

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO CEARÁ
PRÓ-REITORIA DE PESQUISA, PÓS-GRADUAÇÃO E INOVAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Lucas Costa da Silva

**SLCM - Um novo extrator de características para aplicações
embarcadas de classificação de padrões em sinais elétricos**

Fortaleza – CE

17 de dezembro de 2021

Lucas Costa da Silva

**SLCM - Um novo extrator de características para
aplicações embarcadas de classificação de padrões em
sinais elétricos**

Dissertação submetida ao Programa de Pós-Graduação em Ciência da Computação do Instituto Federal de Educação, Ciência e Tecnologia do Ceará, como requisito parcial para obtenção do grau de Mestre em Ciência da Computação.

Linha de Pesquisa: Sistemas embarcados

Orientador: Elias Teodoro Silva Júnior

Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE)

Pró-Reitoria de Pesquisa, Pós-Graduação e Inovação (PRPI)

Programa de Pós-Graduação em Ciência da Computação (PPGCC)

Fortaleza – CE

17 de dezembro de 2021



Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE)
Pró-Reitoria de Pesquisa, Pós-Graduação e Inovação (PRPI)
Programa de Pós-Graduação em Ciência da Computação (PPGCC)

Lucas Costa da Silva

Esta dissertação foi julgada adequada para a obtenção do título de Mestre em Ciência da Computação, sendo aprovada pela Coordenação do Programa de Pós-Graduação em Ciência da Computação do Instituto Federal de Educação, Ciência e Tecnologia do Ceará e pela banca examinadora:

Orientador: Elias Teodoro Silva Júnior

Instituto Federal de Educação, Ciência e Tecnologia do
Ceará (IFCE)

Cláudio Marques de Sá Medeiros

Instituto Federal de Educação, Ciência e Tecnologia do
Ceará (IFCE)

Pedro Pedrosa Rebouças Filho

Instituto Federal de Educação, Ciência e Tecnologia do
Ceará (IFCE)

Fortaleza – CE

17 de dezembro de 2021

Agradecimentos

Em primeiro lugar, gostaria de agradecer a Deus por me fornecer disciplina, força para prosseguir nesta jornada. A minha Família pelo apoio incondicional e amor durante todos esses anos.

A minha companheira Isabel, pelo apoio, conselhos e por estar ao meu lado em várias noites em claro que culminaram no desenvolvimento e conclusão desta pesquisa.

Ao Prof. Tiago Façanha por todos estes anos de companheirismo e amizade, e principalmente por ter me apresentado ao mundo da pesquisa e inovação, ainda durante o ensino médio.

Sou grato a meu orientador Prof. Elias Teodoro por todos os conselhos, apoio e paciência durante todo o trajeto que se iniciou ainda na graduação.

A minha mais sincera gratidão para com todos os que colaboraram, diretamente ou indiretamente, neste trabalho e também ao Instituto Federal do Ceará, em especial aos professores e colegas do PPGCC e LIT. Obrigado.

“Descobrir consiste em olhar para o que todo mundo está vendo e pensar uma coisa diferente.”

(Roger Von Oech)

Resumo

Técnicas de extração de atributos de imagem vêm sendo utilizadas em diversos trabalhos para extração de atributos de sinais, dentre os principais, o GLCM. Devido a serem algoritmos desenvolvidos para imagens, a principal abordagem utilizada por estes trabalhos é a conversão do sinal em imagem. Esta etapa de conversão acarreta consumo de memória para guardar a matriz da imagem. Tendo em vista este problema, este trabalho descreve uma abordagem para utilização dos cálculos estatísticos do GLCM em sinais no tempo, sem que haja a necessidade de transformação do sinal de entrada em imagem, reduzindo consumo de memória. Denominamos esta técnica como SLCM, Signal Level Co-occurrence Matrix. Os experimentos foram embarcados na plataforma STM32F429ZI, que utiliza um microcontrolador Arm Cortex-M4. Os resultados obtidos demonstram redução de 46% no consumo de memória volátil quando comparado a outras técnicas na literatura, sem que estas mudanças afetem significativamente a capacidade de diagnóstico do classificador.

Palavras-chave:GLCM, SLCM, Motores de indução, aprendizado de máquina, Sistemas embarcados, extrator de característica.

Lista de ilustrações

Figura 1 – Motor trifásico de gaiola de esquilo. Adaptado de Automation (1996) . . .	25
Figura 2 – Exemplo de geração de uma matriz de co-ocorrência com o método de chão e teto.	29
Figura 3 – Representação das imagens de uma classe normal e uma classe de falha.	29
Figura 4 – Representação da GLCM	30
Figura 5 – Exemplo de geração de uma matriz de co-ocorrência de 2 bits.	32
Figura 6 – Fluxo de informação para detecção de falhas.	32
Figura 7 – Ilustração da utilização do algoritmo CFS. Fonte: SAMPAIO (2017) . .	32
Figura 8 – Etapas do processo de classificação de falhas na plataforma embarcada.	45
Figura 9 – Processo para gerar matriz de coocorrência.	46

Lista de tabelas

Tabela 1 – Matriz de confusão média ao usar a técnica SLCM e os 24 atributos. . .	37
Tabela 2 – Matriz de confusão ao média ao usar a técnica SLCM e 10 atributos. . .	37
Tabela 3 – Matriz de confusão média ao usar a técnica de chão-teto e 24 atributos.	38
Tabela 4 – Matriz de confusão média ao usar a técnica de chão-teto (seção 2.3.2) e 10 atributos.	38
Tabela 5 – Matriz de confusão média ao usar a técnica de gráfico do sinal no tempo e 24 atributos.	39
Tabela 6 – Matriz de confusão ao usar a técnica de gráfico do sinal no tempo e 10 atributos GLCM.	39
Tabela 7 – Resumo dos resultados de acurácia das técnicas estudadas.	40
Tabela 8 – Redução da frequência de amostragem.	41
Tabela 9 – Aplicação de corte nas amostras	42
Tabela 10 – Resultados do experimento variando o tamanho da amostra pela redução da taxa de amostragem.	43
Tabela 11 – Resultados do experimento variando o tamanho da amostra pela técnica de corte binário.	43
Tabela 12 – Resultados de uso de memória de dados(RAM) na plataforma embarcada.	47
Tabela 13 – Resultados de uso de memória de programa(FLASH) na plataforma embarcada.	48
Tabela 14 – Resultados de desempenho do processo de classificação na plataforma embarcada.	49
Tabela 15 – Relação das 24 medidas estatísticas da GLCM. (SAMPAIO, 2017) . . .	61
Tabela 16 – Relação das 24 medidas estatísticas da GLCM. (SAMPAIO, 2017) . . .	61
Tabela 17 – Relação das 24 medidas estatísticas da GLCM. (SAMPAIO, 2017) . . .	62

Lista de abreviaturas e siglas

MI	Motor de Indução.
CPU	Central Process Unit.
GLCM	Gray Level Co-occurrence Matrix.
LBP	Local binary patterns.
SFFT	Sparse Fast Fourier Transform.
FFT	Fast Fourier transform.
STFT	Short-time Fourier transform.
CFS	Correlation-based feature selection.
SVM	Support Vector Machine.
RBF	Radial Basis Function.
HI	Alta impedância.
LI	Baixa Impedância.

Sumário

1	INTRODUÇÃO	19
1.1	Motivação	21
1.2	Descrição do problema	21
1.3	Objetivos Geral e Específicos	22
1.4	Produção científica	22
1.5	Estrutura da Dissertação	23
2	FUNDAMENTAÇÃO TEÓRICA	25
2.1	Detecção de falhas em motores elétricos	25
2.2	Técnicas de geração de atributos através de mudança de domínio do sinal	27
2.2.1	Transformada Wavelet combinada com estatísticas de alta ordem	27
2.3	Técnicas de geração de imagens através de sinais	28
2.3.1	Geração de imagem usando STFT.	28
2.3.2	Geração de imagem chão-teto.	28
2.3.3	Geração de imagem através do gráfico do sinal no tempo.	29
2.4	Matriz de co-ocorrência de níveis de cinza - GLCM	30
2.5	Signal Level Co-occurrence Matrix (SLCM)	31
2.6	Técnicas de seleção de atributos	32
2.6.1	Seleção de atributos baseado em correlação (CFS)	32
2.7	Máquinas de Vetores suporte	33
2.8	Projeto de Sistema Embarcado	34
3	PROCEDIMENTOS E RESULTADOS	35
3.1	Conjunto de dados	35
3.2	Avaliação dos extratores de características	36
3.2.1	Processo de extração de métricas de avaliação	36
3.2.2	Experimento usando a técnica SLCM	37
3.2.3	Experimento usando a técnica de chão-teto	38
3.2.4	Experimento usando a técnica de gráfico do sinal no tempo	39
3.2.5	Análise de resultados	39
3.3	Metodologias para redução no tamanho da amostra.	40
3.3.1	Redução na taxa de amostragem	41
3.3.2	Redução no tempo de amostragem	41
3.4	Avaliação da redução no tamanho da amostra	42
3.4.1	Usando redução na taxa de amostragem	42

3.4.2	Usando redução do tempo de amostragem	43
3.4.3	Análise de resultados	43
3.5	Avaliação na plataforma embarcada	44
3.5.1	Análise de uso de memória	46
3.5.2	Análise de desempenho do processo de classificação	49
3.6	Avaliação Geral	51
4	CONCLUSÃO	53
4.1	Trabalhos futuros	54
	REFERÊNCIAS	55
	APÊNDICE A – ESTUDO DA COMPLEXIDADE NA EXTRAÇÃO DOS ATRIBUTOS - GLCM	61

1 Introdução

Um sistema embarcado é qualquer dispositivo que inclui um computador programável, mas não se destina a ser um computador de propósito geral. Os sistemas computacionais embarcados estão presentes em praticamente todas as atividades humanas (WOLF, 2012).

Exemplos de tais sistemas são os telefones celulares com máquina fotográfica e agenda, o sistema de controle dos carros e ônibus, os computadores portáteis palm-top, os fornos de micro-ondas com controle de temperatura inteligente, as máquinas de lavar e outros eletrodomésticos.

Os sistemas embarcados também são incorporados na automação industrial com a finalidade de auxiliar em seus processos. Um exemplo é sua utilização no controle de motores de indução (MI). Motores de indução são utilizados em aplicações industriais para conversão de energia elétrica em mecânica, devido a sua alta eficiência, robustez, confiabilidade e baixo custo de manutenção. Os MI são amplamente utilizados na indústria, chegando a consumir entre 40% a 50% de toda a capacidade energética gerada em um país industrializado (THOMSON; FENGER, 2001).

Os motores de indução apresentam falhas devido a vários motivos como envelhecimento, condições de instalação, aplicações inadequadas, falta de manutenção preventiva e esforços mecânicos ou elétricos (GHATE; DUDUL, 2010; NANDI; TOLIYAT, 1999). As falhas mais comuns, conforme listadas em Nandi e Toliyat (1999), Nandi, Toliyat e Li (2005), ocorrem no enrolamento do estator, na isolação do estator ou rotor, através das barras de abertura, anéis de trinca ou excentricidade dinâmica e estática. Conforme indicado em Group et al. (1985), Albrecht et al. (1986), o curto-circuito entre as espiras do enrolamento é a segunda causa mais comum de falha em motores de indução, sendo a primeira a falha no enrolamento do estator.

Quando os motores de indução são acionados por conversor de frequência (inversor), a situação tende a ser ainda pior devido ao estresse imposto pelas rápidas transições de tensão, impostas pelos transistores do inversor, o que contribui ainda mais para o rompimento do isolamento (PANDEY; ZOPE; SURALKAR, 2012). Em Kaufhold et al. (2002) é indicado que o estresse no enrolamento é dez vezes maior em máquinas alimentadas por inversores, quando comparados com máquinas alimentadas em linha.

Nesse cenário, há uma tendência da indústria e da comunidade de pesquisa em buscar soluções para detectar falhas em motores de indução conforme indicado em revisões como Nandi e Toliyat (1999), Pandey, Zope e Suralkar (2012). Além disso, com o impacto dos conversores de frequência, surge a possibilidade de diagnósticos preventivos por técnicas não invasivas através de monitoramento online constante. Se um algoritmo para diagnosticar

a condição do motor for desenvolvido para ser embarcado em um microcontrolador, por exemplo, é possível embutir esse algoritmo no controlador do conversor de frequência, aproveitando o hardware presente na maioria desses equipamentos.

