

INSTITUTO FEDERAL DO CEARÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENÉRGIAS RENOVÁVEIS

JOSÉ CIRO DOS SANTOS

ESTUDO E CLASSIFICAÇÃO DE UM AÇO ELÉTRICO DE GRÃO NÃO
ORIENTADO QUANTO AO SEU ESTADO MICROESTRUTURAL ATRAVÉS DE
SISTEMA DE VISÃO COMPUTACIONAL

Maracanaú
2017

JOSÉ CIRO DOS SANTOS

ESTUDO E CLASSIFICAÇÃO DE UM AÇO ELÉTRICO DE GRÃO NÃO
ORIENTADO QUANTO AO SEU ESTADO MICROESTRUTURAL ATRAVÉS DE
SISTEMA DE VISÃO COMPUTACIONAL

Dissertação submetida ao Programa de Pós-Graduação em Energias Renováveis do Instituto Federal de Educação Ciência e Tecnologia do Ceará, como requisito parcial para obtenção do grau de mestre em energias renováveis.

Linha de pesquisa: Mecânica Aplicada à Conservação do Meio Ambiente

Orientador: Prof. Dr. Francisco Nélcio Costa Freitas

Co-orientador: Prof. Dr. Pedro Pedrosa Rebouças Filho

Maracanaú
2017

Catalogação na Fonte

S237 Santos, José Ciro dos.
Estudo e classificação de um aço elétrico de
grão não orientado quanto ao seu estado
microestrutural através de sistema de visão
computacional / José Ciro dos Santos -- 2017.
128 f.

Dissertação (Programa de Pós-graduação em
Energias Renováveis) -- Instituto Federal de
Educação, Ciência e Tecnologia do Ceará, campus
Maracanaú, 2017.
Orientador: Prof. Dr. Francisco Nélcio C.
Freitas.

1.AÇO ELÉTRICO. 2.INTELIGÊNCIA COMPUTACIONAL.
3.PROCESSAMENTO DIGITAL DE IMAGENS. I.Título.
669.95

Sistema AutoCata(Desenvolvido por Cledson Oliveira)
SIBI/PROEN - Biblioteca Rachel de Queiroz - IFCE-Maracanaú


JOSÉ CIRO DOS SANTOS

ESTUDO E CLASSIFICAÇÃO DE UM AÇO ELÉTRICO DE GRÃO NÃO ORIENTADO
QUANTO AO SEU ESTADO MICROESTRUTURAL ATRAVÉS DE SISTEMA DE
VISÃO COMPUTACIONAL


Dissertação submetida à Coordenação do Curso de Pós-graduação em Energias Renováveis do Instituto Federal de Educação, Ciência e Tecnologia do Ceará, como requisito parcial para a obtenção do título de Mestre em Energias Renováveis, área de concentração Energias Renováveis.

Aprovada em 24 / 10 / 16.


BANCA EXAMINADORA




Prof. Dr. Francisco Nélcio Costa Freitas (Orientador)
Instituto Federal de Educação, Ciência e Tecnologia do Ceará - IFCE



Prof. Dr. Pedro Pedrosa-Rebouças Filho
Instituto Federal de Educação, Ciência e Tecnologia do Ceará - IFCE



Prof. Dr. Francisco Frederico dos Santos Matos
Instituto Federal de Educação, Ciência e Tecnologia do Ceará - IFCE



Prof. Dr. Luiz Flávio Gaspar Herculano
Universidade Federal do Ceará - UFC

“Se o dinheiro for a sua esperança de independência, você jamais a terá. A única segurança verdadeira consiste numa reserva de sabedoria, de experiência e de competência.”

Henry Ford

Agradecimentos

Agradeço a Deus pelo maravilhoso presente que é a vida.

À minha mãe Rita Pedro Gomes dos Santos pelo apoio e incansável dedicação no preparo para a vida.

À minha esposa Maria José Aguiar Ribeiro dos Santos pelo incondicional apoio, paciência e companheirismo.

Ao meu filho Samuel Aguiar Ribeiro dos Santos pelo incentivo, paciência e carinho.

Ao meu orientador professor Dr. Francisco Nélio Costa Freitas pelos ensinamentos e amizade na esfera profissional e pessoal.

Ao meu co-orientador professor Dr. Pedro Pedrosa Rebouças Filho pela orientação, amizade e ajuda na superação dos obstáculos acadêmicos.

Aos professores Geraldo Luiz Bezerra Ramalho, Francisco Frederico dos Santos Matos, Adriano Holanda Pereira e Francisco José dos Santos Oliveira, pelas críticas construtivas, pelo incentivo, apoio e amizade.

Ao Dr Luiz Flávio Gaspar Herculano pela grande ajuda, paciência e ensinamentos na utilização dos equipamentos do Laboratório de caracterização e análise de materiais da Universidade Federal do Ceará.

Ao professor Dr Giovanni Cordeiro Barroso pelo tempo dedicado, pelas orientações

e apoio.

Aos professores Manoel das Chagas Victor, Antônio Carlos de Oliveira e José de Alidomar Ribeiro por me ensinarem a dar os primeiros passos na carreira profissional.

Ao professor Dr Hamilton Ferreira Gomes de Abreu pelo apoio, incentivo e amizade.

Aos bolsistas Roberto Fernandes Ivo, Diego Chaves, Daniel de Alencar Lima, Gabriel Bandeira Holanda e Douglas de Araújo Rodrigues pela ajuda prestada no desenvolvimento desse trabalho.

SANTOS, J. C. *Estudo e classificação de um aço elétrico de grão não orientado quanto ao seu estado microestrutural através de sistema de visão computacional*, Dissertação de mestrado. Instituto Federal de Educação Ciência e Tecnologia do Ceará (2016).

Resumo

A crescente demanda mundial por energia elétrica, torna necessário a adoção de medidas que vão desde a exploração de novos recursos da matriz energética até o desenvolvimento de tecnologias que permitam elevados níveis de eficiência energética de máquinas e equipamentos. Os aços elétricos de grão não orientado são largamente utilizados na construção de rotores e estatores que formam o núcleo dos motores elétricos, e suas características microestruturais estão diretamente relacionadas ao seu desempenho eletromagnético. O presente trabalho apresenta uma abordagem rápida e eficiente para a classificação dos aços elétricos de grão não orientado quanto ao seu estado microestrutural e desempenho eletromagnético à partir da análise de suas fotomicrografias, explorando a fundamentação científica acerca da interação entre suas propriedades magnéticas e sua microestrutura, a qual afirma que o tamanho do grão tem um efeito muito forte nas perdas magnéticas desse material. O estudo foi realizado em amostras de um aço elétrico de grão não orientado, semiprocessado com 1,28% de silício, laminados a frio com reduções de 50% e 70%, recozido em caixa a 730°C por 12 horas, submetidas à tratamento térmico de recozimento para crescimento de grão nas temperaturas de 620°C, 730°C, 840°C e 900°C pelos tempos de 1, 10, 100 e 1000 minutos em cada temperatura, o que levou a formação de um banco de dados com 192 imagens. A abordagem computacional empregada utilizou a combinação dos extratores de atributos, *Gray Level Co-Occurrence Matrix* (GLCM), *Local Binary Pattern* (LBP), momentos centrais, momentos estatísticos e momentos de Hu, com os classificadores *Bayes*, *K-Nearest Neighbor* (KNN) com 1, 3 e 5 vizinhos mais próximos, *K-means*, *Multi layer perceptron* (MLP) com duas configura-

ções, *Support Vector Machines* (SVM) com *kernel* linear, *Radial Basis Function* (RBF), sigmóide e polinomial, ainda combinados com 2 métodos de partição de dados, o *hold out* e o *leave one out*. A classificação realizada pelo método KNN com 1 vizinho, utilizando o banco de dados formado pelo extrator GLCM e método de partição de dados *hold out*, obteve a maior acurácia com taxa de 97,44%, além de valores superiores a 96% nas demais métricas de validação, necessitando de apenas 15,4 milissegundos para teste. Vale ressaltar que com os resultados obtidos, pode-se constatar que a abordagem proposta nesse trabalho gera uma nova metodologia de análise microestrutural de aços elétricos de grão não orientado.

Palavras-chave: Aço elétrico de grão não orientado, Inteligencia computacional aplicada, Processamento Digital de Imagens.

SANTOS, J. C. *Study and classification of an not oriented grain electrical steel as to its microstructural state through computer vision system*, Master dissertation. Instituto Federal de Educação Ciência e Tecnologia do Ceará (2016).

Abstract

The growing global demand for energy makes necessary to adopt actions ranging from the exploration of new energy resources up to the until development of technologies that allow high levels of energy efficiency in machinery and equipment. Electric steels with grain non oriented are widely used in the manufacture of rotors and stators that form the core of electric motors, and their microstructures are directly related to its electromagnetic performance. This work presents a new method, fast and efficient for the classification of electrical steel with non oriented grain as to its microstructural state and electromagnetic performance from analysis of their photomicrographs, exploring the scientific basis of the interaction between their magnetic properties and their microstructure, which states that the grain size has a very strong effect on the magnetic properties of this material. The study was performed in samples of non-oriented grain electrical steel with 1.28 % silicon, cold rolled with reductions of 50 % and 70 %, annealed in box at 730 ° C for 12 hours, subjected the annealing heat treatment to grain growth at temperatures of 620 ° C, 730 ° C, 840 ° C and 900 ° C for times of 1, 10, 100 and 1000 minutes for each temperature, forming a database with 192 images. The approach used a combination of extractors attributes, Gray Level Co-Occurrence Matrix (GLCM), Local Binary Pattern (LBP), central moments, statistical moments and moments of Hu, with the classifiers Bayes, K-Nearest Neighbor (KNN) with 1, 3 and 5 nearest neighbors, K-means, Multi layer perceptron (MLP) with two settings, Support Vector Machines (SVM) with linear,

Radial Basis Function (RBF), sigmoid and polynomial kernel, also combined with two methods of data partition, hold out and leave one out. Rating carried out by the KNN method 1 nearest neighbor using the database formed by extractor GLCM and hold out data partition method, obtained the best accuracy rate of 97.44 % , in addition to values greater than 96 % in other validation metrics, requiring only 15.4 milliseconds for testing. It is noteworthy that with the results obtained, it can be seen that the approach proposed in this work generates a new microstructural analysis methodology of not oriented grain electrical steels.

Keywords: Electrical steel with non oriented grain , Computational Intelligence applied, Digital Image Processing.

