculta. As entradas foram escolhidas de acordo com a influência na detecção de detonação. O sinal do sensor de vibração mecânica foi pré-processado em 3 operações diferentes: o somatório do módulo de 8 bandas no espectro do sinal, o valor máximo instantâneo do sinal de vibração, o valor máximo instantâneo da derivada do sinal. Outros 3 parâmetros do motor foram utilizados para compor o conjunto de entrada com a rotação do motor, o fator lambda e o ponto de ignição. As técnicas foram avaliadas utilizando um banco de dados obtido através de medidas realizadas em 137 pontos de operação, com 200 ciclos cada. Diversos sinais e parâmetros operacionais do motor foram adquiridos a cada ciclo de operação, dentre eles os sinais de pressão de cilindro e o sinal do sensor de vibração mecânica acoplado ao bloco do motor, em situações de funcionamento normal e situação de ocorrência de detonação.

O sinal de pressão de cilindro foi utilizado para detecção de detonação pela técnica SEPO e o resultado foi adotado como referencial de detecção de detonação. O desempenho das técnicas MAV e SEV e da solução proposta neste trabalho, denominado método KODANN, foi avaliado considerando como entrada o sinal do sensor de vibração mecânica. Os resultados obtidos mostram que o KODANN obteve 97,12% de acertos, o que demonstra que a capacidade de adaptação e de generalização da ANN. As técnicas MAV e SEV obtiveram taxa de acertos de 90,27% e 95,34%, respectivamente. Pela análise dos resultados, foi possível concluir que a ANN foi capaz de processar corretamente o sinal do sensor de vibração correspondente aos ciclos de baixo valor de SEPO, o que resultou em uma redução

significativa na taxa de falso positivo obtida pelo KODANN em comparação com o MAV e SEV. Comparativamente, a ANN apresentou uma redução de 204% nos erros de detecção em comparação com a MAV e uma redução de 57% em relação à técnica SEV. A abordagem proposta, utilizando redes neurais e um sinal com baixa relação sinal-ruído, apresentou bom desempenho, mostrando-se promissora como instrumento de aumento de eficiência em motores de combustão interna de ignição por centelha de pequeno porte.

8 TRABALHOS FUTUROS

Como sugestão de trabalhos futuros, alguns tópicos podem ser mais explorados. Partindo da coleta de dados, diferentes motores podem ser utilizados para formar um conjunto de dados diversificado e generalista, assim tendo potencial de agregar uma generalização ao método KODANN. Trabalhos poderiam ser realizados no aprimoramento e teste de outras estruturas de ANNs, assim podendo reduzir o número de erros de detecção de detonação. É sugerido um trabalho na verificação da influência de mais parâmetros de entrada do método KODANN, assim podendo promover um menor número de erros de detecção.

REFERÊNCIAS

ARBIB, M. A. **The handbook of brain theory and neural networks**. 2^a. ed. Cambridge, Massachusetts, London, England: MIT PRESS, 2003.

BI, F.; MA, T.; WANG, X. Development of a novel knock characteristic detection method for gasoline engines based on wavelet-denoising and EMD decomposition. **Mechanical Systems and Signal Processing**, n. 117, p. 517-536, 2019.

CONSELHO NACIONAL DO MEIO AMBIENTE, C. **RESOLUÇÃO Nº 492, DE 20 DE DEZEMBRO DE 2018**. Diário Oficial da União. Brasil: [s.n.]. 20 Dezembro 2018. p. 141.
CORRIGAN, D. J.; FONTANESI, S. Knock: A Century of Research. **SAE International**, v. 15, 2022.

DENATRAN, D. N. D. T. Frota Veículos - 2020. **Ministério da Infraestrutura**, 2020. Disponível em: <<https://www.gov.br/infraestrutura/pt-br/assuntos/transito/conteudo-denatran/frota-de-veiculos-2020>>. Acesso em: 20 Dezembro 2020.