Algumas pesquisas indicam que esse diagnóstico pode ser feito usando algoritmos de inteligência artificial, conforme visto em trabalhos como Morsalin et al. (2014), Bouzid e Champenois (2013), Lashkari e Poshtan (2015) e trabalhos publicados pelos autores Lashkari e Poshtan (2015), Coelho e Medeiros (2013), Coelho et al. (2014), Oliveira, Pontes e Medeiros (2013), Vieira, Medeiros e Silva (2016). No entanto, é comum desenvolver soluções inteligentes para problemas práticos em estações de trabalho onde não há limitações de recursos computacionais. Isso pode levar a problemas de recursos ao mover a implementação final para a plataforma de destino. Consequentemente, essas plataformas embarcadas, geralmente com restrições de recursos, como espaço de memória reduzidos e baixo desempenho da CPU, podem não atender aos requisitos do algoritmo.

Uma forma de detecção de falhas em MIs é analisando o fluxo de vazamento axial como mostrado nos trabalhos de Cunha (2019), Vieira, Medeiros e Silva (2016), esse valor idealmente deve ser zero. No entanto, na prática existem assimetrias na geometria do enrolamento e uniformidade do material. Dessa forma, há um pequeno, mas mensurável fluxo de vazamento axial em máquinas reais. Este sinal de fluxo de vazamento axial é medido ao longo do tempo gerando um sinal elétrico.

Este trabalho usa como conjunto de dados o problema de motores de indução baseado no sinal de fluxo de vazamento axial usado no trabalho de Cunha (2019).

Uma forma de uso de algoritmos de aprendizagem de máquina usando sinais como entrada que vem sendo explorada recentemente é a utilização de uma transformação do sinal em imagem, como mostrado nos trabalhos Abdeldayem e Bourlai (2018), Sousa et al. (2019), Islam, Uddin e Kim (2018), Jang, Kang e Kim (2014), Uddin, Van e Kim (2015), Azad, Khaled e Pavel (2019) que utilizam diferentes técnicas para este fim. Com a imagem gerada é realizada uma análise na textura da imagem, visando a extração de características. Os trabalhos citados apresentam resultados acima de 90% em taxas de acerto, sendo consideradas boas taxas de acerto, porém esta transformação do sinal em uma imagem pode causar um gasto de recursos para armazenamento da imagem gerada ao utilizar uma plataforma embarcada de mais baixo custo, porém com recursos limitados.

A Matriz de Coocorrência de Níveis de Cinza (GLCM) é uma técnica que têm sido utilizada em muitos trabalhos para capturar a textura de imagens desde que foi proposta por Haralick, Shanmugam e Dinstein (1973). Este método utiliza como entrada uma imagem em escala de cinza. A partir desta imagem é produzida uma matriz de co-ocorrência, em seguida são extraídos atributos estatísticos desta matriz que serão utilizados para treinamento e predição em algoritmos de aprendizagem de máquina.

Resumidamente, o processo para extrair atributos de um sinal se dá através das seguintes etapas:

1. **Transformação do sinal:** O sinal é convertido em imagem em escala de cinza.
2. **Conversão de imagem em matriz:** A imagem é convertida para uma matriz de co-ocorrência.
3. **Extração de atributos:** São aplicados calculos estatísticos na matriz de co-ocorrência que são utilizados como atributos para algoritmos de classificação.

Nesse contexto, este trabalho descreve uma abordagem para utilização dos cálculos estatísticos do GLCM em sinais no tempo, sem que haja a necessidade de transformação do sinal de entrada em imagem. A abordagem proposta realiza a geração de uma matriz de co-ocorrência diretamente do sinal, apresentando um ganho de recursos como memória e tempo de CPU, sem perda significativa de generalização do algoritmo.

1.1 Motivação

Este trabalho propõe um método para embarcar um extrator de características de sinais no tempo. É utilizada análises de textura baseada em métricas do GLCM, sem a necessidade de consumir recursos para armazenamento da imagem.

Aplicações embarcadas têm sido incorporadas na automação industrial, com o objetivo de melhorar a qualidade e segurança dos processos. Tais sistemas envolvem classificadores de padrões para funções específicas, que muitas vezes apresentam elevado custo de memória e tempo de processamento.

Uma forma de uso de algoritmos de classificação de padrões usando sinais como entrada que vem sendo explorada recentemente, é a utilização de uma transformação do sinal em imagem, como mostrado nos trabalhos Abdeldayem e Bourlai (2018), Sousa et al. (2019), Islam, Uddin e Kim (2018), Jang, Kang e Kim (2014), Uddin, Van e Kim (2015), Azad, Khaled e Pavel (2019) que utilizam diferentes técnicas para este fim. Com a imagem gerada é realizada uma análise na textura da imagem, visando a extração de características usando GLCM. Embora apresente bons resultados em taxas de acerto, esta transformação do sinal em uma imagem pode causar um gasto de recursos para armazenamento da imagem gerada.

Este trabalho faz um estudo da viabilidade de embarcar os métodos aqui demonstrados, propondo uma nova abordagem que leva em consideração as restrições de memória e tempo, comparando com métodos conhecidos da literatura de transformação de sinais para imagens ou outros domínios.

1.2 Descrição do problema

Abordagens para classificação de padrões usando sinais como entrada vem sendo exploradas na comunidade científica. Sendo que algumas destas abordagens utilizam transformação do sinal em imagem ou transferência de domínios do sinal. Na geração de imagens é realizada uma extração de características baseada em texturas com extratores como GLCM e LBP. Na transferência de domínio, são realizadas transformadas como SFFT, FFT ou Wavelet para aplicação de estatísticas que geram atributos para uma classificação.

Embora apresente bons resultados em taxas de acerto, estas transformações de sinais em imagens podem causar gastos de recursos para armazenamento da imagem gerada, assim como transformações de domínio necessitam de cálculos que podem consumir tempo de CPU.

Este trabalho tem como objetivo propor um extrator de características para sinais no tempo, de forma que não haja a transformação do sinal de entrada, tanto em imagens como em outros domínios. Apresentando ganhos em recursos como memória e tempo de CPU sem perda significativa de generalização do algoritmo.

1.3 Objetivos Geral e Específicos

O objetivo geral deste trabalho é propor uma técnica de extração de características usando métricas de análise de textura para classificação de sinais elétricos.

Os objetivos específicos são:

- Propor um método de extração de características baseadas em textura para sinais elétricos.
- Avaliar o desempenho da técnica proposta quanto a seu acerto levando em consideração os recursos reduzidos.
- Avaliar o desempenho da técnica proposta quanto a sua tolerancia a perda de informação reduzindo o tamanho da entrada.
- Avaliar os resultados obtidos em uma plataforma embarcada.

1.4 Produção científica

Durante este projeto de mestrado, os seguintes trabalhos científicos foram aceitos e publicados, a saber:

- **L. da Silva, E. Silva Jr, and I. Costa. "Um novo extrator de características para aplicações embarcadas de detecção de falhas em motores elétricos", in *Anais Estendidos do X Simpósio Brasileiro de Enge-***

nharia de Sistemas Computacionais, Evento Online, 2020, pp. 192-197, doi: https://doi.org/10.5753/sbesc_estendido.2020.13112.

1.5 Estrutura da Dissertação

O texto está organizado da seguinte forma. No capítulo 2 é apresentado uma explicação sobre as técnicas envolvidas no trabalho, assim como alguns conceitos importantes para entendimento da metodologia a ser implementada.

No capítulo 3 são apresentados os procedimentos realizados para comparar e avaliar as técnicas existentes na literatura. Neste capítulo também são analisadas os resultados dos procedimentos com o objetivo de encontrar uma combinação de parâmetros e técnicas que podem ser utilizados na plataforma embarcada.

Por fim o capítulo 4 apresenta os resultados obtidos tanto em máquinas de propósito geral como na plataforma embarcada, suas conclusões e trabalhos futuros para dar continuidade ao estudo.

2 Fundamentação Teórica

2.1 Detecção de falhas em motores elétricos

Existem dois tipos de motores de indução polifásica: rotor enrolado e gaiola de esquilo. O segundo tipo é o mais comum e será o abordado neste trabalho. Assim, apenas este tipo será discutido. A principal razão de sua popularidade é a simplicidade e robustez do design (FITZGERALD et al., 2003). A corrente do rotor interno é dependente da tensão induzida e de sua impedância (AUTOMATION, 1996). A imagem de um motor de indução em gaiola de esquilo é apresentada na Figura 1.




Figura 1 – Motor trifásico de gaiola de esquilo. Adaptado de Automation (1996)

O circuito do estator é composto por três bobinas, que devem ser alimentadas por tensões trifásicas defasadas por ângulos elétricos de 120 graus entre si. A corrente alternada é fornecida diretamente ao estator, magnetizando-o e gerando um campo rotativo que gira com velocidade síncrona n_s (AUTOMATION, 1996), determinada pelo número de pólos do estator e a frequência aplicada f_e (FITZGERALD et al., 2003).

A interação entre o fluxo magnético gerado pelo enrolamento do estator e as barras do rotor induz uma corrente no rotor, semelhante à operação de um transformador (FITZGERALD et al., 2003). O rotor tenta girar na mesma velocidade do campo rotativo, mas nunca o atinge. Por isso é denominado motor assíncrono. A diferença entre a velocidade síncrona e a velocidade do rotor é chamada de *slip* s . É positivo quando a máquina está funcionando como motor e negativo, como gerador.

A perda de isolamento no enrolamento do estator é uma das falhas mais comuns em motores de indução. É responsável por cerca de 21% a 40% de todas as falhas em máquinas elétricas, dependendo do tipo e tamanho. Falhas no enrolamento geralmente estão

associadas ao envelhecimento lento e contínuo da isolação (RIERA-GUASP; ANTONINO-DAVIU; CAPOLINO, 2014). Quando o isolamento é envelhecido, as falhas locais podem iniciar devido a pequenos estresses, como superaquecimento, vibração ou tensões transientes (BONNETT; SOUKUP, 1992). Esse estresse provoca um curto-circuito entre espiras e a corrente irá circular pelas espiras em curto, gerando calor e aumentando o dano ao isolamento.

A evolução da falha pode levar a curto-circuito fase-terra e fase-fase, com consequências castastóficas (RIERA-GUASP; ANTONINO-DAVIU; CAPOLINO, 2014). A evolução desta falha pode ser muito rápida, apenas alguns segundos, o que requer monitoramento online e constante (CABANAS et al., 2013).

Para ser de interesse prático, os métodos de detecção de curto-circuito entre espiras devem ser capazes de detectar a falta muito rapidamente, e em estágios incipientes, quando a corrente de falta ainda é baixa e antes que sistemas de proteção convencionais como relés de sobrecorrente e diferenciais atuem (RIERA-GUASP; ANTONINO-DAVIU; CAPOLINO, 2014). Outro aspecto que aumenta a importância da detecção de curto-circuito no enrolamento do estator é a predominância de conversores de frequência para acionamento dos motores de indução. Estudos mostram que eles aumentam o estresse no enrolamento por causa dos transientes de tensão (BONNETT, 1996).

Considerando os efeitos dos conversores de tensão nos isoladores de máquinas elétricas, foi criada uma norma internacional, a IEC 60034-18-41. Ela descreve testes de qualificação e controle de qualidade para a aprovação de sistemas de isolamento elétrico para uso em máquinas elétricas rotativas classificadas a $700 V_{rms}$ ou menos, acionados por conversores de tensão. A existência de tal padrão enfatiza o impacto negativo dos conversores de tensão no isolamento do motor.

Normalmente é usada a análise de frequência para diagnóstico baseado em dados. Esta análise não requer conhecimento dos parâmetros e modelos da máquina. Ele combina processamento de sinal e técnicas de agrupamento. Os dados são adquiridos da máquina e processados para extrair atributos que podem ser usados para classificá-los. Nesse tipo de diagnóstico, técnicas de IA e de reconhecimento de padrões são amplamente utilizadas (BELLINI et al., 2008).

Estudos realizados por Tavner (2008) e Thomson (1984) provaram que as ondas de fluxo rotativo em motores defeituosos induzem componentes de frequência correspondentes na corrente do estator. No entanto, um problema raramente abordado é que o uso de FFT convencionais para detectar componentes de falha, implica em resolução de alta frequência, o que requer longos períodos de amostragem, que podem ser mais longos do que o tempo para a falha incipiente se tornar catastrófica (RIERA-GUASP; ANTONINO-DAVIU; CAPOLINO, 2014).