Lista de Figuras

1.1	Perdas totais e suas componentes anômala (Pa), parasítica (Pp) e histerética (Ph) para seis tipos de aços elétricos	3
2.1	Influência do tamanho do grão nas perdas magnéticas totais para aços elétricos com 1,85% si, 2,8% si e 3,2% si	7
2.2	Textura cristalográfica	9
2.3	Célula cúbica unitária	10
2.4	Componentes em uma chapa laminada	10
2.5	Representação dos cristais antes da rotação	11
2.6	Cristais rotacionados utilizando os ângulos de Euler	12
2.7	FDOC de aço carbono laminado a frio	13
2.8	Curvas de magnetização de um monocristal de ferro nas direções $\langle 100 \rangle$, $\langle 110 \rangle$ e $\langle 111 \rangle$	14
2.9	Formação de textura Goss.	15
2.10	Representação esquemática do processo de rearranjo	17
2.11	Estágios da recuperação em metal deformado plasticamente	17
2.12	Diagrama de recristalização primária	18
2.13	Aço elétrico recozido apresentando grãos com crescimento anormal (recristalização secundária) e grãos de crescimento normal remanescentes (recristalização primária)	19

2.14	Aço elétrico recozido apresentando crescimento anormal de grão	20
2.15	Dominios magnéticos	21
2.16	Formação da curva de histerese	24
2.17	Classificação de ferro fundido com base na análise visual da grafita: Norma ISO 945 2008	26
3.1	Histograma de imagens digitais	29
3.2	Ângulos utilizados no cálculo das matrizes de co-ocorrência	32
3.3	Primeiros passos do algoritmo gerador de uma matriz GLCM.	32
3.4	Montagem do LBP para diferentes valores de P e R	34
3.5	Lógica de construção do algoritmo LBP.	35
4.1	Classificação supervisionada	38
4.2	Classificação não supervisionada	39
4.3	Classificação com KNN	41
4.4	Cálculo da distancia Euclidiana	42
4.5	Organização de clusters	43
4.6	Passos para geração do algoritmo k-means	44
4.7	Classificação com support vector machines	48
4.8	Aumento de dimensionalidade no espaço de atributos - SVM não linear	49
4.9	Configuração básica de uma RNA Perceptron simples.	50
4.10	Arquitetura básica de uma rede MLP	52
5.1	Máquina de polimento automático	56
5.2	Microscópio ótico com aquisição digital de imagens da marca Zeiss . . .	57
5.3	Etapas realizadas na metodologia	57
5.4	Fotomicrografias de aços elétricos GNO coletadas nesse trabalho	59
6.1	Fotomicrografia de amostra da classe 0 - AE50-620-1min	66

6.2	FDOC de amostra da classe 0 - AE50-620-1m	66
6.3	Fotomicrografia de amostra da classe 0 - AE50-730-1000min	67
6.4	FDOC de amostra da classe 0 - AE-50%-730°-1000min	67
6.5	Fotomicrografia de amostra da classe 0 - AE50-730-100m	68
6.6	FDOC de amostra da classe 0 - AE50-730-100m	68
6.7	Fotomicrografia de amostra da classe 1 - AE-50%-840°-100m	70
6.8	FDOC de amostra da classe 1 - AE-50%-840°-100m	70
6.9	Fotomicrografia de amostra da classe 1 - AE-50%-900°-10min	71
6.10	FDOC de amostra da classe 1 - AE-50%-900°-10min	71
6.11	Fotomicrografia de amostra da classe 1 - AE-70%-840°-10min	72
6.12	FDOC de amostra da classe 1 - AE-70%-840°-10min	72
6.13	Fotomicrografia de amostra da classe 2 -AE-70%-840°-100min	74
6.14	FDOC de amostra da classe 2 - AE-70%-840°-100min	74
6.15	Fotomicrografia de amostra da classe 2 -AE-70%-840°-1000min	75
6.16	FDOC de amostra da classe 2 - AE-70%-840°-1000min	75
6.17	Fotomicrografia de amostra da classe 2 -AE-50%-840°-1000min	76
6.18	FDOC de amostra da classe 2 - AE-50%-840°-1000min	76
6.19	Gráfico de acurácia - Método Hold out	80
6.20	Gráfico de sensibilidade - Método Hold out	80
6.21	Gráfico de fscore - Método Hold out	82
6.22	Gráfico de precisão - Método Hold out	82
6.23	Gráfico de acurácia - Método Leane one out	88
6.24	Gráfico de sensibilidade - Método Leane one out	88
6.25	Gráfico de precisão - Método Leane one out	89
6.26	Gráfico de fscore - Método Leane one out	89
6.27	Diagrama de caixas dos tempos de extração	93

Lista de Tabelas

5.1	Composição química do aço elétrico de grão não orientado em estudo . .	54
6.1	Métricas obtidas por extração e classificação utilizando o método Hold out	78
6.2	Tabela de tempos em milisegundos para treino e teste dos classificadores utilizando o método Hold out	84
6.3	Resultado das métricas obtidas por extração e classificação utilizando o método Leave one out	86
6.4	Tabela de tempos em milisegundos para extração e classificação utilizando o método Leave one out	91
6.5	Métricas das 3 melhores classificações hold out	92
6.6	Métricas das 3 melhores classificações leave one out	92
6.7	Tempos de extração de dados das fotomicrografias	93
6.8	Matrizes confusão método Hold out	94
6.9	Matrizes confusão método Leave one out	95

Lista de abreviações

1. ABNT Associação Brasileira de Normas Técnicas;
2. AE Aço Elétrico;
3. FDOC Função de Distribuição de Orientação Cristalográfica;
4. GLCM Matriz de Co-ocorrência de Tons de Cinza (*Gray Level Co-occurrence Matrix*);
5. GNO Grão Não Orientado;
6. GO Grão Orientado;
7. ICA Inteligencia Computacional Aplicada;
8. KNN K Vizinhos mais Próximos (*K-Nearest Neighbor*);
9. LBP Padrões Binários Locais (*Local Binary Pattern*);
10. MLP Perceptron Multi Camadas (*Multi Layer Perceptron*);
11. PA Perdas Anômalas;
12. PDI Processamento Digital de Imagens;
13. PH Perdas por Histerese;
14. PP Perdas por corrente Parasita;
15. PS Perceptron Simples;
16. RBF Função Base Radial (*Radial Basis Function*);
17. RNA Redes Neurais Artificiais;
18. RP Reconhecimento de Padrões;

19. SR Sem Recozimento;
20. SVM Maquinas de Vetores de Suporte (*Support Vector Machines*).

Sumário

1	INTRODUÇÃO	1
1.1	Justificativa	2
1.2	Objetivos	4
1.2.1	Objetivo geral	4
1.2.2	Objetivos específicos	4
2	REVISÃO DA LITERATURA	5
2.1	Aços elétricos	5
2.2	Textura cristalográfica	8
2.2.1	Textura cristalográfica de aços elétricos	13
2.3	Recristalização	16
2.4	Propriedades magnéticas	20
2.5	Ferramentas computacionais aplicadas em engenharia e ciência dos materiais	24
3	EXTRAÇÃO DE ATRIBUTOS	27
3.1	Momentos de uma imagem	28
3.2	Matriz de co-ocorrência	30
3.3	Padrões binários locais	34
4	CLASSIFICADORES	36
4.1	Reconhecimento de padrões e Classificação	36

4.2	K-vizinhos mais próximos KNN	39
4.3	K-médias	43
4.4	Classificador Bayesiano	45
4.5	Máquinas de vetor de suporte	47
4.6	Redes neurais Perceptron multi camada	49
5	MATERIAIS E MÉTODOS	53
5.1	Materiais	53
5.1.1	Identificação das amostras	54
5.2	Métodos	54
5.2.1	Preparação metalográfica	55
5.2.2	Coleta e registro das fotomicrografias	55
5.2.3	Extração de características das fotomicrografias	60
5.2.4	Classificação das amostras com base em suas fotomicrografias	61
5.2.5	Validação dos resultados gerados utilizando a análise do especialista	62
6	RESULTADOS E DISCUSSÕES	64
6.1	Resultados metalúrgicos	65
6.1.1	Imagens classe 0 - Grãos recristalizados pequenos	65
6.1.2	Imagens classe 1 - Grãos recristalizados de tamanho médio	69
6.1.3	Imagens classe 2 - Grãos com crescimento anormal (recristalização secundária)	73
6.2	Resultados computacionais	77
6.2.1	Grupo 1 - Hold out	77
6.2.2	Tempos de classificação método hold out	83
6.2.3	Grupo 2 - Leave one out	85
6.2.4	Tempos de classificação método leave one out	90
6.2.5	Comparação entre métodos Hold out e Leave one out	92

6.2.6	Tempos de extração	93
6.2.7	Matrizes de confusão	94
7	CONCLUSÕES E CONTRIBUIÇÕES	96
7.1	Trabalhos futuros	97
	Referências Bibliográficas	99

Capítulo 1

INTRODUÇÃO

A crescente demanda mundial por energia elétrica, e os graves problemas ambientais decorrentes das emissões de CO_2 tornam necessário a adoção de medidas que vão desde a exploração de novos recursos da matriz energética, como os ventos, o sol e as ondas, até o desenvolvimento de tecnologias que permitam a otimização dos níveis de eficiência energética de máquinas e equipamentos. É forte a correlação entre o nível de desenvolvimento da atividade econômica de uma nação e o crescimento de sua demanda total de energia elétrica. O Motor elétrico é o principal responsável pelo funcionamento dessas máquinas e equipamentos, em virtude de seu baixo custo, simplicidade construtiva, facilidade no transporte e grande versatilidade na utilização para os mais diversos tipos de carga.

No que tange à otimização e eficiência, a pesquisa e o desenvolvimento de materiais empregados na construção de equipamentos elétricos se voltam para a diminuição das perdas elétricas desses materiais. Os aços elétricos de grão não orientado são largamente utilizados na construção de rotores e estatores que formam o núcleo de motores elétricos, e suas características microestruturais estão diretamente relacionadas ao desempenho eletromagnético desses motores. De forma geral os aços elétricos desempenham um papel fundamental na cadeia composta por geração, distribuição e utilização final de energia elétrica em virtude de sua ampla utilização na construção de núcleos de motores e trans-


formadores. Suas propriedades magnéticas são os principais fatores que justificam essa utilização, visto que não existe interesse em condução elétrica e sim no fluxo magnético induzido ([Brissonneau, 1984](#)), ainda nesse estudo o autor afirma que são aplicados grandes investimentos em pesquisa por parte dos fabricantes com o objetivo de desenvolver um aço elétrico que possa ser magnetizado com elevados níveis de indução, apresentando mínimas quantidades de perdas totais. Uma parte bastante relevante do consumo total de energia elétrica pode ser atribuído às perdas magnéticas dos aços elétricos, tornando essa a propriedade mais importante desse material. [Werner e Jaffee \(1992\)](#) estimaram que as perdas representaram cerca de 4,5% de toda a energia produzida nos Estados Unidos naquele ano. Os fatores econômicos e ambientais justificam plenamente os investimentos para o desenvolvimento de materiais mais eficientes empregados na construção dos núcleos dos motores, diminuindo as perdas por dissipação e o consequente desperdício de energia elétrica ([Stojakovic, 2008](#)). [Landgraf \(2002\)](#), em seu trabalho sobre o mercado de aços elétricos no Brasil, cita, para o ano de 1998, um mercado estimado em 200 milhões de dólares. [Melo et al. \(1982\)](#) afirmam que naquele ano a produção desse material foi dividida em 30 mil toneladas de aço elétrico de grão orientado e 300 mil toneladas de aço elétrico de grão não orientado.

1.1 Justificativa

Os aços elétricos são materiais ferromagnéticos que apresentam como características a fácil magnetização e a pequena retenção de magnetização residual, todavia ainda apresentam perdas magnéticas por dissipação de calor (Efeito Joule). As perdas magnéticas podem ser mensuradas através da análise da curva de histerese do material, [Bertotti \(1998\)](#) afirma que a área interna da curva de histerese tem uma relevante interpretação, pois mostra a quantidade de energia, durante um ciclo total, dissipada por efeito Joule.

A Figura [1.1](#) apresenta um gráfico contendo as perdas totais e suas componentes

Figura 1.1: Perdas totais e suas componentes anômala (Pa), parasítica (Pp) e histerética (Ph) para seis tipos de aços elétricos.



Fonte: Landgraf (2002)

anômala, parasítica e histerética para três aços silicosos contendo 0,5%Si, 2,0%Si e 3,0%Si, para um aço ABNT 1006 sem recozimento (SR), um aço ABNT 1006 com recozimento (CR) e um aço elétrico de grão orientado (GO). A análise da figura comprova o estudo de Bohn et al. (2004) ao ponto que o aço ABNT 1006 sem recozimento apresentou um valor de perdas totais da ordem de 18W/Kg, porem após seu recozimento essas perdas totais caíram para aproximadamente 10W/Kg em virtude das alterações benéficas em sua microestrutura. Campos (2000) afirma que discordâncias e contornos de grão dificultam a movimentação dos domínios magnéticos fazendo aumentar as perdas por histerese, o que confirma o fato do aço ABNT 1006 sem recozimento apresentar um valor elevado dessas perdas.