FAGUNDEZ, J. L. S. et al. An investigation on performance and combustion characteristics of pure n-butanol and a blend of n-butanol/ethanol as fuels in a spark ignition engine. **Energy**, v. 176, p. 521-530, 2019.

FITTON, J. C.; NATES, R. J. Knock erosion in spark-ignition engines. **SAE transactions**, p. 2318-2326, 1996.

HAYKIN, S. **Neural Networks: A comprehensive foundation**. 2^a. ed. [S.l.]: Pearson, 1998.

HEYWOOD, J. B. **Internal Combustion Engine Fundamentals**. 2^a. ed.: McGraw-Hill, 2018.

HOSEY, R. J.; POWELL, J. D. Closed Loop, Knock Adaptive Spark Timing Control Based on Cylinder Pressure. **Journal of Dynamic Systems, Measurement, and Control**, p. 64-69, 1979. ISSN <https://doi.org/10.1115/1.3426400>.

IEA. **Energy Efficiency 2021**. [S.l.], p. 66. 2021.

KRÖSE, B.; SMAGT, P. V. D. **An introduction to Neural Networks**. 18. ed. Amsterdam: The University of Amsterdam, 1996.

LEPPARD, W. R. Individual-Cylinder Knock Occurrence and Intensity in Multicylinder Engines. **SAE Technical Paper**, Detroit, 1982.

NABER, J. D. et al. Analysis of Combustion Knock Metrics in Spark-Ignition Engines. **SAE Technical Paper**, 2006.

NATES, R. J.; YATES, A. D. B. Knock damage mechanisms in spark-ignition engines. **SAE transactions**, p. 1970-1980, 1994.

PLA, B. et al. Increasing knock detection sensitivity by combining knock sensor signal with a control oriented combustion model. **Mechanical Systems and Signal Processing**, v. 168, Abril 2022.

PLA, B. et al. Increasing knock detection sensitivity by combining knock sensor signal with a control oriented combustion model. **Mechanical Systems and Signal Processing**, v. 168, p. 108665, 2022.

RAUBER, T. W. Redes Neurais Artificiais. **Universidade Federal do Espírito Santo**, v. 29, 2005.

RITCHIE, H. Global CO2 emissions from transport. **Our Word in Data**, 2021. Disponível em: <<https://ourworldindata.org/co2-emissions-from-transport#:~:text=Transport%20accounts%20for%20around%20one%2Dfifth%20of%20global%20carbon%20dioxide,CO2%20emissions%20from%20energy%5D.&text=This%20data%20is%20sourced%20from,three%2Dquarters%20of%20transport>>. Acesso em: 14 jan. 2022.
SCHOLL, D. et al. Spectrogram Analysis of Accelerometer-Based Spark Knock Detection Waveforms. **SAE Technical Paper**, 1997.

SHAHLARI, A. J.; GHANDHI, J. B. A comparison of engine knock metrics. **SAE Technical Paper**, 2012.

SHEN, X.; ZHANG, Y.; SHEN, T. Cylinder pressure resonant frequency cyclic estimation-based knock intensity metric in combustion engines. **Applied Thermal Engineering**, p. 113756, 2019.

WORRET, R. et al. Application of Different Cylinder Pressure Based Knock Detection Methods in Spark Ignition Engines. **SAE Technical Paper**, 2002.

NUP: 23081.038008/2022-13

Prioridade: Normal

Homologação de ata de defesa de TCC e estágio de graduação

125.322 - Bancas examinadoras de TCC: indicação e atuação

COMPONENTE

Ordem	Descrição	Nome do arquivo
3	TCC	TCC_Juliano_Silveira_Versão_Envio_Final.pdf

Assinaturas

12/04/2022 10:45:22

CANDICE MULLER (PROFESSOR DO MAGISTÉRIO SUPERIOR)
07.38.00.00.0.0 - DEPARTAMENTO DE ELETRÔNICA E COMPUTAÇÃO - DELC



1960



1960

Código Verificador: 1324659

Código CRC: 2c905abf

Consulte em: <https://portal.ufsm.br/documentos/publico/autenticacao/assinaturas.html>