Uma outra forma de uso de algoritmos de aprendizagem de máquina usando sinais como entrada que vem sendo explorada recentemente, é a utilização de uma transformação do sinal em imagem, como mostrado nos trabalhos Abdeldayem e Bourlai (2018), Sousa et al. (2019), Islam, Uddin e Kim (2018), Jang, Kang e Kim (2014), Uddin, Van e Kim (2015), Azad, Khaled e Pavel (2019) que utilizam diferentes técnicas para este fim. Com a imagem gerada é realizada uma análise na textura da imagem, visando a extração de características usando representações em escala de cinza. Embora apresente bons resultados em taxas de acerto, esta transformação do sinal em uma imagem pode causar um gasto de recursos para armazenamento da imagem gerada.

2.2 Técnicas de geração de atributos através de mudança de domínio do sinal

2.2.1 Transformada Wavelet combinada com estatísticas de alta ordem

A análise Wavelet é uma técnica de transformação para o domínio do tempo-frequência. Da mesma forma que a transformada de Fourier, ela decompõe os sinais em formas de onda oscilatórias, revelando as propriedades do sinal. No entanto, a diferença entre eles é que a transformada de Fourier representa qualquer função de energia infinita como uma soma de ondas senoidais, com operadores lineares invariantes no tempo, para sinais uniformemente regulares. Enquanto isso, uma base de wavelet define uma representação esparsa de sinais regulares por partes, que podem incluir transientes e singularidades (MALLAT, 1999).

Em investigações anteriores, todos os componentes de frequência presentes no sinal influenciaram os valores da característica e, conseqüentemente, os resultados da classificação. Com a Transformada Discreta de Wavelet é possível analisar um sinal em diferentes faixas de frequência com diferentes resoluções, fixando uma função chamada *Mother Wavet* e decompondo o sinal em versões deslocadas e dimensionadas desses sinais.

A análise de multiresolução usando a transformada wavelet é descrita por Mallat (1989). Consiste em uma representação multinível de um sinal, representado por uma soma de aproximações e detalhes. Em cada nível subsequente, as aproximações são divididas em aproximações e detalhes sucessivos. Portanto, é possível calcular as características estatísticas para cada sub-banda de frequência. Ele aumenta a dimensionalidade do espaço de amostragem e permite a remoção de alguns componentes da faixa de frequência que podem estar afetando negativamente a classificação.

No trabalho de Cunha (2019), após a decomposição de multiresolução do sinal usando a transformada discreta de Wavelet, as medidas estatísticas de assimetria, curtose, desvio absoluto da média e desvio absoluto da mediana foram aplicadas aos coeficientes

de aproximação e detalhe de cada nível de decomposição. Além disso, outro recurso foi adicionado, a *relative wavelet energy* (RWE), que representa a porcentagem de energia contida naquela banda de frequência em relação ao sinal original (GARG et al., 2011).

2.3 Técnicas de geração de imagens através de sinais

Nessa seção serão apresentadas as técnicas de geração de atributos (extração de características) que geram imagens como representações intermediárias de um sinal, para então, gerar os atributos baseados em algum extrator de características, como por exemplo o GLCM (HARALICK; SHANMUGAM; DINSTEIN, 1973; SOH; TSATSOULIS, 1999; WANG et al., 2010), que é comumente usado na literatura para este fim.

2.3.1 Geração de imagem usando STFT.

Esta técnica consiste na transformação do sinal para o espectro da frequência usando STFT (Short-time Fourier transform) gerando uma imagem 2D do sinal 1D pelos eixos de tempo x frequência.

Essa transformação obtém os coeficientes de Fourier para cada segmento do sinal. Isso é controlado por uma janela deslizante que se move através do sinal de tempo com uma porcentagem de sobreposição entre janelas sucessivas (ABDELDAYEM; BOURLAI, 2018). Assim, um espectro variável no tempo pode ser alcançado. A fórmula matemática para obter o STFT é mostrada na expressão 2.1, onde $x[m]$ é o sinal e $w[n]$ é a janela deslizante. Isto produzirá uma imagem, na qual um dos eixos representa o tempo e o outro as frequências. No final é obtida uma imagem 2D convertida em escala de cinza, podendo ser utilizada normalmente em qualquer extrator de características de imagens.

$$STFT\{x[m]\}(n, w) = \sum_{m=-\infty}^{\infty} x[m]w[n-m]e^{jwn} \quad (2.1)$$

2.3.2 Geração de imagem chão-teto.

Esta técnica consiste na geração de uma imagem 2D em escala de cinza através da conversão de um sinal 1D, podendo servir de entrada para um GLCM. Como mostrado nos trabalhos de Islam, Uddin e Kim (2018), Jang, Kang e Kim (2014), Uddin, Van e Kim (2015), Azad, Khaled e Pavel (2019) que utilizam essa abordagem para conversão de sinal em imagem.

Um sinal S com N pontos no tempo permite gerar uma imagem quadrada de dimensões $M \times M$. Para encontrar a dimensão da imagem (M), temos que $M = \lceil \sqrt{N} \rceil$,

onde N é o número total de amostras do sinal.

$$p(j, k) = S(i) | j = \lfloor \frac{i}{M} \rfloor, k = \lceil \frac{i}{M} \rceil \quad (2.2)$$

Dado o i -ésimo valor do sinal, $S(i)$, existe um *pixel* p na imagem resultante que pode ser encontrado na coordenada (j, k) . O valor da coordenada (j, k) pode ser encontrado através do cálculo de chão de $\frac{i}{M}$ e teto de $\frac{i}{M}$, respectivamente, com isso temos a expressão mostrada na equação 2.2.




Figura 2 – Exemplo de geração de uma matriz de co-ocorrência com o método de chão e teto.

Desta forma, para cada valor do sinal S existe um pixel na imagem que representa este valor, ver Figura 2. Com isso a imagem gerada é equivalente a uma imagem em escala de cinza, servindo então como entrada para qualquer extrator de características de imagens. A Figura 3 mostra dois exemplos de imagens geradas para problemas que envolvem falhas em motores de indução.




Figura 3 – Representação das imagens de uma classe normal e uma classe de falha.

Neste trabalho, esta técnica será utilizada em conjunto com o extrator de características GLCM.

2.3.3 Geração de imagem através do gráfico do sinal no tempo.

Esta técnica utiliza como base o desenho do sinal como capturado na etapa de aquisição (SOUSA et al., 2019). O sinal é exposto através de um gráfico amplitude por tempo, com o auxílio de alguma biblioteca gráfica, sendo gerada uma imagem a partir desse gráfico. Esta imagem é utilizada como entrada para métodos de extração de características de imagens.

Esta técnica é comumente a primeira escolha em representações de sinais em imagens por ser de simples implementação.

2.4 Matriz de co-ocorrência de níveis de cinza - GLCM

A Matriz de Coocorrência de Níveis de Cinza (GLCM) é uma técnica que têm sido utilizada em muitos trabalhos para medir a textura de imagens desde que foi proposta por Haralick, Shanmugam e Dinstein (1973). Na GLCM, cada entrada (i, j) na Matriz de Coocorrência (MC) corresponde ao número de ocorrências do par de níveis de cinza i e j que estão a uma distância D e direção θ na imagem original. A MC é definida na equação 2.3, onde R é uma constante para padronização que representa o total de vizinhanças encontradas (i, j) (HARALICK; SHANMUGAM; DINSTEIN, 1973).

$$p(i, j, D, \theta) = P(i, j, D, \theta) / R \quad (2.3)$$

A Figura 4a apresenta as características da GLCM. A orientação θ pode ser representada em quatro direções: horizontal, diagonal, vertical e anti-diagonal (0° , 45° , 90° e 135°).




Figura 4 – Representação da GLCM

Uma MC descreve a quantidade de combinações de níveis de cinza em uma imagem com uma determinada direção e distância entre os pixels vizinhos. O número de linhas e colunas dessa matriz é igual ao número de níveis de cinza, N_g , na imagem. Neste trabalho inicialmente foi adotado $N_g = 256$. A Figura 4b mostra um exemplo para o cálculo dos valores da MC de uma imagem I 4×5 pixels com $\theta = 0^\circ$. O elemento $(1, 1)$ na MC contém

o valor 1 porque só existe uma instância na imagem onde dois pixels, horizontalmente adjacentes, têm os valores 1 e 1. O elemento (1, 2) contém o valor 2 porque existem duas instâncias na imagem onde dois pixels, horizontalmente adjacentes, têm os valores 1 e 2.

O trabalhos de Haralick, Shanmugam e Dinstein (1973), Soh e Tsatsoulis (1999), Wang et al. (2010) juntos disponibilizam um conjunto de 24 medidas estatísticas a partir de uma MC que podem ser usadas para representar características presentes em texturas, extraídas de uma única imagem.

2.5 Signal Level Co-occurrence Matrix (SLCM)

As técnicas de reconhecimento de padrões em sinais tipicamente utilizam um modelo onde o sinal passa por algum tipo de extrator de características, antes de ser entregue ao algoritmo classificador. Um extrator de características muito utilizado na literatura é o GLCM(HARALICK; SHANMUGAM; DINSTEIN, 1973) onde, dada uma imagem 2D, é gerada uma matriz de co-ocorrência e desta matriz são extraídos atributos estatísticos que evidenciam a mudança de textura na imagem.

A técnica aqui proposta visa à extração de características de sinais no domínio do tempo, gerando uma matriz de co-ocorrência. Para isso, o sinal no tempo passa pelas seguintes etapas:

1. **Digitalização:** Conversão analógico para digital, geralmente entregue em 12 bits pelo ADC.
2. **Redução:** Consiste em diminuir a quantidade de bits usada para representar os valores. Os números digitalizados em 12 bits são convertidos conforme alguma potência de 2, levando a uma redução no tamanho da matriz de co-ocorrência.
3. **Criação da Matriz de co-ocorrência:** A estrutura final dessa matriz é a mesma do GLCM(HARALICK; SHANMUGAM; DINSTEIN, 1973), mas o método de geração é diferente, já que a entrada será um vetor de 1D. Na matriz de co-ocorrência, uma dada coordenada (x,y) contém o número de vezes que aquela sequência (x - y) ocorre no sinal. Na expressão 2.4, um sinal S , dá origem a uma matriz de co-ocorrência MC , que é inicializada com zeros. Em um determinado passo t , se incrementa o valor do elemento de MC localizado na linha de valor $S(t)$ e coluna $S(t + 1)$. Para um exemplo de um sinal discretizado em 256 números inteiros, ou 8 bits, a matriz terá 256 x 256 elementos. A figura 5 mostra um exemplo de geração de uma matriz de co-ocorrência de 2 bits, onde os valores variam de 0 a 3.
4. **Cálculo de estatísticas:** Um conjunto de estatísticas para se aplicar sobre a matriz de co-ocorrência é apresentado e descrito em Haralick, Shanmugam e Dinstein (1973).

Outras expressões foram adicionadas em Soh e Tsatsoulis (1999), Wang et al. (2010) chegando a um total de 24. Esses valores calculados são usados como características, entregues ao algoritmo de classificação.

$$MC[S(t), S(t+1)] = MC[S(t), S(t+1)] + 1 \quad (2.4)$$

O modelo de aplicação embarcada proposto está apresentado na figura 6. O motor elétrico sob observação foi instrumentado com um sensor de fluxo magnético. O sinal obtido é digitalizado por um microcontrolador, encarregado de executar os algoritmos de extração de características (SLCM) e de classificação.

	0	1	2	3
0	0	2	1	0
1	1	0	0	1
2	0	1	0	0
3	1	0	0	0

Figura 5 – Exemplo de geração de uma matriz de co-ocorrência de 2 bits.




Figura 6 – Fluxo de informação para detecção de falhas.

2.6 Técnicas de seleção de atributos

2.6.1 Seleção de atributos baseado em correlação (CFS)

O CFS, proposto por Hall (1998), é um algoritmo que avalia o valor de um subconjunto de atributos considerando a capacidade preditiva individual de cada atributo juntamente com o grau de redundância entre os mesmos. Neste trabalho o CFS foi utilizado para selecionar quais os atributos que mais contribuem na predição correta do classificador com a expectativa de reduzir o vetor de características usado no processo de aprendizagem do classificador. Vale ressaltar que o conjunto resultante contendo os atributos selecionados pelo CFS é inerente ao problema aplicado. Ou seja, o CFS pode selecionar atributos diferentes em aplicações distintas.