O desenvolvimento de aços elétricos mais eficientes é uma busca incessante no meio acadêmico e industrial com o objetivo de otimizar o desempenho eletromagnético. A caracterização desses aços quanto a sua eficiência pode ser realizada através do estudo de sua microestrutura, sua textura cristalográfica e de suas curvas de histerese magnéticas, para isso faz-se necessário a análise criteriosa por parte de um profissional experiente na área de engenharia metalúrgica e de materiais, entretanto, executar esta análise manualmente é uma tarefa sensível a interpretações subjetivas, é laboriosa e sujeita

às falhas decorrentes das limitações humanas, como cansaço ou fadiga, repetitividade de ações ou erros de análise. Existem *softwares* comerciais utilizados na análise da microestrutura e nas propriedades magnéticas de metais, contudo seus custos são elevados o que impossibilita o desenvolvimento de trabalhos acadêmicos e experimentais de baixo custo.

1.2 Objetivos

1.2.1 Objetivo geral

O presente trabalho tem por objetivo geral apresentar um estudo computacional baseado em processamento digital de imagens para classificar, quanto ao seu estado microestrutural, um aço elétrico de grão não orientado contendo 1,28% de silício, submetido a tratamentos térmicos para crescimento de grão, utilizando suas fotomicrografias.

1.2.2 Objetivos específicos

- Fazer a análise microestrutural, por microscopia óptica digital, do estado de recristalização do material após os tratamentos térmicos para crescimento de grão;
- Fazer a caracterização prévia do material no estado microestrutural de recristalização, após os tratamentos térmicos para crescimento de grão norteados pela textura cristalográfica do material;
- Aplicar os métodos de análise computacional nas classes atribuídas às fotomicrografias dos estados microestruturais de recristalização do material após os tratamentos térmicos para crescimento de grão;
- Identificar quais as combinações de extratores e classificadores são as mais indicadas para essas aplicações considerando taxas de acerto, confiabilidade e tempos de extração e classificação.

Capítulo 2

REVISÃO DA LITERATURA

Este capítulo apresenta os conhecimentos em engenharia e ciência dos materiais necessários ao desenvolvimento do trabalho. São abordados temas como microestrutura dos aços elétricos de grão não orientado, recristalização, textura cristalográfica e propriedades magnéticas desse material.

2.1 Aços elétricos

Os aços para fins elétricos são largamente utilizados na indústria mundial, ocupando lugar de destaque dentre os produtos siderúrgicos, segundo [Landgraf et al. \(2001\)](#), em 1999, o Brasil utilizou cerca de 300.000 toneladas desse material, majoritariamente na construção de núcleos de motores e transformadores. [Landgraf \(2002\)](#) em seu artigo afirma que a propriedade dos aços elétricos que torna possível a existência da maioria das máquinas elétricas como motores, geradores e transformadores, é a capacidade que esse aço tem de amplificar um campo magnético externo aplicado. Máquinas e equipamentos que utilizam motores elétricos ou ainda transformadores, tem seu desempenho energético afetado pelas perdas magnéticas e permeabilidade dos materiais utilizados na sua construção. [Landgraf et al. \(2001\)](#) afirmam ainda que a necessidade mundial de

conservar energia, dá ao estudo dos aços elétricos uma posição de destaque. Segundo seu trabalho, 50% da energia produzida em escala global é destinada aos motores de tração, e seus fabricantes tem buscado junto as siderúrgicas, desenvolver aços com melhores desempenhos eletromagnéticos no intuito de aumentar a eficiência dos motores.


De acordo com [Brissonneau \(1984\)](#) o aço elétrico ideal teria como característica principal a maior magnetização possível quando exposto ao menor campo magnético externo, apresentando mínimas quantidades de perdas totais. Os aços elétricos tem como característica a presença de Silício em sua estrutura, o que lhe garante maior resistividade elétrica e baixas perdas magnéticas. São produzidos através de processos de laminação a frio em tiras com espessura inferior a 2,0 milímetros e posteriormente submetidos ao tratamento térmico de recozimento com o objetivo de modificar sua microestrutura, obtendo grãos de maiores dimensões. Segundo [Landgraf \(2002\)](#) 1% do volume total de aços produzidos anualmente é utilizado por suas propriedades magnéticas.

Ainda segundo [Landgraf \(2002\)](#) os aços para fins elétricos são divididos em aços elétricos de grão orientado (GO) e aços elétricos de grão não orientado (GNO). Os aços elétricos GO tem excelentes propriedades magnéticas, contudo seu fluxo é unidirecional, tornando-o ideal para produção de transformadores, onde sua montagem permite alinhar o fluxo magnético no sentido longitudinal da chapa. Esses aços se beneficiaram do estudo de [Goss \(1934\)](#), que através da realização de um determinado procedimento conseguiu gerar uma textura cristalográfica (110)[001] em aços ao silício, essa componente de textura permite que o material apresente excelente permeabilidade magnética na direção de sua laminação. Os aços elétricos GO tem um custo de produção superior aos aços GNO e já foram amplamente estudados.

Os aços elétricos de grão não orientado são ideais para aplicações que necessitam de materiais com propriedades magnéticas iguais para qualquer direção considerada, característica conhecida como isotropia, seu custo de produção é inferior aos aços elétricos GO e sua utilização principal é na construção de rotores e estatores de motores elétricos

(Hubert et al., 2003). O estudo da microestrutura dos aços elétricos de grão não orientado oferece informações bastante relevantes acerca da eficiência energética desse material, pois o tamanho do seu grão é inversamente proporcional às perdas magnéticas por histerese, isto é: quanto maior o grão, menores serão essas perdas (Landgraf et al., 2001). Shimanaka et al. (1982) comprovou que existe um tamanho de grão ideal limitado entre $100\mu\text{m}$ e $150\mu\text{m}$, seu estudo afirma que com o aumento do tamanho do grão há uma contínua diminuição das perdas magnéticas por histerese, contudo as perdas magnéticas anômalas crescem, motivo pelo qual deve haver uma limitação para o crescimento do grão, a Figura 2.1 ilustra essa afirmação.

Figura 2.1: Influência do tamanho do grão nas perdas magnéticas totais para aços elétricos com 1,85% Si, 2,8% Si e 3,2% Si.



Fonte: Adaptado de Shimanaka et al. (1982)

Os aços elétricos GNO são divididos em duas classes distintas: os totalmente processados e os semiprocessados. Os aços elétricos GNO totalmente processados já são produzidos com as características ideais para sua aplicação final, sua textura já é de-


finida pela usina siderúrgica que entrega esse material na condição recozida. Os aços elétricos GNO semiprocessados são produzidos pelas siderúrgicas de modo a permitir que o usuário final possa executar o tratamento térmico de recozimento com a finalidade de alcançar o tamanho de grão definido por [Shimanaka et al. \(1982\)](#), após a estampagem da chapa em seu formato final. De acordo com [Campos \(2000\)](#), durante o recozimento executado pelo usuário final, há a formação da textura final, a descarbonetação e a eliminação das tensões residuais do material.

2.2 Textura cristalográfica

A maioria dos materiais em estado sólido incluindo metais, cerâmicas e minerais são compostos por estruturas policristalinas formadas por uma grande quantidade de microcristais, também conhecidos como grãos. Na ciência dos materiais, a textura cristalográfica é a distribuição das orientações dos cristais em um material policristalino. Quando a distribuição da orientação desses cristais é aleatória, afirma-se que o material não apresenta textura. [Freitas \(2003\)](#) afirma que a existência de textura confere aos materiais policristalinos propriedades diferentes para diferentes direções analisadas, isto é, o significado do termo textura está fortemente relacionado às propriedades anisotrópicas dos materiais. [Bresciani Filho et al. \(1991\)](#) afirmam que a presença de textura num agregado policristalino confere propriedades físicas e propriedades mecânicas diferentes para as diversas direções macroscópicas do metal, ou seja, conduz o material metálico a um comportamento anisotrópico. Nas Figuras [2.2a](#) e [2.2b](#) são mostradas representações de materiais com distribuição de grãos aleatória (sem textura) e com a apresentação de textura.

Figura 2.2: Textura cristalográfica

(a) Amostra de material com textura (b) Amostra de material sem textura




Fonte: Freitas (2003)

Segundo Freitas (2003) as várias etapas de processamento dos metais, como solidificação, deformação plástica e recristalização conduzem a formação de uma orientação preferencial onde determinados eixos cristalográficos posicionam-se de forma geométrica definida em relação às direções macroscópicas do corpo metálico. Engler e Randle (2009) afirmaram em seu estudo que a orientação cristalográfica, refere-se ao modo como os planos atômicos em um volume de cristal são posicionados relativamente a uma referência fixa. Esta característica aplica-se a todos os sólidos cuja estrutura é cristalina, incluindo minerais, cerâmicas, semicondutores, supercondutores e metais. Quase todos estes materiais são policristalinos, e as suas unidades componentes são referidos como cristais ou simplesmente grãos.

A representação e compreensão das orientações cristalográficas preferenciais dos materiais texturados apresenta um grau de complexidade, entende-se que a textura pode ser representada por uma orientação dos cristais considerada ideal chamada componente, próxima da qual um razoável número de grãos se agrupam (Freitas, 2003). No aço elétrico utilizado nesse trabalho, as componentes são paralelas ao plano da chapa, representadas pelo plano cristalino (hkl) e pela direção $[uvw]$ pertencente a esse plano. De acordo com Callister e Rethwisch (2007) as direções e planos cristalográficos são representados por

3 números inteiros ou índices, seus valores são determinados com base em uma célula cubica unitária composta por três eixos (x,y,z) , conforme a figura 2.3.


Figura 2.3: Célula cúbica unitária.



Fonte: Callister e Rethwisch (2007)

A Figura 2.4 mostra um plano (001) paralelo a direção de laminação, e uma direção cristalográfica [110] pertencente a esse plano, utilizando os índices temos a componente representada por um cubo rotacionado (Viana, 2001).

Figura 2.4: Componentes (001)[110] em uma chapa laminada.




Fonte: Viana (2001)

De acordo com Viana (2001), uma descrição mais completa de textura deve conter dados acerca da distribuição de suas orientações cristalográficas, informando o plano,


a direção e o volume de cada orientação presente, para isso utilizamos as Funções de Distribuição de Orientação Cristalográfica (FDOC). Esta função caracteriza a densidade de probabilidade de encontrar determinadas orientações em uma amostra de material (Freitas, 2003). Na FDOC a orientação do cristal é determinada através da rotação ao redor dos eixos x, y, z da célula unitária, também conhecidos por ângulos de Euler. De forma resumida, a FDOC cria uma relação entre a direção de laminação da amostra (DL), a direção transversal à direção de laminação (DT), a direção normal à direção de laminação (DN) com os eixos da célula unitária (x, y, z) através dos ângulos de Euler ($\varphi_1, \phi, \varphi_2$) conforme notação de Bunge (Bunge, 2013). A Figura 2.5 apresenta a amostra com os cristais antes das rotações com os ângulos de Euler (Stojakovic, 2008). A Figura 2.6 mostra os cristais devidamente orientados após a rotação.

Figura 2.5: Representação dos cristais antes da rotação.



Fonte: Freitas (2003)


Figura 2.6: Cristais rotacionados utilizando os ângulos de Euler.



Fonte: Freitas (2003)

Segundo Freitas (2003), a textura dos aços é normalmente representada utilizando apenas a seção de $\varphi_2=45^\circ$, de acordo com a notação de Bunge, pois no estudo da textura cristalográfica, essa seção possui as principais informações acerca de planos e direções cristalográficas desse material. Cada seção possui curvas de isovalor interpretadas com o auxílio de ábacos próprios. A Figura 2.7 mostra a FDOC de um aço carbono laminado a frio.

Figura 2.7: FDOC de aço carbono laminado a frio.




Fonte: [Freitas \(2003\)](#)

2.2.1 Textura cristalográfica de aços elétricos

A textura cristalográfica e o tamanho do grão são as características microestruturais mais importantes para as propriedades magnéticas dos aços elétricos ([Landgraf et al., 2001](#)), os autores afirmam em seu trabalho que a textura dos aços elétricos afetam diretamente o desempenho dos equipamentos que utilizam esse material em sua construção, isso ocorre em função da forte anisotropia das propriedades magnéticas, afirmando ser muito mais fácil a magnetização do ferro na direção $[100]$ do que em qualquer outra direção. Esses eixos de fácil magnetização com a direção $[100]$ são formados pelas arestas de um cubo paralelos ao plano de laminação da chapa. Segundo [Campos et al. \(2006\)](#) um dos grandes desafios para os produtores de aços elétricos de grão não orientado é obter a textura cristalográfica mais favorável às propriedades magnéticas, isso é possível através da diminuição da fração de componentes de textura indesejáveis como $[111]//DN$

e aumento do percentual de componentes favoráveis como $[100]//DN$ e $[100]//DL$, onde DL é a direção de laminação e DN a direção normal à chapa. A Figura 2.8 mostra as curvas de magnetização em três direções diferentes em um monocristal de ferro.


Figura 2.8: Curvas de magnetização de um monocristal de ferro nas direções $[100]$, $[110]$ e $[111]$.



Fonte: Landgraf et al. (2001)

Em busca da melhor textura para aços elétricos, Norman P. Goss ([Goss, 1934](#)) desenvolveu e patenteou um método de fabricação de aços elétricos de grão orientado que dá ao material excelente permeabilidade magnética na direção de laminação como resultado da formação de uma forte textura $(110)[001]$, denominada componente de textura Goss. [Kovac et al. \(2004\)](#) comprovaram a eficiência do estudo de Goss, afirmando que a textura $(110)[001]$ é comercialmente a melhor para aços elétricos de grão orientado. O processo produtivo desenvolvido por Goss é utilizado na fabricação de aços elétricos de grão orientado, exigindo que as máquinas e equipamentos que utilizam esse material sejam montados de modo que o fluxo magnético seja paralelo à direção de laminação da chapa, tendo como principal utilização a construção de transformadores. A figura 2.9 ilustra a formação da componente de textura Goss.

Figura 2.9: Formação de textura Goss.



Fonte: Repositório digital UFOP


Os aços elétricos de grão não orientado são utilizados em aplicações como os motores elétricos, neles o campo magnético é aplicado no plano da chapa, todavia o fluxo magnético muda constantemente de direção em virtude da aplicação de corrente alternada. A textura dos aços elétricos GNO não apresenta um componente único, mas vários componentes conhecidos como textura de fibra, dessa forma a textura ideal é a fibra que apresenta maior facilidade de magnetização, nesse caso a textura de fibra $\langle 100 \rangle$. Os fabricantes de aços elétricos GNO ainda estudam o desenvolvimento da textura de fibra ideal através de um processo industrialmente viável, buscando melhorar suas propriedades magnéticas. As pesquisas objetivam produzir uma textura $\langle 100 \rangle // \text{DN}$, ou seja, uma fibra $100 \langle 0vw \rangle$, também chamada de fibra- θ . Segundo [Kovac et al. \(2004\)](#), as vantagens desse tipo de textura para aços elétricos vêm sendo reconhecidas a várias décadas, enquanto isso não acontece, os fabricantes utilizam uma fibra em torno da componente Goss $(110)[001]$ que pode ser encontrada na fibra $\langle 110 \rangle // \text{DN}$ também chamada de fibra- ζ .

2.3 Recristalização

A deformação resultante dos processos de laminação a frio aplicados aos metais, geram defeitos em sua estrutura cristalina como mudança no formato e na orientação dos grãos adquirindo uma textura de deformação e aumento da área dos contornos de grãos por unidade de volume. Esses defeitos não apresentam estabilidade se submetidos à aplicação de calor, o que permite que tratamentos térmicos aplicados à esses metais depositem energia no interior do cristal deformado, desestabilizando os defeitos na rede cristalina gerados pela deformação (Padilha e Siciliano, 2005).

Padilha e Siciliano (2005) tratam a recristalização como uma transformação de fase irreversível, termicamente ativada, que ocorre por nucleação e crescimento, afirmando que as mudanças microestruturais ocorridas durante o recozimento de um metal deformado a frio tendem a diminuir a energia armazenada durante o processo de deformação, e acontecem através de mecanismos de rearranjo e eliminação de defeitos cristalinos. O tratamento térmico de recozimento à temperaturas elevadas aplicado ao metal deformado a frio, tende a resolver os defeitos da rede cristalina através do rearranjo das discordâncias, restaurando parcialmente a microestrutura do material. A Figura 2.10 ilustra esse processo. É importante salientar que a recuperação das propriedades e da microestrutura não é total, visto que a estrutura das discordâncias não é completamente removida (Freitas, 2011).


Figura 2.10: Representação esquemática do processo de rearranjo: (a) Arranjo de discordâncias em monocristal deformado por flexão, (b) rearranjo de discordâncias após o recozimento.



Fonte: [Padilha e Siciliano \(2005\)](#)

O recozimento do metal deformado plasticamente a frio através do processo de laminação, faz surgir um fenômeno chamado de recristalização. Nele novos grãos são formados dentro da estrutura deformada do metal, esses grãos crescem absorvendo os grãos menores gerando uma nova estrutura com baixo percentual de discordâncias, esse fenômeno específico é conhecido por recristalização primária ([Freitas, 2011](#)). O crescimento desses novos grãos ocorre principalmente no contorno dos grãos deformados, os grãos crescem em função da grande quantidade de energia interna gerada no material deformado, até consumir completamente essa região, a Figura 2.11 ilustra esse processo.


Figura 2.11: Estágios da recuperação em metal deformado plasticamente; (A) estrutura com discordâncias, (B) formação de células, (C) aniquilação de discordâncias nas paredes das células, (D) formação de subgrãos.



Fonte: [Humphreys e Hatherly \(2004\)](#)

A Figura 2.12 mostra a relação entre o tamanho do grão resultante da recristalização, o encruamento prévio do metal e a temperatura de recozimento adotada.

Figura 2.12: Diagrama de recristalização para ferro eletrolítico submetido ao recozimento por 1 hora.




Fonte: Adaptado de [Burgers \(1963\)](#)

A continuidade do recozimento nesse material pode levar ao crescimento ainda maior dos grãos, isso ocorre porque mesmo após a recristalização primária, o material apresenta contornos de grãos termodinamicamente instáveis, isso faz com que a estrutura já recristalizada passe a apresentar um crescimento anormal de grãos caracterizando a recristalização secundária. Esse crescimento acontece em função da continuação do processo de migração dos contornos de grão ([Humphreys e Hatherly, 2004](#)). De acordo com [Padilha e Siciliano \(2005\)](#), o tamanho do grão resultante tem maior dependência do grau de deformação plástica do material do que dos níveis de temperatura de recozimento. As Figuras 2.13 e 2.14 apresentam a ocorrência dos fenômenos de recristalização primária


e recristalização secundária para um aço elétrico de grão não orientado com 1,28% de silício, laminado a frio com redução de 50% em sua espessura.

Figura 2.13: Aço elétrico recozido apresentando grãos com crescimento anormal (recristalização secundária) e grãos de crescimento normal remanescentes (recristalização primária).



Fonte: [Freitas \(2011\)](#).

Figura 2.14: Aço elétrico recozido apresentando crescimento anormal de grão resultante da recristalização secundária.




Fonte: Freitas (2011).

2.4 Propriedades magnéticas

Materiais magnéticos, em especial o ferro, cobalto e níquel, são aqueles que tem a capacidade de interagir com campos magnéticos externos, essa interação pode ser a atração por ímãs ou a capacidade de permanecer magnetizado quando o campo magnético externo não mais é aplicado, essas características se devem ao fato de possuírem em sua estrutura domínios magnéticos, um material ferromagnético desmagnetizado tem seus domínios desorientados mutuamente, essa desorientação anula os efeitos magnéticos do material, todavia, ao se aplicar um campo magnético externo, os domínios se alinham magnetizando esse material conforme ilustrado na Figura 2.15. Para Bohn et al. (2004) a principal característica da fase ferromagnética é o alinhamento dos momentos magnéticos dos átomos constituintes do material. Ao ser retirado o campo magnético externo, o alinhamento desses domínios poderá permanecer ou não, mantendo uma magnetização residual ou cessando essa característica. Os materiais ferromagnéticos que apresentam

um campo magnético residual após a exposição à um campo magnético externo são conhecidos como ferromagnéticos duros, os materiais que não apresentam níveis significantes de retenção são conhecidos como ferromagnéticos moles.

Figura 2.15: (a) sem a aplicação de campo magnético externo, (b) com excitação magnética externa.



Fonte: [Gomes \(2007\)](#)

As propriedades magnéticas dos aços elétricos estão diretamente relacionadas a sua microestrutura. A influencia do tamanho do grão nas perdas magnéticas dos aços elétricos se justifica pela interação entre as superfícies dos contornos de grão e as paredes dos domínios magnéticos ([Campos et al., 2006](#)). Esses aços tem como característica principal a indução de fluxo magnético, são considerados materiais magneticamente moles, isto é, se magnetizam muito facilmente apresentando níveis muito baixos, ou praticamente nulos, de magnetização residual. As perdas magnéticas desses aços representam uma parte considerável do consumo total de energia elétrica. Estudos indicaram que em 1992, nos Estados Unidos, o desperdício de energia elétrica oriundo das perdas chegou a 4,5% do consumo total daquele país([Werner e Jaffee, 1992](#)). Dessa forma, é de fundamental importância o desenvolvimento de estudos e pesquisas, aplicados ao controle dos processos de fabricação dos aços, visando a diminuição das perdas magnéticas desses materiais.

As perdas magnéticas totais que ocorrem no ferro, P_t , são divididas em três tipos:

perdas histeréticas, P_h , perdas parasíticas, P_p (em função das correntes de Foucault) e perdas anômalas, P_a (perdas em excesso), de acordo com a Equação 2.1. A componente de perdas histeréticas é usualmente medida através do calculo da área interna da curva de histerese, sendo o restante correspondente a soma das perdas anômalas e parasíticas (Chin e Wernick, 1980).

$$P_t = P_h + P_p + P_a \quad (2.1)$$

Segundo Bohn et al. (2004), as perdas parasíticas podem ser reduzidas com o uso de altos teores de silício, o que tornaria o custo final do aço bastante elevado, essa componente de perda pode ser calculada pela expressão clássica da Equação 2.2 (Bozorth, 1951), com a qual é possível calcular a dissipação de energia devido à circulação, no interior do material, das correntes elétricas parasíticas induzidas pela variação do fluxo.

$$P_p = \frac{(\pi * B * f * e)^2}{6 * d * \rho} \quad (2.2)$$

onde:

P_p = perdas parasíticas (W/Kg);

e = espessura da lâmina - (mm);

f = frequência de ensaio - (Hz);

B = indução máxima do ensaio - (T);

d =densidade - (kg/m^3 , ou $10^3 \text{ g}/\text{cm}^3$);

ρ = resistividade elétrica - ($\mu\Omega\text{m}$, ou $10^2\mu\Omega\text{cm}$).