A Figura 7 exemplifica o funcionamento do algoritmo CFS. A partir de uma matriz de dados, composta pelos vetores de características associados à classe que cada imagem pertence, o CFS retorna um vetor contendo um subconjunto de atributos que apresenta

um bom grau de distinção entre as classes. O tamanho do vetor resultante, dependendo da correlação dos dados, pode ser menor ou igual ao tamanho do vetor de características.




Figura 7 – Ilustração da utilização do algoritmo CFS. Fonte: SAMPAIO (2017)

2.7 Máquinas de Vetores suporte

A Máquina de Vetores Suporte (Support Vector Machine - SVM) é cada vez mais utilizada na solução de diversos tipos de problemas, pois têm apresentado resultados equivalentes a outros algoritmos de Aprendizagem de Máquinas, como as Redes Neurais Artificiais (RNAs) (LORENA; CARVALHO, 2007). A SVM é uma técnica embasada na Teoria de Aprendizado Estatístico (TAE), que consiste em estabelecer condições matemáticas que permitem escolher um classificador, com bom desempenho, para o conjunto de dados disponíveis para treinamento e teste (VAPNIK, 1995).

O processo de indução de classificadores usado em SVM é supervisionado. Desta forma, o processo de aprendizagem é realizado com base nos diversos pares de entrada e saída pertencentes à base de dados de exemplos (NETO, 2011).

A SVM, busca a construção de um hiperplano como superfície de decisão, de tal forma que a separação entre os exemplos seja máxima. Isso com padrões linearmente separáveis ¹.

Para os padrões não-linearmente separáveis, busca-se uma função de mapeamento (*Kernel*) apropriada para tornar o conjunto mapeado linearmente separável. Desta forma, pode-se trabalhar indiretamente em espaço de elevada dimensão, desde que as computações sejam realizadas em um outro espaço, denominado Espaço *Kernel* (*Kernel Space*) (NETO, 2011). Com isso, a SVM não-linear realiza uma mudança de dimensionalidade, caindo então em um problema de classificação linear, com a opção de fazer uso do hiperplano ótimo ² (GONÇALVES, 2015).

¹ Os padrões devem estar suficientemente separados entre si para assegurar que a superfície de decisão consista de um hiperplano (KUBAT, 1999)

² Hiperplano de separação com maior margem. Entende-se como margem, a menor distância entre os

As SVM possuem diferentes *kernels* que caracterizam seu modo de reconhecimento dos padrões. De acordo com NETO (2011) os mais comumente utilizados são o linear, polinomial e gaussiano (RBF). Assim, seus respectivos parâmetros provocam alterações nos resultados fornecidos por uma SVM.

Sendo assim, algumas escolhas devem ser feitas para obtenção de uma SVM, como a função Kernel, os parâmetros da função, além da definição do algoritmo para determinação do hiperplano ótimo.

A base teórica das SVM é bem estabelecida dentro da Matemática e Estatística. Um estudo mais aprofundado pode ser observado em Smola et al. (2000), Friedman et al. (2001), NETO (2011).

2.8 Projeto de Sistema Embarcado

Um Sistema Embarcado é qualquer dispositivo que inclui um computador programável, mas não se destina a ser um computador de propósito geral. Os sistemas computacionais embarcados estão presentes em praticamente todas as atividades humanas (WOLF, 2012). Para Marwedel (2006) Sistemas Embarcados são sistemas de processamento de informações que são incorporados em um produto maior e que normalmente são transparentes para o usuário. Exemplos de sistemas embarcados incluem sistemas de processamento de informação em equipamentos de telecomunicações, sistemas de transporte, equipamentos de fabricação e eletrônicos de consumo.

Segundo Wolf (2012) os projetistas devem ser capazes de identificar onde os microprocessadores podem ser usados, projetar uma plataforma de *hardware* com dispositivos de entrada e saída que possa suportar as tarefas requeridas, e implementar um *software* que execute os processos requeridos.

Dois dos principais desafios para um projeto de sistemas embarcados são saber quanto de *hardware* será necessário e como minimizar o consumo de energia. No *hardware* pode-se selecionar o tipo de microprocessador usado, a quantidade de memória, os dispositivos periféricos, entre outros (WOLF, 2012).

Para a aplicação deste trabalho, busca-se o menor *hardware* combinado com um software que resolva todo o processo de classificação. Neste caso, será observado no fluxo dos dados (segmentação, extração de atributos e classificação) onde está o maior consumo de recursos (tempo de computação e memória) e como otimizá-los.

exemplos do conjunto de treinamento e o hiperplano utilizado para separação destas classes (LORENA; CARVALHO, 2007)

3 Procedimentos e Resultados

Este capítulo apresenta os procedimentos utilizados para encontrar uma melhor combinação de parâmetros a fim de embarcar o processo de detecção de falhas em motores elétricos em uma plataforma embarcada, com quantidade limitada de recursos de capacidade de processamento e memória.

O capítulo está dividido em cinco seções. A seção 3.1 apresenta uma breve descrição do conjunto de dados a ser utilizado nos experimentos, assim como sua forma de captura e tipos de falhas contemplados.

A seção 3.2 apresenta a metodologia utilizada para medir o acerto de diferentes técnicas para extração de atributos em um mesmo dataset, assim como uma comparação com a técnica proposta SLCM, as técnicas são submetidas a um mesmo processo e seus acertos comparados, com isto, são definidas as técnicas que serão utilizadas e os atributos em cada técnica.

A seção 3.3 descreve técnicas que apresentam um ganho na redução do número de pontos, necessários para a detecção de eventual falha no motor, com o número de pontos reduzido é esperado um menor consumo de memória e recursos de CPU para a plataforma embarcada final.

A seção 3.4, aplica as estratégias de redução de número de pontos estudadas na seção 3.3, nas técnicas encontradas na seção 3.2 para medir através da taxa de acerto, qual a tolerância de cada técnica a perda de informação, assim como apresentar se há possibilidade de redução de consumo para a plataforma embarcada.

Por fim, a seção 3.5, aplica os resultados obtidos nas seções anteriores e os avalia quanto ao consumo de memória e tempo de CPU em uma plataforma embarcada com recursos limitados.

3.1 Conjunto de dados

Esta seção apresenta o conjunto de dados usado para avaliar o extrator de características. Trata-se de uma aplicação de detecção de falhas em motores de indução trifásicos, que utiliza sinais de fluxo magnético extraídos em diferentes condições de operação, divididas em 7 classes, sendo elas:

1. **Sem falhas (NORMAL):** Representa o estado o equipamento não apresenta falhas.
2. **Alta Impedância (HI):** Representa o estágio inicial da falha, no qual o isolador elétrico está começando a se degradar e um caminho de corrente paralelo aparece;

3. **Baixa impedância (LI):** Representa um curto-circuito completo. A corrente flui no novo caminho e uma tensão é induzida na bobina em curto.

Para todas as falhas simuladas diferentes níveis de intensidade também são emulados, dependendo da quantidade de curvas em curto. Três níveis são considerados: 1,41%, 4,81% e 9,26% do enrolamento do estator. Combinando o tipo e a intensidade dos defeitos existem, respectivamente, HI-1, HI-2 e HI-3, para alta impedância, e LI-1, LI-2 e LI-3, para falhas de baixa impedância.

As classes foram dispostas por ordem de severidade, onde a classe 1 (NORMAL) representa sem falha e classe 7 (LI-3) a falha mais grave.

Cada classe é composta por cerca de 350 amostras e cada amostra possui um sinal com 100.000 pontos (CUNHA; SILVA JR.; MEDEIROS, 2021). Os mesmos sinais de fluxo magnético são usados pra gerar os diversos experimentos. As seções seguintes mostram como cada um deles é gerado.

3.2 Avaliação dos extratores de características

Para todas as técnicas mostradas nas seções a seguir, o extrator de características está baseado na matriz de coocorrência de Haralick, Shanmugam e Dinstein (1973) e no conjunto de 24 atributos estatísticos (SOH; TSATSOULIS, 1999; WANG et al., 2010), após extraídos, os valores passam por um processo de padronização de cada amostra, que consiste em subtrair o valor da média e dividir pelo valor do desvio padrão. Todos os experimentos utilizam como classificador um SVM(CORTES; VAPNIK, 1995) com kernel RBF. O SVM será utilizado por ser um algoritmo estado da arte, com bons resultados em aplicações similares como mostrado nos trabalhos de Cunha (2019), Sampaio et al. (2018) podendo ser utilizado em plataformas embarcadas.

Um estudo sobre a influencia do classificador utilizado poderá ser realizado para reduzir os custos da classificação, caso necessário. Este trabalho tem como foco demonstrar a eficácia do extrator de características, com isto o estudo terá como finalidade a fase de extração de características, realizando experimentos que utilizam somente SVM como classificador.

3.2.1 Processo de extração de metricas de avaliação

Para avaliar as técnicas e extratores presentes neste trabalho, uma metodologia de extração de metricas para comparações foi estipulada. A métrica a ser utilizada será a taxa de acerto (Acurácia) para avaliar a forma multiclasse (normal e 6 tipos de falhas) e binária (normal vs falhas) dos algoritmos.

Para avaliação das taxas de acerto, o conjunto de dados foi dividido tomando 80% das amostras de cada classe para treinamento e 20% para testes. Para ajuste dos parâmetros do SVM é usada uma busca em grade com validação cruzada ($k = 2$).

Após a aplicação da validação cruzada e busca em grade, um modelo é gerado e a seguir validado usando o conjunto de testes com os parametros encontrados, sendo este processo corresponde a uma rodada do experimento. Posteriormente, o conjunto é aleatoriamente dividido em treino e teste para uma nova rodada. Ao todo foram executadas 50 rodadas em cada condição ou técnica investigada e os resultados refletem a média dessas 50 rodadas.

Para gerar o resultado de taxa de acerto binária, não serão executadas novamente as rodadas, somente a redução das matrizes confusao para duas classes foi realizado.

3.2.2 Experimento usando a técnica SLCM

Neste experimento é aplicada a técnica de SLCM para geração da matriz de coocorrência do sinal. Esta matriz é utilizada para o processo de geração das características, sem ser necessária a conversão do sinal em uma imagem 2D.

	NORMAL	HI-1	HI-2	HI-3	LI-1	LI-2	LI-3
NORMAL	96,5	1,9	1,7	0,8	0,2	0,0	0,0
HI-1	1,3	68,3	0,5	0,1	39,3	0,3	0,0
HI-2	1,6	0,1	96,6	0,4	0,0	0,8	0,0
HI-3	0,3	0,1	0,4	98,1	0,7	0,0	0,0
LI-1	0,1	29,4	0,6	0,4	59,7	0,0	0,0
LI-2	0,0	0,1	0,1	0,1	0,0	98,7	0,4
LI-3	0,1	0,0	0,0	0,0	0,0	0,5	99,6

Tabela 1 – Matriz de confusão média ao usar a técnica SLCM e os 24 atributos.

A Tabela 1 mostra a matriz de confusão dos resultados obtidos neste experimento usando todos os 24 atributos disponíveis. Em Silva Jr et al. (2020) é apresentado um conjunto de 10 atributos escolhidos com base na ocupação de memória e tempo de CPU, com resultados de acurácia similares ao uso de todos os 24 atributos e uma redução significativa nos recursos utilizados. Aplicando estes atributos a este problema a matriz confusão resultante pode ser vista na tabela 2.

O resultados de acurácia média, assim como os resultados da classe normal contra falhas (acurácia binária) foram respectivamente 87,91% e 98,86% para 24 atributos e 92,33% e 99,07% para os 10 atributos.

	NORMAL	HI-1	HI-2	HI-3	LI-1	LI-2	LI-3
NORMAL	97,3	1,5	1,4	0,8	0,2	0,0	0,0
HI-1	0,8	78,4	0,5	0,1	20,0	0,3	0,0
HI-2	1,2	0,1	96,4	0,5	0,1	1,1	0,3
HI-3	0,3	0,1	0,6	98,4	0,5	0,1	0,0
LI-1	0,1	19,9	0,3	0,2	79,2	0,0	0,0
LI-2	0,2	0,1	0,8	0,1	0,0	98,4	0,4
LI-3	0,0	0,0	0,0	0,0	0,0	0,4	99,3

Tabela 2 – Matriz de confusão ao média ao usar a técnica SLCM e 10 atributos.

3.2.3 Experimento usando a técnica de chão-teto

Neste experimento é aplicada a técnica de chão-teto para geração de uma imagem 2D do sinal de fluxo. Esta imagem passa pelo processo completo do extrator de características GLCM. Para fins de comparação com outras técnicas, os parâmetros para GLCM são: Distancia $D=1$ e $\theta = 0^\circ$. Os 24 atributos após extraídos passam pelo mesmo processo de padronização aplicado na técnica SLCM.