A variação da espessura da chapa tem influencia direta nessa componente de perda. Com a espessura maior tem-se um aumento no percurso das correntes parasitas aumentando-se essas perdas. Além disso a aplicabilidade dessa equação para o cálculo das perdas

parasíticas é limitado à frequências abaixo de 500Hz.

[Bohn et al. \(2004\)](#) afirma que as perdas histeréticas tem forte correlação com a microestrutura dos aços, beneficiando-se sobretudo do aumento no tamanho do grão, além das reduções dos teores dos elementos formadores de inclusões não metálicas, e da melhora da orientação dos cristais dentro da chapa.

[Bertotti \(1998\)](#) afirma que as perdas magnéticas podem ser mensuradas pela área interna da sua curva de histerese, essa curva representa a quantidade de energia dissipada, de forma irreversível, durante um ciclo completo de magnetização, tal perda acontece em função do efeito Joule. De forma análoga [Hug et al. \(1997\)](#) indica em seu artigo que a quantidade de energia dissipada por ciclo, expressa em J/m^3 , pode ser obtida através do calculo da área interna da curva de histerese, essa área interna representa a perda de energia magnética por unidade de volume de material. O alinhamento de domínios faz com que os níveis de magnetização desse material aumentem até alcançar o nível de saturação, ao chegar a esse nível, uma quantidade de energia é acumulada como mostra a Figura 2.16. A partir desse ponto de saturação, o aumento da intensidade do campo externo não produzirá nenhuma mudança apreciável nos níveis de magnetização do aço elétrico. Ao diminuir a intensidade do campo magnético aplicado, os níveis de magnetização induzidos no aço elétrico diminuem, entretanto a linha da curva de histerese que representa essa diminuição não retorna sobre a linha ascendente, a área interna da figura formada pelas linhas ascendente e descendente denotam dissipação de energia.

Figura 2.16: Formação da curva de histerese.



Fonte: [Freitas \(2011\)](#)

2.5 Ferramentas computacionais aplicadas em engenharia e ciência dos materiais


[Cortez et al. \(2009\)](#) utilizaram com sucesso, redes neurais multi-camadas na segmentação da microestrutura a partir de imagens metalográficas. Já [de Albuquerque et al. \(2011\)](#) desenvolveram uma solução computacional para segmentação das microestruturas do ferro fundido branco hipoeutético baseado em morfologia matemática. [Papa et al. \(2010\)](#) propuseram uma abordagem de segmentação rápida de imagens de ferro fundido nodular, cinzento e maleável utilizando os classificadores OPF (Optimum-Path-Forest) e SVM (Support Vector Machines). [Cavalcante et al. \(2009\)](#) aplicaram com sucesso técnicas de processamento de imagem na análise automática da quantidade e do tamanho do grão em imagens metalográficas.

[Reboucas Filho et al. \(2015b\)](#) desenvolveram um sistema computacional utilizado na classificação supervisionada para a montagem automática de mosaicos formado por fotomicrografias de materiais metálicos. A análise de imagens metalográficas por muitas vezes não se resume a um único ponto específico, em vários casos se faz necessário um es-

tudo das regiões vizinhas àquela inicialmente analisada, dando um enfoque macrográfico. Isso pode ser observado em análises metalográficas de soldas, nesse caso, além da análise micrográfica focada nos pontos em estudo, geralmente se faz necessário uma análise das Zonas Termicamente Afetadas, buscando as imagens adjacentes àquela zona. Para que essa análise macrográfica seja realizada, um mosaico de fotomicrografias é montado. Essa montagem é feita de forma manual anexando uma imagem a outra, exigindo um profissional especializado, e ainda sujeita às várias limitações inerentes a condição humana, como cansaço, fadiga, repetibilidade ou distrações. O sistema desenvolvido por [Reboucas Filho et al. \(2015b\)](#) utiliza o método SIFT (Scale Invariant Feature Transform) além de técnicas de reconhecimento de padrões e processamento e análise digital de imagens para a montagem automática dos mosaicos, permitindo uma análise macroscópica ampla sem a necessidade da montagem manual dos mosaicos realizada por especialistas, conferindo agilidade, precisão e evitando os erros oriundos da condição humana.

Em seu trabalho, [Gomes e Paciornik \(2005\)](#) desenvolveram um sistema computacional utilizado em Engenharia e ciência dos materiais, que tem por finalidade classificar amostras de ferro fundido com base na análise de seus veios, lamelas ou nódulos. A norma ISO 945 de 2008 fala da classificação por análise visual do grafite presente na microestrutura dos ferros fundidos, segundo a norma esse material está dividido em seis classes distintas de acordo com a Figura 2.17. Cada uma das figuras apresentadas pela norma passou pelo processo de extração de atributos, suas características mais representativas geraram os modelos utilizados para a construção do conjunto de treinamento, um classificador então é o responsável por categorizar novas imagens de ferros fundidos em uma das seis classes, com base no vetor de características dessas novas imagens e nas informações *aprendidas* durante o processo de treinamento do software.

Figura 2.17: Classificação de ferro fundido com base na análise visual da grafita: Norma ISO 945 2008



Fonte: [Gomes \(2007\)](#)

Capítulo 3

EXTRAÇÃO DE ATRIBUTOS

A extração de atributos em um sistema de visão computacional consiste em extrair atributos significativos das regiões de interesse da imagem resultante do processo de segmentação, pós-processamento, ou como no caso desse trabalho, diretamente da imagem original em tons de cinza. Para [Pratt \(1991\)](#), os atributos extraídos de uma imagem evidenciam as diferenças e similaridades entre os objetos que as compõem. Serão medidas características como tamanho, forma, textura, posição, curvatura ou ocorrência de determinadas formas geométricas, resultando em dados quantitativos que serão utilizados para discriminar cada imagem no processo de classificação por meio da aprendizagem de máquina ([Jain et al., 2000](#)).

São diversos os métodos de extração de características utilizados em PDI, e assim como nas etapas anteriores, não existe uma resposta genérica que possa ser utilizada para qualquer problema, o ideal é que sejam executados testes com alguns métodos distintos de modo a determinar qual o mais eficiente para o problema específico. segundo [Trier et al. \(1996\)](#) a escolha das técnicas corretas é um fator de grande importância para que o sistema consiga um desempenho satisfatório e taxas elevadas de confiabilidade. Esses dados extraídos são geralmente organizados no formato de um vetor de características que serão utilizados posteriormente na etapa de classificação de padrões, que neste trabalho


definirá a qualidade das propriedades magnéticas de aços elétricos GNO. Os extratores de atributos utilizados nesse trabalho foram Momentos Centrais, Momentos Estatísticos, Momentos Invariantes (Momentos de Hu), Padrões Binários Locais (Local Binary Pattern, LBP) e Matriz de Co-ocorrência (Gray Level Co-occurrence Matrix, GLCM)

3.1 Momentos de uma imagem

De maneira geral, os momentos de uma imagem são caracterizados por valores numéricos calculados e extraídos da imagem, que descrevem a distribuição dos pontos que constituem as regiões de interesse. Permitem o cálculo da área de um objeto, de seu centróide, ou ainda identificar um determinado objeto mesmo que tenha sofrido mudança de rotação, escala ou translação

Momentos estatísticos realizam a extração de atributos com base na distribuição dos níveis de cinza da imagem, o cálculo é realizado com base no histograma dessa imagem e o resultado é a distribuição estatística desses níveis de cinza ([Gonzalez e Woods, 2000](#)). Os atributos extraídos descrevem a distribuição espacial dos pontos contidos na imagem ou em uma região específica de interesse ([Wong et al., 1995](#)). O histograma da imagem é uma ferramenta bastante utilizada nas várias etapas do PDI, apresenta dados estatísticos sobre o contraste da imagem, os níveis de iluminação e a distribuição dos pixels ([Traina et al., 2003](#); [Theodoridis e Koutroumbas, 2003](#)). O gráfico do histograma é plotado com o eixo vertical apresentando a probabilidade de ocorrência dos tons de cinza que compõem a imagem, enquanto que o eixo horizontal apresenta a intensidade dos pixels distribuídos em 256 tons de cinza ([Gonzalez e Woods, 2000](#)). A Figura 3.1 apresenta o histograma de duas imagens digitais, em (a) temos a imagem original, a Figura (b) apresenta o histograma dessa imagem, a Figura (c) apresenta a imagem resultante da equalização do histograma e a Figura (d) plota o histograma equalizado.

Figura 3.1: Exemplo de imagens digitais e seus respectivos histogramas.



Fonte: [Marques Filho e Neto \(1999\)](#)

Os momentos centrais possibilitam a descrição da forma do objeto, isso ocorre em função da sua invariância a translação ([Czachorski et al., 2011](#)), sua principal referencia na formação dos atributos é o centro de gravidade do objeto, e por esse motivo são invariantes à translação, contudo ainda são dependentes da escala e rotação.

A variação das características dos objetos quanto à escala ou rotação é um dos principais problemas de um sistema de classificação. Proposto pelo pesquisador Ming-Kuei Hu da Syracuse University ([Hu, 1962](#)) os momentos invariantes, também conhecidos por momentos de Hu, utilizam como princípio o reconhecimento e extração independentemente da orientação, tamanho e posição do objeto, seu vetor de atributos resultante é gerado a partir de sete equações matemáticas que permitem a descrição de figuras geométricas planas baseadas nos momentos invariantes bidimensionais ([Yang et al., 2011](#); [Licciardi et al., 2012](#); [Flusser et al., 2015](#)).

$$\Phi_1 = \eta_{20} + \eta_{02} \quad (3.1)$$

$$\Phi_2 = (\eta_{20} - \eta_{02})^2 + 4\eta_{11}^2 \quad (3.2)$$

$$\Phi_3 = (\eta_{30} - \eta_{12})^2 + (3\eta_{21} - \eta_{03})^2 \quad (3.3)$$

$$\Phi_4 = (\eta_{30} - \eta_{12})^2 + (3\eta_{21} - \eta_{03})^2 \quad (3.4)$$

$$\begin{aligned} \Phi_5 = & (\eta_{30} - 3\eta_{12}) + (\eta_{30} - \eta_{12})[(\eta_{30} - \eta_{12})^2 - 3(\eta_{21} - \eta_{03})^2] \\ & + (3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \end{aligned} \quad (3.5)$$

$$\begin{aligned} \Phi_6 = & (\eta_{20} - \eta_{02})[(\eta_{30} - \eta_{12})^2 - (\eta_{21} - \eta_{03})^2] \\ & + 4\eta_{11}(\eta_{30} - \eta_{12})(\eta_{21} - \eta_{03}) \end{aligned} \quad (3.6)$$

$$\begin{aligned} \Phi_7 = & (3\eta_{21} - \eta_{03})(\eta_{30} - \eta_{12})[(\eta_{30} - \eta_{12})^2 - 3(\eta_{21} - \eta_{03})^2] \\ & - (\eta_{30} - 3\eta_{12})(\eta_{21} - \eta_{03})[3(\eta_{30} - \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \end{aligned} \quad (3.7)$$

3.2 Matriz de co-ocorrência


[Haralick \(1979\)](#) propôs um método de extração de características baseados na textura da imagem. A posição dos pixels em relação aos outros é uma informação de relevante importância para a descrição da textura de uma imagem, e a textura, por sua vez, é uma das principais características no reconhecimento de objetos ou regiões de interesse

de uma imagem, e pode ser definida como variações locais em valores de pixels que se repetem de forma aleatória ou regular no objeto de interesse da imagem (Pedrini e Schwartz, 2008). Gonzalez e Woods (2000) definem textura como um conjunto de padrões perceptíveis pelo olho humano, presentes nas superfícies físicas e que trazem consigo informações como rugosidade e suavidade. Haralick et al. (1973) descrevem textura como a propriedade inata de praticamente todas as superfícies, que contém informações importantes sobre seu arranjo estrutural e sua relação com o ambiente circundante. O método proposto por Haralick (1979) se utiliza de recursos decorrentes de cálculos de matrizes de co-ocorrência (GLCM - Gray level co-occurrence matrix) que servem de base para preparação de medidas estatísticas conhecidas como descritores Haralick. Essas matrizes realizam a contagem da quantificação de diferentes níveis de cinza (Ramalho et al., 2014; Reboucas Filho et al., 2015a). A matriz GLCM é o ponto de partida para a extração de diversos descritores estatísticos. Segundo Haralick et al. (1973) 14 medidas estatísticas podem ser extraídas da GLCM, porém a quantidade final de características pode variar, dentro desse limite, em função da imagem.

De acordo com Baraldi e Parmiggiani (1995) essa técnica permite analisar as co-ocorrências existentes entre pares de pixels relacionados através de uma distância definida d conhecida como espaçamento entre pixels, em uma determinada direção θ que pode assumir os valores de 0° , 45° , 90° e 135° , conforme ilustra a Figura 3.2:

Segundo Billy et al. (2006) vários descritores texturais são disponibilizados após a definição da matriz de co-ocorrência, sua construção ocorre através de uma célula formada por (i, j) que registra a frequência de ocorrência de dois pixels na imagem separados por uma distância d e funciona como um contador, os valores de intensidade dos dois pixels são i e j respectivamente. A Figura 3.3 mostra à esquerda, uma imagem f com duas regiões de intensidades 1 e 2 com um pixel de distância entre elas. Assim, se $d = 1$ que representa o pixel imediatamente a direita, a matriz de co-ocorrência $\mathbf{G}$ tem sua posição $(1, 2)$ incrementada para 2, indicando a ocorrência de 2 pixels com cor 1 e 2


Figura 3.2: Ângulos utilizados no cálculo das matrizes de co-ocorrência



Fonte: Baraldi e Parmiggiani (1995)

separados pela distância d . Esse processo é repetido até que a matriz de co-ocorrência $\mathbf{G}$ esteja completa.

Figura 3.3: Primeiros passos do algoritmo gerador de uma matriz GLCM.



Fonte: Mathworks (2016)

Os principais descritores texturais gerados pela matriz GLCM são:

Variância : A variância mede a diferença entre os valores dos tons de cinza e a média desses valores, é uma medida de heterogeneidade da textura. (Equação 3.8).

$$Variância = \sum_{i=0}^{N_g} \sum_{j=0}^{N_g} (i - \mu^2) G(i, j) \quad (3.8)$$

Entropia : A entropia mede os níveis de desorganização ou desordem dos padrões de cinza que formam a imagem. (Equação 3.9).

$$Entropia = - \sum_{i=0}^{N_g} \sum_{j=0}^{N_g} P(i,j) \text{Log}_2[G(i,j)] \quad (3.9)$$

Homogeneidade : A homogeneidade é uma medida que denota a semelhança entre os níveis de cinza que formam a imagem (Equação 3.13).

$$Homogeneidade = \sum_{i=0}^{N_g} \sum_{j=0}^{N_g} \frac{G(i,j)}{1 + |i - j|^2} \quad (3.10)$$

Energia : A medida de energia tem a função de avaliar a uniformidade da textura da imagem, é também conhecida como segundo momento angular (Equação 3.11).

$$Energia = \sqrt{\sum_{i=0}^{N_g} \sum_{j=0}^{N_g} G(i,j)^2} \quad (3.11)$$

Contraste : A medida de contraste indica as mudanças abruptas dos níveis de cinza na imagem (Equação 3.12).

$$Contraste = \sum_{i=0}^{N_g} \sum_{j=0}^{N_g} |i - j|^2 G(i,j) \quad (3.12)$$

Correlação : Indica as correlações entre pixels vizinhos. (Equação 3.13).

$$Correlação = \sum_{i=0}^{N_g} \sum_{j=0}^{N_g} \frac{(i - \mu_i)(j - \mu_j)}{\sigma_i^2 \sigma_j^2} \quad (3.13)$$

Para essas equações o valor constante na coordenada (i,j) da matriz de co-ocorrência normalizada é representado por $G(i,j)$, enquanto que os diferentes padrões de cinza da imagem são representados por N_g , a média e desvio padrão são representados por μ_i , μ_j , σ_i , e σ_j respectivamente, para a linha i e coluna j da matriz de co-ocorrência.

As características de textura apresentadas pelo extrator GLCM são obtidas através de sua representação normalizada, essa normalização pode ser calculada pelo número de vezes em que tal co-ocorrência acontece dividido pela total de combinações possíveis, onde L denota o nível de cinza máximo presente na imagem, a Equação 3.14 mostra esse calculo.


$$P_{i,j} = \frac{P(i,j)}{\sum_{i=0}^L \sum_{j=0}^L P(i,j)} \quad (3.14)$$

3.3 Padrões binários locais

Ojala et al. (1996) propuseram um método para representação de texturas baseado em códigos binários locais chamado LBP (Local Binary Patterns), esse método tem como fundamentação a atribuição de um rótulo para cada pixel da imagem a partir de uma limiarização adaptativa local resultando em um número binário para cada pixel, o método demonstrou excepcional precisão em sistemas destinados a reconhecimento facial (Ahonen et al., 2006). O extrator LBP tem como característica sua robustez e sua resistência à influência das mudanças na escala dos tons de cinza causadas por variações de iluminação, esse descritor comumente apresenta grande eficiência na extração de atributos apresentando baixos níveis de complexidade computacional. Suas aplicações voltadas à classificações se estendem por áreas diversas como em extração de atributos e classificação de tecidos tumorais (Al-Kadi, 2015) (Linder et al., 2012), detecção de lesões em imagens de mamografias (de Sampaio et al., 2015), e reconhecimento de face (Luo et al., 2013) (Yang e Chen, 2013).

O cálculo original do LBP indica que o valor de um pixel na posição $V_0 = (x,y)$ é calculado a partir de um conjunto contendo P amostras distanciadas e distribuídas de forma igual sobre uma circunferência de raio R circunscrita com V_0 conforme ilustrado na Figura 3.4.


Figura 3.4: Montagem do LBP para diferentes valores de P e R



Fonte: Liela Khobanizad (2016)

O princípio básico do extrator LBP continua sendo a comparação de cada pixel com sua vizinhança, a Figura 3.5 ilustra a geração do código. A lógica para formação do algoritmo apresenta uma matriz quadrada de pixels de ordem 3, onde um valor binário 1 é atribuído quando o valor do pixel central V_0 for menor ou igual ao do pixel vizinho V_i e 0 quando o valor do pixel central V_0 for maior que o valor do pixel vizinho, Figura 3.5(b), gerando uma matriz binária Figura 3.5(c). Após essa binarização dos pixels da vizinhança o resultado final do código LBP é obtido através do somatório dos valores da multiplicação dos valores dos pixels da vizinhança por uma matriz de pesos em que cada peso da matriz é obtido pelo fator de exponenciação de valor 2 Figura 3.5(d).

Figura 3.5: Lógica de construção do algoritmo LBP.



A Equação 3.15 apresenta a fórmula para o calculo do extrator de atributos baseado em Padrões Binários Locais.

$$N_{LBP} = \sum_{i=1}^8 s(E_i) \times 2^{i-1} \quad (3.15)$$

Capítulo 4

CLASSIFICADORES

O processamento computacional realizado para a classificação dos aços elétricos segue uma sequência dividida nas seguintes etapas: aquisição de imagens, extração de atributos, reconhecimento de padrões, classificação e validação dos classificadores.

De acordo com [Gonzalez e Woods \(2000\)](#) após a aquisição das imagens, os passos seguintes de processamento e análise digital de imagens podem ser implementados em forma de algoritmo. O processamento digital de imagens (PDI) se utiliza de técnicas e algoritmos que tem por função melhorar ou modificar o aspecto visual de imagens digitais, para [Gomes \(2007\)](#) pode ser definido ainda como o conjunto de técnicas que utiliza operações matemáticas para alterar os pixels de imagens digitais. [Gonzalez e Woods \(2000\)](#) afirmam que o processamento digital de imagens tem duas aplicações principais: melhorar informação visual para interpretação humana e o processamento de dados de imagens para percepção automática através de máquinas.

4.1 Reconhecimento de padrões e Classificação


O constante desenvolvimento de ferramentas e recursos computacionais, tornou possível o projeto e desenvolvimento de complexos sistemas de classificação e reconhecimento

de padrões, utilizados para as mais diversas finalidades, como o reconhecimento facial (Guo et al., 2000), reconhecimento de fala ou padrões de escrita (Justino et al., 2003), além de amplas utilizações em campos como a medicina (Furey et al., 2000), a robótica e a estatística. Segundo Theodoridis e Koutroumbas (2003), o reconhecimento de padrões é um dos principais componentes de qualquer sistema de tomada de decisões. Ainda de acordo com Theodoridis e Koutroumbas (2003), reconhecimento de padrões é um campo da ciência da computação que tem por função classificar ou agrupar objetos em categorias com base em suas características. Para Duda et al. (2012), o reconhecimento de padrões tem por função a construção de um modelo simples para a representação de um conjunto de dados através de suas características mais representativas possibilitando sua divisão em categorias. A abordagem adotada no desenvolvimento do presente trabalho utiliza técnicas de reconhecimento de padrões para classificar os pixels ou regiões específicas de fotomicrografias dos aços elétricos estudados.

Reconhecer padrões significa classificar variáveis em categorias, que podem ser definidas pelo programador do sistema ou aprendidas pelo programa com base em informações do próprio sistema. Connell e Jain (2001) afirmam que existem dois métodos principais de classificação empregados para reconhecimento de padrões: a classificação supervisionada e a não supervisionada, nos dois métodos duas etapas são necessárias, o treinamento ou aprendizagem e a classificação (Moreira, 2005). De acordo com Braga et al. (2000) a fase de treinamento tem por objetivo regular os parâmetros livres da máquina de modo a localizar as relações entre os pares entrada e saída.

Na classificação supervisionada as classes são definidas pelo projetista do sistema, e as variáveis ou padrões de entrada serão distribuídos dentro dessas classes. O operador insere exemplos de classes previamente estabelecidas que são utilizadas para treinar o sistema. Na Figura 4.1 temos a representação de um espaço bidimensional contendo 3 classes conhecidas distintas, é possível classificar a amostra com base na relação de proximidade das características da amostra com os objetos pertencentes a essa classe. A


Figura 4.1: Classificação supervisionada.

Fonte: [Gomes \(2007\)](#)

classificação supervisionada tende a ser mais precisa que a não supervisionada pelo fato de já contar com informações das classes estudadas como a distribuição de probabilidades ([Moraes, 1992](#)).

No método de classificação não supervisionada não é inserido no sistema nenhuma informação acerca das classes as quais as amostras pertencem, os padrões são definidos por limites ou fronteiras entre as classes, embasando-se no princípio de que o algoritmo é responsável por identificar as classes contidas no conjunto de dados utilizando-se para isso de técnicas de agrupamento. A Figura 4.2 mostra outro conjunto de objetos em um espaço bidimensional, porém agora não há informações acerca das características dos objetos e suas classes, aqui o sistema procura por amostras com características similares e os agrupa em categorias.

Figura 4.2: Classificação não supervisionada.

Fonte: [Gomes \(2007\)](#)

Em geral são realizadas combinações de diferentes abordagens de classificadores para a resolução de um problema, não existindo uma resposta otimizada ou pré definida, segundo [Gonzalez e Woods \(2000\)](#) a solução específica para um determinado problema pode ser completamente ineficaz para um outro. Os classificadores utilizados nesse trabalho foram KNN, K-means, Bayes, MLP e SVM.