	NORMAL	HI-1	HI-2	HI-3	LI-1	LI-2	LI-3
NORMAL	97,6	1,8	1,1	1,6	0,3	0,0	0,0
HI-1	0,8	66,9	0,4	0,1	39,3	0,0	0,0
HI-2	1,0	0,0	97,3	0,5	0,0	0,8	0,0
HI-3	0,4	0,1	0,5	97,5	0,2	0,1	0,0
LI-1	0,4	31,0	0,4	0,2	59,97	0,0	0,0
LI-2	0,0	0,0	0,1	0,1	0,0	98,8	0,3
LI-3	0,0	0,0	0,2	0,1	0,2	0,4	99,7

Tabela 3 – Matriz de confusão média ao usar a técnica de chão-teto e 24 atributos.

A Tabela 3 mostra a matriz de confusão dos resultados obtidos neste experimento usando todos os 24 atributos disponíveis. Já a Tabela 4 mostra os resultados obtidos usando os atributos sugeridos em (Silva Jr et al., 2020).

	NORMAL	HI-1	HI-2	HI-3	LI-1	LI-2	LI-3
NORMAL	95,9	0,5	2,6	0,7	0,1	0,3	0,0
HI-1	1,4	78,3	0,9	0,0	19,4	0,0	0,0
HI-2	3,6	0,7	92,5	1,9	0,6	0,7	0,0
HI-3	1,2	0,1	1,2	97,5	0,0	0,1	0,0
LI-1	0,7	23,3	0,7	0,1	75,1	0,0	0,0
LI-2	0,1	0,1	1,1	0,2	0,0	98,6	0,0
LI-3	0,0	0,0	0,5	0,0	0,0	0,3	99,2

Tabela 4 – Matriz de confusão média ao usar a técnica de chão-teto (seção 2.3.2) e 10 atributos.

O resultados de acurácia média e acurácia binária foram de 88,05% e 98,93% para 24 atributos e 92,93% e 99,04% para os 10 atributos respectivamente. Ambas as abordagens

apresentam um resultado interessante, que a falha mais severa (LI-3) é pouco confundida com a classe NORMAL, que é uma característica que deve ser observada no problema.

3.2.4 Experimento usando a técnica de gráfico do sinal no tempo

Neste experimento é aplicada a técnica de geração de imagem através do gráfico do sinal no tempo como explicado na seção 2.3.3. A imagem gerada por sua vez, passa pelo processo de extração de características do GLCM. Para fins de comparação os parâmetros do GLCM são os mesmos das técnicas anteriores, Distancia $D=1$ e $\theta = 0^\circ$. Os atributos após extração passam pelo mesmo processo de padronização aplicado na técnica SLCM.

	NORMAL	HI-1	HI-2	HI-3	LI-1	LI-2	LI-3
NORMAL	51,0	7,0	11,2	8,9	6,3	1,3	0,0
HI-1	10,4	37,3	12,4	16,0	31,6	0,8	0,0
HI-2	16,0	8,9	55,3	5,2	10,8	3,1	0,0
HI-3	12,2	18,4	6,6	52,7	16,9	1,1	0,0
LI-1	8,5	27,6	11,6	15,8	33,4	1,0	0,0
LI-2	2,0	0,8	3,0	1,3	0,9	92,0	1,0
LI-3	0,0	0,0	0,0	0,1	0,0	0,8	99,0

Tabela 5 – Matriz de confusão média ao usar a técnica de gráfico do sinal no tempo e 24 atributos.

A tabela 5 mostra a matriz de confusão dos resultados obtidos neste experimento usando todos os 24 atributos disponíveis. Já a Tabela 6 mostra os resultados obtidos usando os atributos sugeridos em Silva Jr et al. (2020).

	NORMAL	HI-1	HI-2	HI-3	LI-1	LI-2	LI-3
NORMAL	59,0	12,4	16,4	18,0	10,5	2,0	0,0
HI-1	6,7	35,9	12,5	16,2	32,9	0,4	0,0
HI-2	12,9	7,4	53,3	3,1	11,3	1,7	0,9
HI-3	12,3	21,6	6,3	50,2	19,5	2,0	0,0
LI-1	5,8	21,9	7,8	11,0	25,2	0,3	0,0
LI-2	2,7	0,6	2,8	1,5	0,5	82,5	7,4
LI-3	0,5	0,1	0,8	0,0	0,0	11,2	91,6

Tabela 6 – Matriz de confusão ao usar a técnica de gráfico do sinal no tempo e 10 atributos GLCM.

O resultados de acurácia média e acurácia binária foram de 59,45% e 88,18% para 24 atributos e 56,35% e 85,73% para os 10 atributos respectivamente.

3.2.5 Análise de resultados

Os resultados de acurácia multiclasse e acurácia binária para cada técnica foram resumidos na tabela 7. Analisando os resultados da técnica SLCM, é apresentado um

aumento pouco significativo de acerto, quando consideradas as classes Normal vs Falhas (seis classes restantes), assim como um aumento na acurácia multiclasse, junto com uma redução significativa de custo computacional devido à retirada de atributos (Silva Jr et al., 2020).

	24 atributos		10 atributos	
	Acc multiclasse	Acc binária	Acc multiclasse	Acc binária
SLCM	87,9±4,91	98,9±1,38	92,3±1,57	99,1±0,05
Chão-teto	88,0±2,86	98,9±0,05	92,9±1,42	99,0±0,44
Gráfico no tempo	59,4±0,39	88,2±0,14	56,3±0,19	85,7±0,15

Tabela 7 – Resumo dos resultados de acurácia das técnicas estudadas.

De forma similar, analisando os resultados da técnica Chão-teto, é observado o mesmo comportamento encontrado na técnica de SLCM, um aumento na taxa de acerto multiclasse, assim como um aumento na acurácia binária.

A técnica de Gráfico no tempo, não apresenta resultados satisfatórios quando comparada a outras técnicas apresentadas, com acurácias muito abaixo do aceitável. Devido a isto, neste trabalho não iremos prosseguir com essa técnica para comparações com as técnicas de SLCM e Chão-teto.

Com o aumento na acurácia multiclasse e binária nas técnicas apresentadas, todas as próximas análises apresentadas neste trabalho utilizarão somente os 10 atributos sugeridos por Silva Jr et al. (2020), devido a seu custo computacional reduzido.

3.3 Metodologias para redução no tamanho da amostra.

O Conjunto de dados de falhas de motores de indução, apresenta amostras com um total de 100.000 pontos. Estes pontos foram capturados a uma frequência de 10kHz, totalizando um tempo de captura de 10 segundos. Desta forma, é necessário um estudo para definir quanto destes pontos são necessários para a classificação, por que para uma aplicação embarcada 100.000 pontos ocupam grande quantidade de memória para armazenamento e tempo para captura dos dados.

Dito isto, esta seção tem o objetivo de reduzir o tamanho da amostra sem perda significativa de qualidade do sinal na etapa de classificação, algumas técnicas para redução da amostra foram aplicadas. Posteriormente seus resultados serão analisados e evidenciados os ganhos de cada técnica.

Nesse procedimento são criados novos conjuntos de dados, reduzindo o tamanho da amostra. Para cada conjunto novo de amostras, se repete o processo de treinamento do classificador. Isso permite avaliar a influência das reduções nas taxas de acerto do sistema extrator-classificador. Ao ser aplicada em diferentes métodos de extração de características,

é possível avaliar o quanto cada método é imune a essas reduções. Do ponto de vista do classificador, essas reduções podem significar a também a redução nas informações (características) que lhe permitem distinguir melhor entre as classes do problema.

3.3.1 Redução na taxa de amostragem

Esta exploração visa a avaliar os impactos da redução da frequência de amostragem nas taxas de acerto do sistema extrator-classificador. Os benefícios de reduzir a taxa de amostragem são: (1) menor uso de memória para armazenamento do vetor de pontos obtido do sensor, e o (2) uso de um conversor analógico-digital de menor custo.

O processo ocorre com a geração de amostras em frequências de amostragem cada vez menores, respeitando o teorema de Nyquist, reduzindo a quantidade de pontos.

O sinal original foi amostrado com uma Frequência de amostragem (F_s) de 10kHz. Um filtro Butterworth de quinta ordem foi aplicado com a frequência de corte (F_c) mostrada na equação 3.1. Na primeira rodada, as frequências acima de 2,5kHz são filtradas e F_s assume o valor de 5Khz. Com isso a quantidade de pontos é reduzida à metade totalizando 50.000 pontos. Em seguida o processo é repetido para obter um segundo corte.

$$F_c = \frac{F_s}{2} - (F_s \times 0,06) \quad (3.1)$$

Foram gerados ao todo seis novos conjuntos de amostras, com frequências de amostragem de 5kHz, 2,5kHz, 1,25kHz, 625Hz, 312Hz, 156Hz, nomeados de $M1$ a $M6$ respectivamente. Juntamente com o conjunto com frequência de amostragem original de 10kHz, totalizam sete conjuntos de amostras. Na Tabela 8, F_s é a frequência de amostragem e N é o número de pontos de cada amostra do conjunto resultante.

	Fs (kHz)	N
Original	10	100000
M1	5	50000
M2	2.5	25000
M3	1.25	12500
M4	0.625	6250
M5	0.312	3125
M6	0.156	1562

Tabela 8 – Redução da frequência de amostragem.

3.3.2 Redução no tempo de amostragem

Esta exploração visa a avaliar os impactos da redução no tamanho da amostra nas taxas de acerto do sistema extrator-classificador. Os benefícios de reduzir o tamanho da

amostra são: (1) menor uso de memória para armazenamento do vetor de pontos obtido do sensor, e (2) menor tempo de captura da amostra, que leva à possibilidade de emitir maior quantidade de diagnósticos por unidade de tempo, ou ainda à possibilidade de economizar energia, desligando o sistema por mais tempo de ociosidade.

Esta técnica realiza tão somente um corte no sinal no tamanho desejado, descartando o restante dos pontos do sinal. Para o processo de exploração, a cada corte o sinal é dividido ao meio e somente a primeira metade do sinal é tomada. Esta técnica permitiria um aumento no número de amostras para o treinamento do classificador. Entretanto, os dados excedentes não serão usados a fim de manter a comparação justa entre os diferentes tamanhos de amostra.

Na tabela 9 são mostrados os dados dos 7 conjuntos resultantes, cada um com amostras de tamanho variando de 50.000 a 1.562 pontos, além do original, que possui amostras de 100.000 pontos. N é o número de pontos de cada amostra.

	N
Original	100.000
Q1	50.000
Q2	25.000
Q3	12.500
Q4	6.250
Q5	3.125
Q6	1.562

Tabela 9 – Aplicação de corte nas amostras

3.4 Avaliação da redução no tamanho da amostra

Nessa seção são apresentados os resultados após aplicadas as técnicas de redução das amostras, conforme seções 3.3.1 e 3.3.2. Essa etapa ocorre antes da extração de características e, por isso, a exploração é feita para os dois modos de extração. A partir desses resultados será escolhida a configuração a ser aplicada na plataforma embarcada, seguindo o modelo da figura 6.

3.4.1 Usando redução na taxa de amostragem

Nesse experimento são aplicados os métodos descritos na seção 3.3.1 para geração dos conjuntos de dados com taxa de amostragem reduzida. As características são extraídas usando as duas técnicas sob avaliação, chão-teto (seção 2.3.2) e SLCM. As características das amostras são entregues ao classificador, seguindo o processo de treinamento e teste já descrito na seção 3.2.

A tabela 10 apresenta os resultados obtidos para os dois métodos de extração. Os valores de Acurácia e de F1-Score do classificador SVM são a média de 50 rodadas de execução do experimento. São usados somente os 10 atributos GLCM sugeridos em (Silva Jr et al., 2020), devido a seu custo computacional reduzido e um melhor resultado de taxa de acerto.

	SLCM		Chão-teto	
	Acurácia	F1-Score	Acurácia	F1-Score
Original	90,88	90,83	91,04	90,99
M1	67,80	67,79	67,92	67,87
M2	56,82	56,34	56,65	56,15
M3	62,42	62,05	62,48	62,06
M4	71,97	71,83	72,12	71,94
M5	69,78	69,52	69,33	69,10
M6	57,95	57,27	58,34	57,60

Tabela 10 – Resultados do experimento variando o tamanho da amostra pela redução da taxa de amostragem.

3.4.2 Usando redução do tempo de amostragem

Nesse experimento são aplicados os métodos descritos na seção 3.3.2 para geração dos conjuntos de dados com corte no tamanho e tempo de captura do sinal. As características são extraídas usando as duas técnicas sob avaliação, chão-teto (seção 2.3.2) e SLCM. As características das amostras são entregues ao classificador, seguindo o processo de treinamento e teste já descrito na seção 3.2.

A tabela 11 apresenta os resultados obtidos para os dois métodos de extração. Os valores de Acurácia e de F1-Score do classificador SVM são a média de 50 rodadas de execução do experimento. São usados somente os 10 atributos GLCM sugeridos em (Silva Jr et al., 2020), devido a seu custo computacional reduzido e melhor resultado de taxa de acerto.

	SLCM		Chão-teto	
	Acurácia	F1-Score	Acurácia	F1-Score
Original	90,88	90,83	91,04	90,99
Q1	89,14	89,05	89,40	89,31
Q2	88,94	88,79	88,38	88,26
Q3	87,10	86,98	85,45	85,33
Q4	84,71	84,54	82,21	82,09
Q5	78,35	78,25	76,43	76,38
Q6	72,82	72,77	69,47	69,44

Tabela 11 – Resultados do experimento variando o tamanho da amostra pela técnica de corte binário.

3.4.3 Análise de resultados

Observando os resultados da tabela 10 comparando o conjunto Original e a variação no valor de M , nota-se perdas significativas no desempenho do classificador ao reduzir a taxa de amostragem em relação ao conjunto Original. Devido a esta perda de generalidade do algoritmo essa abordagem de redução não será utilizada na versão embarcada.

O resultado mostrado na tabela 11, indica que o classificador tolera bem as reduções no tamanho da amostra, sugerindo que essa técnica pode ser usada sem perda significativa da sua capacidade de generalização. Os resultados do $Q3$ (amostras de 12.500 pontos) apresentam acurácia acima de 85% em ambas as técnicas e serão usados para avaliação na plataforma embarcada.

3.5 Avaliação na plataforma embarcada

Esta seção descreve a implementação do classificador em uma plataforma embarcada. As medidas de desempenho e memória são apresentadas e discutidas.

A plataforma escolhida consiste em uma STM32F429ZI, que utiliza um micro-controlador Arm Cortex-M4. O STM32F429ZI opera a 180mHz de frequência de clock e possui 2mB de memória flash e 256kB de memória RAM.

Conforme descrito na seção 3.4 os experimentos realizados nesta seção usarão os seguintes parâmetros:

1. **Técnica de redução de número de amostras:** Redução no tempo de amostragem com $Q3$ conforme tabela 11.
2. **Número de pontos do sinal de entrada:** 12500, conforme tabela 9.
3. **Técnicas para extração/geração de atributos:** Chão e teto, SLCM e uma comparação com os resultados obtidos no trabalho de Cunha (2019) com a utilização do mesmo conjunto de dados e a técnica de transformada wavelet.

A Figura 8 apresenta as etapas para o processo de classificação de falhas de motores de indução necessários para uso em uma plataforma embarcada. Sendo elas:

1. **Captura de dados pelo ADC:** Nesta etapa os dados de fluxo magnético vindos do ADC são capturados e armazenados na memória RAM da plataforma embarcada. Nos testes realizados neste trabalho utilizamos o dado já armazenado em memória, não fazendo o uso de um ADC real.
2. **Conversão dos dados para escala de cinza:** Nesta etapa os dados são convertidos para escala de cinza com n bits de representação. Neste trabalho utilizamos $n = 7$.

3. **Geração de imagem:** Nesta etapa os dados armazenados de fluxo magnético são transformado em uma imagem. Esta etapa não é necessária na técnica proposta (SLCM).
4. **Geração de matriz de coocorrência ($n \times n$):** Neste ponto a matriz de coocorrência dos valores armazenados em escala de cinza é gerada. A matriz possui tamanho relativo a escala de cinza escolhida, sendo geralmente de 8 bits. O trabalho Silva Jr et al. (2020) demonstra que ao utilizar o extrator de características GLCM, a matriz de coocorrência pode ser reduzida sem perda de generalidade do classificador. Baseado neste trabalho, os experimentos realizados nesta seção utilizam uma matriz de coocorrência com 7 bits, valores de 0 a 127.
5. **Extração de atributos:** Nesta etapa é aplicada a extração de atributos utilizando as estatísticas do GLCM. O Trabalho de SAMPAIO (2017) apresenta um estudo profundo sobre a seleção de atributos, resultando em um conjunto de 10 atributos que apresentam um custo reduzido de recursos de memória e tempo de CPU. Neste trabalho utilizaremos estes 10 atributos.
6. **Classificação:** Por fim, nesta etapa os atributos são apresentados ao classificador SVM, com modelo previamente treinado em estação de trabalho.




Figura 8 – Etapas do processo de classificação de falhas na plataforma embarcada.

Com a redução da matriz de coocorrência para 7 bits, um estudo foi realizado em estação de trabalho para avaliar a taxa de acerto deste conjunto de parâmetros. As taxas de acerto encontradas foram de $88,05\% \pm 1,42$ para o método SLCM e $85,98\% \pm 1,57$ para o método de chão e teto. Estes resultados são similares aos encontrados na Tabela 11, que

utiliza uma matriz de coocorrência de 8 bits (valores de 0-255). Esses valores comprovam a viabilidade da redução da matriz sem perda de generalidade do classificador a ser inserido na plataforma embarcada.

Na plataforma embarcada foi analisada a técnica proposta SLCM e a técnica de geração de imagem de chão e teto. Como o SLCM não gera imagens a partir do sinal, o sinal serve como entrada direta para a montagem da matriz de coocorrência. Devido a esta característica foi proposta uma implementação chamada de Opt-SLCM.

O Opt-SLCM se trata de uma otimização aplicada ao uso do SLCM como extrator de atributos. Como mostrado no diagrama da figura 9a, para as técnicas SLCM e Chão e teto, o sinal deve ser completamente capturado e armazenado antes de ser gerada a matriz de coocorrência, consumindo recursos de memória de dados.

Contudo, o Opt-SLCM, mostrado no diagrama 9b, tem como principal diferença o fato de somente o valor anterior e atual do sinal serem armazenados na memória de dados. Estes valores são contabilizados e já inseridos na matriz de coocorrência como uma vizinhança. Neste momento é incrementado um contador e o processo de captura de dados pelo ADC continua. Quando o número máximo de pontos é atingido o processo de captura do sinal e montagem da matriz de coocorrência é encerrado e pode seguir para a etapa de extração de atributos. Esta otimização consome menos recursos de memória de dados e será utilizada para comparação nas seções a seguir.




Figura 9 – Processo para gerar matriz de coocorrência.

3.5.1 Análise de uso de memória

Nesta seção será apresentado o consumo de memória de dados e memória de programa.

A análise da memória de dados, foi dividida em 5 blocos a fim de evidenciar o ganho em cada técnica. Os resultados para a memória de dados podem ser vistos na tabela 12.

1. **Sinal:** Consiste na memória utilizada para armazenamento do sinal a ser recebido em tempo de execução. O sinal capturado pelo ADC geralmente é representado por números inteiros de 10 a 12 bits. No entanto, é realizado o processo de conversão para números inteiros de 7 bits. O valor convertido é utilizado como entrada para a geração de matriz de coocorrência.
2. **Imagem:** Espaço reservado para alocação da imagem gerada a partir do sinal de entrada. Os algoritmos clássicos, como o chão e teto, transformam o sinal em imagem, mas o SLCM não.
3. **Matriz de coocorrência:** Espaço reservado para a matriz de coocorrência. Esta matriz quadrada de tamanho 128, devido ao uso de 7 bits de resolução, é de tamanho fixo para todos os métodos comparados. O valor máximo assumido pelos elementos dessa matriz está associado à resolução da imagem. Considerando uma amostra de $n \times m$ pixels, esse valor está limitado a $n \times (m - 1)$. Nessa implementação esse valor seria 12.432, que requer um inteiro de 16 bits para sua representação.
4. **Atributos:** Espaço para armazenamento dos 10 atributos extraídos da matriz de coocorrência obtidos pelas estatísticas do GLCM. Armazenados em variáveis de ponto flutuante 32 bits.
5. **Outras variáveis:** Outras variáveis para controle de fluxo de código e outras atividades não relevantes para a comparação dos métodos.

RAM (BYTES)	chão-teto	SLCM	Opt-SLCM	Wavelet
Sinal	12.500	12.500	2	60.000
Imagem	12.544	0	0	-
Matriz de coocorrência	65.536	65.536	65.536	-
Atributos	40	40	40	56
Outras variáveis	2.152	2.156	2.158	65.384
TOTAL	92.772	80.232	67.736	125.440

Tabela 12 – Resultados de uso de memória de dados(RAM) na plataforma embarcada.

Ambos os métodos armazenam o sinal integralmente na memória após a digitalização feita pelo conversor analógico-digital (ADC). Entretanto, os métodos de chão e teto, STFT e gráfico do sinal no tempo criam uma imagem a partir do sinal, enquanto o método de SLCM converte o sinal diretamente na matriz de coocorrência, não usando memória para esse armazenamento intermediário.

Utilizando o Opt-SLCM o armazenamento do sinal é reduzido somente a dois valores, o anterior e o atual. A comparação é realizada a cada novo dado vindo do ADC e introduzida a contagem diretamente na matriz de coocorrência. As três técnicas geram matrizes de coocorrência do mesmo tamanho. Para fins de comparação o trabalho de Cunha (2019) apresenta os resultados em uma plataforma embarcada do mesmo conjunto de dados, fazendo uso do mesmo classificador para a técnica de transformação de domínio, wavelet. Devido ao uso de uma técnica diferente os valores de Matrix de co-ocorrencia e Imagem nao sao gerados, os valores que nao podem ser comparados foram agrupados na linha "Outras Variaveis".

FLASH (BYTES)	chão-teto	SLCM	Opt-SLCM	Wavelet
Funções de decisão	50.232	64.344	64.344	17.392
Vetores Suporte	48.800	51.160	51.160	40.320
Outras variáveis/Código	23.856	24.168	23.696	15.649
TOTAL	122.888	139.672	139.200	73.361

Tabela 13 – Resultados de uso de memória de programa(FLASH) na plataforma embarcada.

A análise de memória de programa foi dividida em três blocos, onde a maior parte das alterações de consumo ocorrem, sendo eles:

1. **Funções de decisão:** Estas funções fazem parte da tomada de decisão do classificador SVM do tipo One-vs-One, onde cada função possui uma quantidade diferente de Vetores suporte a serem utilizados. Para um problema de 7 classes o classificador SVM utiliza um total de 21 funções de decisão com diferentes tamanhos de vetores suporte em cada, causando alteração no consumo de memória dependendo do modelo treinado para cada caso.
2. **Vetores Suporte:** Estes vetores suporte compõem os hiperplanos do classificador SVM. O total de vetores suporte depende do número de vetores necessários em cada função de decisão, e a essa quantidade depende do modelo treinado.
3. **Outras variáveis/Código:** Outras variáveis de sistema para ativação de periféricos e suporte ao programa compilado.

A tabela 13 apresenta os resultados obtidos nas diferentes técnicas aplicadas quanto a esse consumo de memória. Os métodos que utilizam SLCM como base possuem o mesmo modelo importado para o classificador SVM causando um consumo muito similar de memória de programa. O modelo de classificação da técnica chao-teto utiliza ao todo 1.220 vetores suporte, contra um total de 1.279 no modelo usado pelo SLCM. Isto explica o consumo superior de memória de programa.

O modelo apresentado no trabalho de Cunha (2019) possui um total de 720 vetores suporte e algumas otimizações para o reuso de variáveis que não foram reproduzidas em nossos experimentos, devido a isso, o consumo de memória de programa deste método é menor que as outras técnicas apresentadas. Estas técnicas de redução de uso de memória de programa apresentada na técnica wavelet não foram aplicadas nas outras técnicas, devido ao fato que dos microcontroladores terem uma grande capacidade de armazenamento em memória FLASH, e o ponto crítico de aplicações deste tipo é a redução do uso de memória RAM.

3.5.2 Análise de desempenho do processo de classificação

A análise de desempenho em tempo de computação foi dividida em 3 medições. O objetivo é evidenciar a influência da técnica de extração de características e o modelo do classificador. Sendo elas:

1. **Discretização e criação da CM (matriz de coocorrência):** Tempo para varredura da imagem gerada e discretização para geração da matriz de coocorrência. Como na técnica Wavelet não há geração de CM, iremos considerar a etapa de Decomposição Wavelet como primeira etapa.
2. **Extração de atributos:** Tempo para extração de atributos através das estatísticas do GLCM.
3. **Classificação SVM:** Tempo para realizar a classificação dos atributos extraídos.