4.2 K-vizinhos mais próximos KNN

O classificador KNN (K-Nearest Neighbors) é um dos algoritmos de classificação mais simples, eficiente e versátil. O método foi descrito em 1950, todavia somente 10 anos depois ganhou notoriedade em função do desenvolvimento de computadores com maior poder de processamento ([Cover e Hart, 1967](#)). O princípio utilizado por esse classificador é baseado na distancia dos exemplos de treinamento no espaço de características, analisando os padrões dos vizinhos mais próximos e aplicando métricas de distancia na classificação, sendo geralmente a distancia Euclidiana a mais utilizada ([Duda et al., 2012](#)).

O processo de classificação realizado pelo KNN pode ser definido por um conjunto D de treinamento, em que cada elemento de D é uma tupla $(x_1, x_2, \dots, x_n, c)$, onde c denota a classe à qual a tupla é pertencente $(x_1, \dots, x_n)$. A tupla $(x_1, \dots, x_n)$ pode ser vista como um ponto num espaço n -dimensional. Portanto, eles têm uma noção de distância. Seja $Y = (y_1, \dots, y_n)$ uma nova tupla, ainda não classificada. O classificador kNN calcula as distâncias de Y para todas as tuplas de treinamento e considera-se as k tuplas de treinamento mais próximas de Y , após esse calculo o classificador verifica qual a classe de k vizinhos mais frequente e aloca nessa classe a amostra desconhecida (Cover e Hart, 1967).

A distância entre as amostras de treino e teste é calculada utilizando uma medida de similaridade, após isso as k amostras de treino mais próximas, isto é, mais similares são selecionadas, a amostra é classificada de acordo com o critério de agrupamento das categorias das k amostras de treino selecionados na etapa anterior, K é a quantidade de vizinhos mais próximos que serão analisados pelo classificador KNN, este procura K -vizinhos do conjunto de treinamento que apresentem a menor distancia do objeto a ser classificado, e esse pertencerá à classe predominante dentre os K -vizinhos analisados (Bezdek et al., 1986). O valor de K é um parâmetro livre, previamente definido pelo programador que poderá alterá-lo de modo a conseguir taxas de acerto mais elevadas na classificação. A Figura 4.3 mostra um exemplo da utilização do classificador KNN com amostras divididas em 3 classes e 2 amostras de classes desconhecidas, o classificador encontra os K -vizinhos mais próximos de cada amostra e dentre esses vizinhos encontra a classe mais representativa Gnecco et al. (2001).

Figura 4.3: Método de classificação KNN.



Fonte: [Gnecco et al. \(2001\)](#)


Existem várias métricas para o cálculo da distância de similaridade entre dois pontos. Considerando $X = (x_1, x_2, \dots, x_n)$ e $Y = (y_1, y_2, \dots, y_n)$ dois pontos pertencentes à $\mathbb{R}^n$ as métricas mais utilizadas pelo classificador são:

- Distância Euclidiana: $d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$;
- Distância Manhattan: $d(x, y) = \sum_{i=1}^n |x_i - y_i|$.
- Distância Minkowsky: $d(x, y) = \left(\sqrt[n]{\sum_{i=1}^n (|x_i - y_i|^n)} \right)^{\frac{1}{n}}$;
- Distância Mahalanobis: $d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$;


As Figuras 4.4a e 4.4b mostram aplicações do cálculo das distancias Euclidianas em um espaço bidimensional e tridimensional respectivamente.

Figura 4.4: Cálculo da distancia Euclidiana.

(a) espaço bidimensional




(b) espaço tridimensional

Fonte: [Falcão \(2005\)](#)

4.3 K-médias

O classificador K-Means, também conhecido por K-médias, é o método mais simples do grupo de classificação não supervisionada, ele classifica os dados de acordo com as próprias informações, sem a necessidade de nenhuma pré-classificação ou supervisão, se utilizando para isso do conceito de clusters (agrupamentos). Cluster pode ser definido como um conjunto de amostras, na qual cada amostra está mais perto ou é mais similar ao centroide dentro do cluster do que qualquer outro centroide fora, resumidamente podemos definir cluster como a organização de objetos similares em grupos distintos, Figura 4.5.


Figura 4.5: Organização de clusters.



Fonte: [Bishop \(2006\)](#)

O algoritmo divide o conjunto de dados que serão classificados em K-agrupamentos e define um centróide que será o representante de cada grupo de dados (Bishop, 2006), esses centróides são os vetores de atributos. Os padrões serão classificados utilizando métricas de distancia de acordo com o centróide mais próximo, associando K padrões a cada centróide. Ao final cada centróide receberá o rótulo da classe com maior ocorrência de associação com seus K padrões.

Figura 4.6: Passos para geração do algoritmo k-means.



Fonte: Falcão (2005)

As etapas para geração do algoritmo K-means estão ilustrados nas Figuras 4.6a, 4.6b, 4.6c e 4.6d. Na etapa 1 os objetos são apresentados em um plano bidimensional, na etapa

2 os centroides são inseridos aleatoriamente, na etapa 3 são calculadas e aplicadas as métricas de distancia atribuindo a cada objeto do cluster o centroide mais próximo, na etapa 4 os centroides são recalculados, após esse processo, as etapas 3 e 4 são repetidas até que não haja mudança nos centroides.

4.4 Classificador Bayesiano

O classificador Bayesiano faz parte do grupo de classificação supervisionada, e é conhecido por seu bom desempenho. O método tem por fundamento a utilização de técnicas estatísticas, classificando um objeto com base na probabilidade deste objeto pertencer a uma determinada classe. É um método de classificação supervisionada em que o classificador calcula a probabilidade condicional do objeto pertencer a uma classe e aloca o objeto à classe que obteve a maior probabilidade ([Domingos e Pazzani, 1997](#)). Esse método de classificação apresenta uma aprendizado estatístico e incremental em que cada amostra de treino pode aumentar ou diminuir a probabilidade de uma hipótese estar correta. São indicados para grande volumes de dados, como em *Data mining* pois produzem resultados rapidamente com altos níveis de correção. São utilizados conceitos como probabilidade condicional, probabilidade a priori e probabilidade a posteriori no teorema de decisão Bayesiano para calcular probabilisticamente as chances de vários objetos pertencerem a mesma classe ([Mitchell, 1997](#)), assumindo que o valor de um atributo tem forte dependência do valor de outro. Foram utilizadas com sucesso em Processamento digital de imagens ([Máximo e Fernandes, 2003](#)), medicina ([Soares, 2007](#)), filtragem de spams ([Almeida e Yamakami, 2011](#)) e classificação de documentos ([Santos e Schiel, 2012](#)).

A classificação realizada pelo método de Bayes busca minimizar o risco ou perda condicional média. A definição de probabilidade condicional afirma que quando duas variáveis são estatisticamente dependentes, o conhecimento do valor de uma delas conduz

a estimativa do valor da outra. Isto é expresso pela seguinte definição de probabilidade condicional para duas variáveis aleatórias x e y

$$P(x,y) = \frac{P(x|y)}{P(x)} = \frac{P(y|x)}{P(y)} \quad (4.1)$$

$P(x | y)P(y) = P(y | x)P(x)$ representa a probabilidade conjunta $P(x,y)$. Reorganizando esses números temos a Equação 4.2 denominada Regra de Bayes. Essa equação mostra a relação entre uma probabilidade condicional e a sua inversa, isto é, a probabilidade de uma hipótese dada a observação de uma evidência e vice versa.

$$P(x|y) = \frac{p(y|x)P(x)}{P(y)} \quad (4.2)$$

A fórmula de Bayes é interpretada como uma inversão da conexão estatística, transformando $P(y | x)$ em $P(x | y)$.

Para uma dada amostra x e ω , onde x representa uma amostra do padrão e ω a classe. Cada x pertence a uma determinada classe ω_i , descrita pela probabilidade $P(\omega_i)$, que é a probabilidade a *priori* da classe. Um classificador bayesiano, atribui, a um dado objeto, a classe que tem maior probabilidade de ser a verdadeira probabilidade a *posteriori* $P(\omega_i|x)$, e essa probabilidade pode ser calculada pela regra de Bayes (Duda et al., 2012)

$$P(\omega_i | x) = \frac{p(x | \omega_i)P(\omega_i)}{p(x)} \quad (4.3)$$

em que $P(\omega_i)$ é a probabilidade a *priori* da classe, $p(x | \omega_i)$ é a função de probabilidade condicional da classe ou verossimilhança, e $p(x)$ é a evidencia ou densidade de probabilidade, expressa por

$$p(x) = \sum_{i=1}^c p(x | \omega_i)P(\omega_i) \quad (4.4)$$


no qual c é a quantidade de classes existentes no problema.

4.5 Máquinas de vetor de suporte

As *Support Vector Machine* (SVM) fazem parte do grupo de algoritmos de classificação supervisionada e também estão embasados na teoria de aprendizagem estatística (Vapnik, 1999), seus resultados de classificação são comparados e algumas vezes superiores aos obtidos por outros algoritmos de aprendizado como as Redes Neurais Artificiais (Steinwart e Christmann, 2008). Desenvolvidas inicialmente para aplicações em tarefas de classificação binária, atualmente podem ser utilizadas para a classificação contendo N classes em função do desenvolvimento de dois algoritmos, o SVM *one – versus – all*, e o SVM *one – versus – one* (Bagesteiro, 2015). As SVM foram utilizadas com sucesso em aplicações na medicina (Furey et al., 2000; Zien et al., 2000), reconhecimento de impressões digitais (Yao et al., 2001), detecção de faces (Osuna et al., 1997), reconhecimento facial (Guo et al., 2000), reconhecimento de assinaturas (Justino et al., 2003) e reconhecimento de textos (Joachims, 1998). Nas SVM's, o objetivo da aprendizagem estatística é obter uma função que minimize a probabilidade da saída obtida pela máquina ser diferente da saída desejada, diminuindo o erro em relação ao conjunto de treinamento assim como o erro em relação ao conjunto de teste. Essa função gerada define fronteiras lineares ou não lineares para a separação do conjunto de dados binários e embora tenha sido formulado para resolução de problemas com apenas duas classes, existem abordagens que permitem a resolução de problemas multiclasse (Crammer e Singer, 2002).

Diferente dos demais classificadores, as SVM's trabalham para encontrar a melhor fronteira ou hiperplano entre as classes, de modo que haja uma separação entre as diferentes classes com a maior margem possível, esse hiperplano é definido a partir da ajuda de padrões encontrados durante o treinamento chamados de vetores de suporte. A Figura 4.7 mostra duas classes separadas pelo classificador SVM, a linha em vermelho


Figura 4.7: Classificação com support vector machines.

Fonte: [Steinwart e Christmann \(2008\)](#)

representa o hiperplano enquanto que as linhas tracejadas são os vetores de suporte.

A maioria das aplicações reais apresentam problemas que não são linearmente separáveis, essa não linearidade pode ser causada por ruídos ou pela própria natureza do problema, nesses casos a separação dos dados em classes distintas requer a utilização de uma função não-linear, para isso o espaço de atributos original deverá ser projetado em um espaço de atributos com um numero maior de dimensões onde os dados se tornam linearmente separáveis por um hiperplano conforme Figura 4.8, isso ocorre em virtude da probabilidade da separação dos dados em um espaço de atributos de maior dimensionalidade ser superior se comparado a um espaço de baixa dimensão.

Figura 4.8: Aumento de dimensionalidade no espaço de atributos - SVM não linear .