Desempenho (ms)	chão-teto	SLCM	Opt-SLCM	Wavelet
Criação da CM	5,0994	4,9401	4,9399	-
Decomposição Wavelet	-	-	-	116,256
Extração de atributos	387,7249	389,2843	389,7671	56,3201
Classificação SVM	40,9979	43,2133	43,2138	37,016
TOTAL	433,8222	437,4377	437,9208	209,5921

Tabela 14 – Resultados de desempenho do processo de classificação na plataforma embarcada.

A etapa de geração da imagem e o tempo para capturar o sinal do ADC não serão considerados nesta etapa do estudo, pois os vetores já estão armazenados em memória em formato de matriz para imagens e vetor para o sinal. A Tabela 14 apresenta as medidas de tempo de execução de cada método para cada etapa do processo. Os resultados do método wavelet foram extraídos do trabalho de Cunha (2019). Devido aos experimentos terem sido realizados em um microcontrolador com clock de 168mHz, os tempos foram normalizados pela frequência de 180mHz, para justa comparação. Outra diferença, é que no trabalho de Cunha (2019) são utilizadas otimizações de hardware (FPU, DSP) para

diminuir o tempo de execução nos cálculos de multiplicações de matrizes. Devido a estas diferenças, é complexa a comparação entre Wavelet e as outras técnicas em cada etapa e por isso não serão descritas nos parágrafos a seguir. No entanto, o tempo total de execução é uma métrica importante para comparação entre soluções para o problema de falha de motores de indução.

Na primeira etapa o método de chão-teto apresenta um valor 3% maior quando comparado com a técnica proposta, o SLCM. Esse valor pode ser explicado devido ser necessário dois laços para percorrer a imagem nas duas dimensões. O método SLCM possui somente um laço e, por essa implementação, mesmo percorrendo a mesma quantidade de pontos acarreta redução de tempo.

Na segunda etapa (Extração de atributos), é esperado que na extração de atributos não haja diferenças no tempo entre os métodos, pois as estatísticas não dependem do método. Porém, existe uma divergência e ela pode ser explicada devido a uma das estatísticas ser o maior valor presente na matriz de coocorrência. Para obter este valor é necessária uma lógica condicional que resulta em um aumento ou redução de tempo de computação dependendo dos valores da matriz de coocorrência gerada.

Por fim, a técnica chão-teto possui menor quantidade de vetores suporte (1.220 vetores) quando comparada com a técnica proposta SLCM (1.279 vetores). Devido a isto, na última etapa (Classificação SVM) a diferença de tempo é resultante da quantidade de vetores suporte entre os modelos gerados em cada técnica.

O tempo de classificação de uma amostra da técnica wavelet é 47% menor quando comparada a técnica SLCM. Porém, o trabalho de Cunha (2019) utiliza uma técnica de redução de frequência de amostragem para 5kHz, que resulta em 15.000 pontos capturados durante 3 segundos. Já a técnica SLCM necessita de 1,25 segundos (frequência de 10Khz e 12.500 pontos) para captura de uma amostra. Portanto, a técnica wavelet precisa de 3,02 segundos para captura e classificação, contra o tempo de 1,69 segundos para a técnica SLCM, resultando em um tempo 56% menor.

O tempo total da técnica chão e teto, não é significativamente diferente do tempo da técnica SLCM, podendo ser considerado igual neste problema.

3.6 Avaliação Geral

Este artigo propõe uma nova abordagem para utilização das estatísticas do GLCM em sinais no tempo. O GLCM é uma técnica que têm sido utilizada em muitos trabalhos para capturar a textura de imagens desde que foi proposta por Haralick, Shanmugam e Dinstein (1973). O objetivo é evitar a criação de uma imagem intermediária para representação do sinal de entrada. A abordagem é avaliada usando um conjunto de dados para detecção de falhas em motores de indução, em comparação com diferentes técnicas similares encontradas na literatura. Duas abordagens para reduzir a quantidade de recursos computacionais no processo de aquisição são discutidas.

Após a validação dos experimentos, as alterações no conjunto de dados original resultaram em uma redução de 87,5% (100.000 para 12.500) no número de pontos de aquisição necessários para gerar um resultado de classificação. Depois de validar essas explorações de conjunto de dados em uma estação de trabalho, o classificador com melhor precisão em cada técnica foi embarcado em um microcontrolador e o tempo de execução e o uso de memória foram avaliados.

A técnica proposta não apresenta uma diferença significativa em relação a tempo de computação. Entretanto, apresenta uma redução importante no custo de memória volátil que pode chegar a 46% (125.440 para 67.736 bytes) quando comparado a outras técnicas na literatura, sem que estas mudanças afetem significativamente (redução de 90,88% para 87,10%) a capacidade de diagnóstico do classificador.

4 Conclusão

O objetivo geral deste trabalho é propor uma técnica de extração de características usando métricas de análise de textura para classificação de sinais elétricos. Para atingir este objetivo foi analisado o uso de uma modificação na extração da matriz de co-ocorrência do GLCM para ter como entrada um sinal em um dimensão sem ser necessária sua transformação para imagem ou outro domínio 2D. Este método modificado foi nomeado como *Signal level concurrence Matrix* (SLCM).

Para avaliar o desempenho da técnica proposta quanto a sua taxa de acerto, foram efetuados experimentos com técnicas já existentes na literatura que utilizam a transformação do sinal em imagens. As técnicas utilizadas para comparação foram as técnicas de chão e teto e geração de imagem através do gráfico do sinal no tempo. Nesta etapa também foi analisada a seleção de quais atributos seriam extraídos da matriz de co-ocorrência. Como resultado deste experimento foi detectado que a técnica proposta não apresenta perda de generalidade quando comparada com as melhores técnicas da literatura, provando ser eficaz na classificação de sinais elétricos com métricas de análise de textura.

Em seguida, a tolerância da técnica proposta a reduções no tamanho da entrada foi avaliada. Esta redução é importante para reduzir o tempo de captura do sinal possibilitando retorno mais rápido sobre o resultado da classificação, assim como, possibilita o uso de microcontroladores com bem menos recursos para armazenamento do sinal e tempo de cálculo dos atributos. A técnica proposta apresenta uma boa tolerância a redução do tamanho da entrada, sendo reduzido de 100,000 para 12,500 pontos o tamanho da entrada e sem perda significativa de generalidade. Com isto, a técnica proposta pode ser utilizada com sinais menores e com um tempo de captura reduzido.

Por fim, os melhores parâmetros de tamanho da entrada, melhores atributos e tamanho da matriz de co-ocorrência foram sintetizados e levados para estudo do comportamento da técnica quando utilizada uma plataforma embarcada com limitações de recursos computacionais. A avaliação na plataforma embarcada em comparação com técnicas de geração de imagens e transferência de domínio de trabalhos similares que também foram embarcados, apresenta um resultado bastante satisfatório chegando a reduzir o consumo de memória em 46% e o tempo total para classificação e captura de um sinal em 56%.

Além de economizar memória, a técnica proposta contribuiu para diminuir o tempo de aquisição, conseguindo tempos de resposta bem menores. Conciliando com uma taxa de acerto acima de 90% e sem confundir as classes com severidades mais altas com a classe normal, reduzindo o número de falsos negativos da aplicação final.

4.1 Trabalhos futuros

Para trabalhos futuros, novos conjuntos de dados serão pesquisados para avaliar a técnica proposta em diferentes problemas. A avaliação da técnica proposta usando um classificador embarcado conectado a um motor real está em andamento. Assim como otimizações dos algoritmos para uso de hardware dedicado para as operações de ponto flutuante.

Referências

- ABDELDAYEM, S. S.; BOURLAI, T. Automatically detecting arrhythmia-related irregular patterns using the temporal and spectro-temporal textures of ecg signals. In: IEEE. *2018 24th International Conference on Pattern Recognition (ICPR)*. [S.l.], 2018. p. 2301–2307. Citado 4 vezes nas páginas 20, 21, 26 e 28.
- ALBRECHT, P. et al. Assessment of the reliability of motors in utility applications-updated. *IEEE Transactions on Energy conversion*, IEEE, n. 1, p. 39–46, 1986. Citado na página 19.
- AUTOMATION, R. Application basics of operation of three-phase induction motors. *Sprecher+ Schuh AG Rockwell Automation, Arau*, v. 2011, 1996. Citado 2 vezes nas páginas 11 e 25.
- AZAD, M.; KHALED, F.; PAVEL, M. A novel approach to classify and convert 1d signal to 2d grayscale image implementing support vector machine and empirical mode decomposition algorithm. *Int J Adv Res*, v. 7, p. 328–335, 2019. Citado 4 vezes nas páginas 20, 21, 26 e 28.
- BELLINI, A. et al. Advances in diagnostic techniques for induction machines. *IEEE Transactions on industrial electronics*, IEEE, v. 55, n. 12, p. 4109–4126, 2008. Citado na página 26.
- BONNETT, A. H. Analysis of the impact of pulse-width modulated inverter voltage waveforms on ac induction motors. *IEEE Transactions on Industry Applications*, IEEE, v. 32, n. 2, p. 386–392, 1996. Citado na página 26.
- BONNETT, A. H.; SOUKUP, G. C. Cause and analysis of stator and rotor failures in three-phase squirrel-cage induction motors. *IEEE Transactions on Industry applications*, IEEE, v. 28, n. 4, p. 921–937, 1992. Citado na página 26.
- BOUZID, M. B. K.; CHAMPENOIS, G. Neural network based method for the automatic detection of the stator faults of the induction motor. In: IEEE. *2013 International Conference on Electrical Engineering and Software Applications*. [S.l.], 2013. p. 1–7. Citado na página 20.
- CABANAS, M. F. et al. Detection of stator winding insulation failures: On-line and off-line tests. In: IEEE. *2013 IEEE Workshop on Electrical Machines Design, Control and Diagnosis (WEMDCD)*. [S.l.], 2013. p. 210–219. Citado na página 26.
- COELHO, D.; MEDEIROS, C. Short circuit incipient fault detection and supervision in a three-phase induction motor with a som-based algorithm. In: *Advances in Self-Organizing Maps*. [S.l.]: Springer, 2013. p. 315–323. Citado na página 20.
- COELHO, D. N. et al. Performance comparison of classifiers in the detection of short circuit incipient fault in a three-phase induction motor. In: IEEE. *2014 IEEE Symposium on Computational Intelligence for Engineering Solutions (CIES)*. [S.l.], 2014. p. 42–48. Citado na página 20.

CORTES, C.; VAPNIK, V. Support-vector networks. *Machine learning*, Springer, v. 20, n. 3, p. 273–297, 1995. Citado na página 36.

CUNHA, R. G. C. *Machine Learning and Multiresolution Signal Decomposition for Embedded Applications: A Study of Short-Circuit Failure Detection in Induction Motors*. Dissertação (Mestrado), 2019. Citado 8 vezes nas páginas 20, 27, 36, 44, 47, 48, 49 e 50.

CUNHA, R. G. C.; SILVA JR., E. T. da; MEDEIROS, C. M. de S. *Inter-turn Short-Circuit In Induction Motor*. Kaggle, 2021. Disponível em: <<https://www.kaggle.com/dsv/1885987>>. Citado na página 36.

FITZGERALD, A. E. et al. *Electric machinery*. [S.l.]: McGraw-Hill New York, 2003. v. 5. Citado na página 25.

FRIEDMAN, J. et al. *The elements of statistical learning*. [S.l.]: Springer series in statistics New York, 2001. v. 1. Citado na página 33.

GARG, G. et al. Relative wavelet energy as a new feature extractor for sleep classification using eeg signals. in *Journal of Biomedical Signal Processing. Jan-June Issue*, 2011. Citado na página 27.

GHATE, V. N.; DUDUL, S. V. Optimal mlp neural network classifier for fault detection of three phase induction motor. *Expert Systems with Applications*, Elsevier, v. 37, n. 4, p. 3468–3481, 2010. Citado na página 19.

GONÇALVES, A. R. Máquina de vetores suporte. *Acesso em*, v. 21, 2015. Citado na página 33.

GROUP, M. R. W. et al. Report of large motor reliability survey of industrial and commercial installations, part i. *IEEE Trans. Industrial Applications*, v. 1, n. 4, p. 865–872, 1985. Citado na página 19.

HALL, M. A. Correlation-based feature subset selection for machine learning. *Thesis submitted in partial fulfillment of the requirements of the degree of Doctor of Philosophy at the University of Waikato*, 1998. Citado na página 32.

HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. H. Textural features for image classification. *IEEE Transactions on systems, man, and cybernetics*, Ieee, n. 6, p. 610–621, 1973. Citado 8 vezes nas páginas 20, 28, 30, 31, 36, 51, 61 e 62.

ISLAM, R.; UDDIN, J.; KIM, J.-M. Texture analysis based feature extraction using gabor filter and svd for reliable fault diagnosis of an induction motor. *International Journal of Information Technology and Management*, Inderscience Publishers (IEL), v. 17, n. 1-2, p. 20–32, 2018. Citado 4 vezes nas páginas 20, 21, 26 e 28.

JANG, W.-C.; KANG, M.; KIM, J.-M. Fault classification of an induction motor using texture features of vibration signals. In: *Frontier and Innovation in Future Computing and Communications*. [S.l.]: Springer, 2014. p. 177–183. Citado 4 vezes nas páginas 20, 21, 26 e 28.

KAUFHOLD, M. et al. Interface phenomena in stator winding insulation-challenges in design, diagnosis, and service experience. *IEEE Electrical insulation magazine*, IEEE, v. 18, n. 2, p. 27–36, 2002. Citado na página 19.

KUBAT, M. Neural networks: a comprehensive foundation by simon haykin, macmillan, 1994, isbn 0-02-352781-7. *The Knowledge Engineering Review*, Cambridge University Press, v. 13, n. 4, p. 409–412, 1999. Citado na página 33.

LASHKARI, N.; POSHTAN, J. Detection and discrimination of stator interturn fault and unbalanced supply voltage fault in induction motor using neural network. In: IEEE. *The 6th Power Electronics, Drive Systems & Technologies Conference (PEDSTC2015)*. [S.l.], 2015. p. 275–280. Citado na página 20.

LORENA, A. C.; CARVALHO, A. C. de. Uma introdução às support vector machines. *Revista de Informática Teórica e Aplicada*, v. 14, n. 2, p. 43–67, 2007. Citado na página 33.

MALLAT, S. *A wavelet tour of signal processing*. [S.l.]: Elsevier, 1999. Citado na página 27.

MALLAT, S. G. A theory for multiresolution signal decomposition: the wavelet representation. *IEEE transactions on pattern analysis and machine intelligence*, Ieee, v. 11, n. 7, p. 674–693, 1989. Citado na página 27.

MARWEDEL, P. *Embedded system design*. [S.l.]: Springer, 2006. v. 1. Citado na página 34.

MORSALIN, S. et al. Induction motor inter-turn fault detection using heuristic noninvasive approach by artificial neural network with levenberg marquardt algorithm. In: IEEE. *2014 International Conference on Informatics, Electronics & Vision (ICIEV)*. [S.l.], 2014. p. 1–6. Citado na página 20.

NANDI, S.; TOLİYAT, H. A. Condition monitoring and fault diagnosis of electrical machines—a review. In: IEEE. *Conference Record of the 1999 IEEE Industry Applications Conference. Thirty-Forth IAS Annual Meeting (Cat. No. 99CH36370)*. [S.l.], 1999. v. 1, p. 197–204. Citado na página 19.

NANDI, S.; TOLİYAT, H. A.; LI, X. Condition monitoring and fault diagnosis of electrical motors—a review. *IEEE transactions on energy conversion*, IEEE, v. 20, n. 4, p. 719–729, 2005. Citado na página 19.

NETO, A. R. D. R. *SINPATCO II: Novas Estratégias de Aprendizado de Máquinas para Classificação de Patologias da Coluna Vertebral*. Tese (Doutorado) — Universidade Federal do Ceará - UFC, 2011. Citado na página 33.

OLIVEIRA, Á. G. de; PONTES, R. S. T.; MEDEIROS, C. M. de S. Neural network used to stator winding interturn short-circuit fault detection in an induction motor driven by frequency converter. In: IEEE. *2013 BRICS Congress on Computational Intelligence and 11th Brazilian Congress on Computational Intelligence*. [S.l.], 2013. p. 459–464. Citado na página 20.

PANDEY, K.; ZOPE, P.; SURALKAR, S. Review on fault diagnosis in three-phase induction motor. *MEDHA-2012, Proceedings published by International Journal of Computer Applications (IJCA)*, 2012. Citado na página 19.

RIERA-GUASP, M.; ANTONINO-DAVIU, J. A.; CAPOLINO, G.-A. Advances in electrical machine, power electronic, and drive condition monitoring and fault detection: state of the art. *IEEE Transactions on Industrial Electronics*, IEEE, v. 62, n. 3, p. 1746–1759, 2014. Citado na página 26.

SAMPAIO, F. *Estudo de redução do custo computacional em aplicações embarcadas utilizando Máquinas de Vetores Suporte e extratores de atributos de imagens por textura*. Dissertação (Mestrado), 2017. Citado 6 vezes nas páginas 11, 13, 32, 45, 61 e 62.

SAMPAIO, F. et al. An embedded classifier for mobile robot localization using support vector machines and gray-level co-occurrence matrix. In: SPRINGER. *International Conference on Artificial Intelligence and Soft Computing*. [S.l.], 2018. p. 201–213. Citado 2 vezes nas páginas 36 e 62.

Silva Jr, E. T. et al. A method for embedding a computer vision application into a wearable device. *Microprocessors and Microsystems*, Elsevier, p. 103086, 2020. Citado 8 vezes nas páginas 37, 38, 39, 40, 42, 43, 45 e 62.

SMOLA, A. J. et al. *Advances in large margin classifiers*. [S.l.]: MIT press, 2000. Citado na página 33.

SOH, L.-K.; TSATSOUKIS, C. Texture analysis of sar sea ice imagery using gray level co-occurrence matrices. *IEEE Transactions on geoscience and remote sensing*, IEEE, v. 37, n. 2, p. 780–795, 1999. Citado 6 vezes nas páginas 28, 30, 31, 36, 61 e 62.

SOUSA, P. H. F. de et al. Intelligent incipient fault detection in wind turbines based on industrial iot environment. *Journal of Artificial Intelligence and Systems*, Institute of Electronics and Computer, v. 1, n. 1, p. 1–19, 2019. Citado 4 vezes nas páginas 20, 21, 26 e 29.

TAVNER, P. Review of condition monitoring of rotating electrical machines. *IET electric power applications*, IET, v. 2, n. 4, p. 215–247, 2008. Citado na página 26.

THOMSON, W. Diagnosing faults in induction motors—engineering ideas. *Electrical Review*, v. 215, n. 17, 1984. Citado na página 26.

THOMSON, W. T.; FENGER, M. Current signature analysis to detect induction motor faults. *IEEE Industry Applications Magazine*, Ieee, v. 7, n. 4, p. 26–34, 2001. Citado na página 19.

UDDIN, J.; VAN, D. N.; KIM, J.-M. Accelerating 2d fault diagnosis of an induction motor using a graphics processing unit. *International Journal of Multimedia and Ubiquitous Engineering*, v. 10, n. 1, p. 341–352, 2015. Citado 4 vezes nas páginas 20, 21, 26 e 28.

VAPNIK, V. N. *The Nature of Statistical Learning Theory*. Berlin, Heidelberg: Springer-Verlag, 1995. ISBN 0387945598. Citado na página 33.

VIEIRA, R. G.; MEDEIROS, C. M.; SILVA, E. T. Classification and sensitivity analysis to detect fault in induction motors using an mlp network. In: IEEE. *2016 International Joint Conference on Neural Networks (IJCNN)*. [S.l.], 2016. p. 796–802. Citado na página 20.

WANG, H. et al. Multilevel binomial logistic prediction model for malignant pulmonary nodules based on texture features of ct image. *European journal of radiology*, Elsevier, v. 74, n. 1, p. 124–129, 2010. Citado 6 vezes nas páginas 28, 30, 31, 36, 61 e 62.

WOLF, M. *Computers as components: principles of embedded computing system design*. [S.l.]: Elsevier, 2012. Citado 2 vezes nas páginas 19 e 34.

APÊNDICE A – Estudo da complexidade na extração dos atributos - GLCM

A GLCM disponibiliza um conjunto de 24 medidas estatísticas, que podem ser extraídas de uma única imagem os atributos são descritos na tabela 15.

Fonte	#	Atributos
Haralick, Shanmugam e Dinstein (1973)	14	ASM, Contraste, Correlação, Soma dos Quadrados, IDM, Média da Soma I, Variância da Soma, Entropia da Soma, Entropia, Variância da Diferença, Entropia da Diferença, IMC I, IMC II, MCC.
Soh e Tsatsoulis (1999)	6	Homogeneidade, Autocorrelação, Dissimilaridade, Tons de agrupamento, Proeminência do agrupamento, Probabilidade Máxima.
Wang et al. (2010)	4	Média da soma II, Tendência de Agrupamento, Média da diferença, Inércia.
	24	-

Tabela 15 – Relação das 24 medidas estatísticas da GLCM. (SAMPAIO, 2017)

Neste estudo foi utilizada a notação assintótica Θ para descrever os tempos de execução dos algoritmos de cálculo de todos os 24 atributos GLCM inspecionando os desempenhos no pior caso. O tamanho da entrada n do algoritmo para calcular os atributos é o valor da dimensão da Matriz de Coocorrência MC. Sendo que sempre é preciso percorrer toda a matriz para extrair um atributo.

Custo Temporal	Atributos
$\Theta(n^2)$	CustoASM, Contraste, IDM, Entropia, Homogeneidade, Média da soma II, Probabilidade máxima, Dissimilaridade, Média da diferença, Autocorrelação.
$\Theta(n^2 + n)$	Correlation, Inertia.
$\Theta(n^2 + 2n)$	Média da soma I, Entropia da soma, Variância da diferença, Entropia da diferença
$\Theta(n^2 + 4n - 2)$	Sum Variance
$\Theta(2n^2)$	Variância, IMC I, IMC II, MCC, Tendência de agrupamento, Tons de agrupamento, Proeminência do agrupamento

Tabela 16 – Relação das 24 medidas estatísticas da GLCM. (SAMPAIO, 2017)

Na tabela 16 são apresentados todos os 24 atributos de acordo com a complexidade do tempo de execução, baseado nas equações de Haralick, Shanmugam e Dinstein (1973), Soh e Tsatsoulis (1999), Wang et al. (2010). Analisando todos valores para os cálculos dos atributos, a menor complexidade de tempo de execução encontrada foi $\Theta(n^2)$, que consiste no custo de percorrer a matriz de co-ocorrência somente uma vez.

Custo Espacial	Atributos
$\Theta(1)$	ASM, Contraste, Variância, IDM, Entropia, Homogeneidade, Média da Soma II, Probabilidade máxima, Tendência de agrupamento, Tons de agrupamento, Proeminência do agrupamento, Dissimilaridade, Média da diferença, Autocorrelação, Inércia .
$\Theta(n)$	Variância da diferença, Entropia da diferença.
$\Theta(2n - 1)$	Média da Soma I, Entropia da Soma.
$\Theta(2n)$	Correlação, Variância da Soma , IMC I, IMC II, MCC.

Tabela 17 – Relação das 24 medidas estatísticas da GLCM. (SAMPAIO, 2017)

Com essa mesma abordagem, foi realizado um novo estudo de complexidade baseado no consumo de memória. Novamente, n representa a dimensão da matriz de coocorrência e cada elemento da matriz consiste em um valor de ponto flutuante. A Tabela 17 apresenta o estudo de complexidade espacial na obtenção de cada atributo, agrupados de forma crescente.

Os atributos do grupo que apresentam uma complexidade espacial $\Theta(1)$, consomem apenas um espaço de memória equivalente ao tamanho da matriz de co-ocorrência. Constatase que o grupo que contém os atributos com complexidade temporal $\Theta(n^2)$ está incluído no conjunto de atributos com complexidade espacial $\Theta(1)$. Assim, os 10 atributos com menor tempo de computação também apresentam a menor complexidade espacial.

Conforme apontado nos trabalhos de SAMPAIO (2017), Sampaio et al. (2018), Silva Jr et al. (2020) que utilizam estes 10 atributos em comparação com os 24 do GLCM em diferentes conjuntos de dados, em todos os casos o acerto com 10 atributos foi igual ou superior aos originais, e com uma redução de uso de CPU e consumo de memória acima de 80%.