Fonte: [Justino et al. \(2003\)](#)

O mapeamento desses dados em espaços de atributos com dimensões maiores é realizado pelas funções de *kernel*, existem varias funções desse tipo, as mais frequentemente utilizadas são:

- Kernel Polinomial:

$$(\langle \mathbf{x}_i \cdot \mathbf{x}_j \rangle + 1)^p;$$

- Kernel RBF - Função Base Radial (Radial basis function):

$$\exp\left(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{2\sigma^2}\right);$$

- Kernel Sigmoidal:

$$\tanh(\beta_0 \langle \mathbf{x}_i \cdot \mathbf{x}_j \rangle) + \beta_1).$$


4.6 Redes neurais Perceptron multi camada

De acordo com [Braga et al. \(2000\)](#) Redes Neurais Artificiais (RNA's) são sistemas computacionais semelhantes ao cérebro humano capazes de realizar aprendizagem e generalização em função do processamento paralelo de dados e da grande conectividade entre os neurônios dispostos em suas varias camadas. Segundo [S e Haykin \(2009\)](#) as

RNA's foram desenvolvidas com o objetivo de modelar o sistema de funcionamento do cérebro humano para obter soluções de problemas computacionais com elevados níveis de complexidade, e esta é a base para a classificação utilizando as Multi-layer Perceptron.

O modelo mais elementar de uma RNA foi desenvolvido por [Rosenblatt \(1958\)](#), e foi chamado de Perceptron simples (PS), esse modelo tem sua estrutura formada por apenas uma camada neural constituída por um único neurônio, a Figura 4.9 apresenta a configuração de uma Rede Neural Artificial Perceptron Simples constituída de x_N sinais de entradas, associadas a w_N pesos, uma função de ativação $\varphi(.)$ e uma saída (y).

Figura 4.9: Configuração básica de uma RNA Perceptron simples.



Fonte: [S e Haykin \(2009\)](#)

A Equação 4.5 rege o funcionamento da rede Perceptron simples, $\varphi(.)$ é a função de ativação responsável por determinar a forma e a intensidade de alteração dos valores transmitidos de um neurônio a outro. Para $\varphi(.)$ é possível adotar diversas funções, dentre as mais comuns estão a função degrau, função pseudolinear, sigmoide, tangente hiperbólica e a função gaussiana ([S e Haykin, 2009](#)). O w_0 também chamada de *bias* ou limiar de ativação, em alguns casos representados por θ , geralmente assume, sem qualquer perda de interpretabilidade, o valor unitário como respectiva entrada. Em síntese o PS


é na verdade um classificador binário que mapeia sua entrada $\mathbf{x}$ (um vetor de valores reais) para um valor de saída y (uma valor binário simples).

$$y = \varphi\left(\sum_{i=0}^N w_i x_i\right) \quad (4.5)$$

O reconhecimento de padrões utilizando MLP's é aplicado para a resolução de problemas em que as classes não são linearmente separáveis ([Minsky e Papert, 1969](#)) sendo esse o tipo de problema mais comumente encontrado em aplicações reais. Para [Peng e Wen \(1999\)](#) a utilização desse método oferece grandes vantagens na classificação não linear se comparado aos classificadores estatísticos. Este método utiliza Redes Neurais Artificiais (RNA) com duas ou mais camadas de neurônios, visto que RNA's de uma camada resolvem apenas problemas linearmente separáveis.

Estruturalmente, as RNA's são divididas em camadas de entrada e saída e camadas de neurônios ocultas localizadas entre a entrada e saída da rede, interligadas por um grande numero de conexões geralmente unidirecionais, na maioria dos modelos essas conexões estão associadas a pesos, que tem a função de armazenar o conhecimento adquirido pelo modelo e ponderar a entrada recebida por cada neurônio da rede. A inserção das camadas ocultas em uma RNA permite à rede a modelagem de funções com elevado nível de complexidade sendo aplicadas com sucesso em diversas áreas do conhecimento ([S e Haykin, 2009](#)). A Figura 4.10 mostra a estrutura de uma RNA com duas camadas de neurônios ocultas, vale ressaltar que todos os neurônios de uma camada estão conectados a todos os neurônios da camada anterior e da camada posterior, para cada ligação associa-se um valor numérico, este é o peso sináptico.

Figura 4.10: Arquitetura básica de uma rede MLP.



Fonte: [Albuquerque et al. \(2007\)](#)

O classificador MLP faz parte dos métodos de classificação supervisionada, seu treinamento é realizado através de um algoritmo chamado de retropropagação do erro ou *backpropagation*, esse treinamento é realizado em duas etapas consecutivas. A primeira etapa é chamada de *forward*, nessa etapa é gerada a saída da rede correspondente ao padrão modelado. Na segunda etapa chamada *backward*, um valor de erro é calculado a partir da comparação da resposta encontrada na saída do sistema e da resposta desejada da saída, visto que esse é um sistema de classificação supervisionada, isso pode ser visto na Figura 4.10. Este erro é utilizado como parâmetro para a atualização dos pesos sinápticos da camada de saída, sendo em seguida retro-propagado para a camada anterior a partir de sua multiplicação pelo peso das conexões entre as camadas, ajustando os pesos e limiares de todos os neurônios. A informação de erro que é propagada na direção contrária é a responsável pelo nome *Backpropagation*. Desta maneira, cada camada oculta recebe sua parcela de contribuição no erro gerado na camada de saída e atualiza seus próprios pesos.

Capítulo 5

MATERIAIS E MÉTODOS

Neste capítulo são apresentados os procedimentos, a metodologia empregada e os materiais utilizados nesse trabalho, descrevendo a composição do aço elétrico e detalhando a preparação metalográfica das amostras. Em seguida são apresentadas fotomicrografias das três classes estudadas e a descrição do processo para aquisição dessas imagens, além dos extratores de atributos e dos métodos de seleção de dados para treino e teste, leave one out e hold out. Por fim temos uma breve apresentação dos classificadores utilizados e das métricas de validação desses classificadores.

5.1 Materiais

O material utilizado nesse trabalho foi doado pela empresa Usiminas em pedaços de chapas medindo 60mm X 40mm. Trata-se de um aço elétrico de grão não orientado com 1,28% de silício laminado a frio. As amostras foram recozidas a 730°C por 12 horas e apresentam redução de 50% e 70% em sua espessura. Com o objetivo de alcançarmos a condição de recristalização secundária, gerando grãos com grande crescimento anormal, essas amostras foram submetidas a um tratamento térmico adicional à temperaturas de 620°C, 730°C, 840°C e 900°C durante os tempos de 1, 10, 100 e 1000 minutos para ambas

as reduções, totalizando 32 amostras. A Tabela 5.1 mostra sua composição química.

Tabela 5.1: Composição química do aço elétrico de grão não orientado em estudo

C	Mn	Si	P	S	Al
0,05%	0,29%	1,28%	0,025%	0,014%	0,036%

5.1.1 Identificação das amostras

As amostras foram identificadas de acordo com sua redução na espessura, tempo e temperatura de tratamento térmico seguindo a descrição AE-R-X-Y, onde:

- AE = Aço elétrico de grão não orientado com 1,28% de silício;
- R = Percentual de redução por laminação a frio;
- X = Temperatura em °C do tratamento térmico para crescimento de grão;
- Y = Tempo em minutos do tratamento térmico para crescimento de grão.

Exemplo:

AE-50-840-100 = Aço elétrico de grão não orientado com 1,28% de silício, com laminação industrial e redução de 50% em sua espessura, submetido a tratamento térmico para crescimento de grão na temperatura de 840°C pelo tempo de 100 minutos.

5.2 Métodos

A metodologia empregada nesse estudo foi dividida em trabalhos metalúrgicos e computacionais, com a preparação das amostras para microscopia óptica, coleta e construção do banco de imagens, extração de atributos mais significantes e construção do banco de dados, classificação e validação dos resultados gerados.


5.2.1 Preparação metalográfica

Após a realização do tratamento térmico, foram realizados procedimentos de preparação das amostras para análise microscópica. A preparação metalográfica teve início com o embutimento a quente em baquelite, seguido pelo lixamento executado com lixas nas dimensões granulométricas de 100, 220, 320, 400, 600 e 1200, em movimento radial em uma máquina politriz elétrica. Em seguida as amostras receberam um segundo polimento, agora utilizando pasta diamantada nas granulometrias de $6\mu\text{m}$, $3\mu\text{m}$ e $1\mu\text{m}$, porém após esse polimento a maioria das amostras ainda apresentava riscos, necessitando de um último polimento ainda mais fino, realizado em uma máquina de polimento mecânico utilizando sílica coloidal como substância abrasiva, Figura 5.1, o tempo desse polimento para cada amostra variou entre 1 e 6 horas. O último procedimento metalográfico adotado foi o ataque químico, este procedimento faz com que a amostra sofra algumas transformações eletroquímicas aumentando seu contraste, esse aumento varia em função da composição química do material e do reagente, além do tempo e temperatura às quais as amostras são expostas ao ataque. Nesse trabalho as amostras foram mergulhadas em uma solução química conhecida como Nital, composta por 95% de álcool etílico e 5% de ácido nítrico, durante um tempo de aproximadamente 5 segundos, esse ataque químico tem por finalidade revelar a microestrutura do material evidenciando os contornos dos grãos. Após esse ataque químico as amostras foram submetidas a um processo de limpeza para remover os resíduos através da lavagem em álcool, e posteriormente secas através de jato de ar quente.

5.2.2 Coleta e registro das fotomicrografias

A extração de atributos e classificação foram realizados nas fotomicrografias de amostras de aço elétrico de grão não orientado com 1,28% de silício, laminado a frio, recozidas a 730°C por 12 horas com redução de 50% e 70% em sua espessura, submetidas a tratamento térmico posterior visando o crescimento de grão a temperaturas de 620°C , 730°C ,

Figura 5.1: Máquina de polimento automático



Fonte: (Freitas, 2011)

840°C e 900°C, permanecendo em cada temperatura pelos tempos de 1, 10, 100 e 1000 minutos. As amostras utilizadas para o treinamento dos classificadores foram divididas em 3 classes distintas de acordo com a evolução de seu estado microestrutural denotada pelo crescimento dos grãos. A classe 0 não apresentou mudanças em sua microestrutura quando comparadas às amostras recozidas a 730°C por 12 horas, a classe 1 apresenta um crescimento considerável dos grãos se comparados à classe 0, enquanto que a classe 2 apresenta um crescimento anormal dos grãos característico do fenômeno de recristalização secundária. Essa divisão foi realizada com base na análise da microestrutura de cada amostra. As imagens foram coletadas sem a barra de escala micrográfica de modo a não influenciar em seu processamento computacional, porém após a classificação, as imagens podem ser editadas de modo a permitir a inserção dessa barra. Para a coleta de imagens foi utilizado um microscópio ótico com aquisição digital de imagens da marca Zeiss mostrado na Figura 5.2, foram 6 fotos de cada uma das 32 amostras, salvas em quatro formatos de arquivos diferentes (jpg, tif, bmp e zvi), totalizando 192 fotomicrografias e 768 arquivos com ampliação de 100 vezes, essas imagens foram utilizadas para treinamento e teste dos classificadores.


As Figuras 5.4a à 5.4l são exemplos das fotomicrografias coletadas para a realização desse trabalho, essas imagens são de amostras pertencentes às 3 classes estudadas, e

Figura 5.2: Microscópio ótico com aquisição digital de imagens da marca Zeiss



Fonte: Elaborada pelo autor.


Figura 5.3: Etapas realizadas na metodologia



Fonte: Elaborada pelo autor.

evidenciam as diferenças microestruturais referentes ao tamanho dos grãos que as compõem, as figuras apresentam grãos sem crescimento considerável, grãos com crescimento normal gerados pela recristalização primária, e grãos com crescimento anormal oriundos da recristalização secundária.

Figura 5.4: Fotomicrografias de aços elétricos GNO coletadas nesse trabalho



Fonte: Elaborada pelo autor.

5.2.3 Extração de características das fotomicrografias

Aqui foram utilizadas rotinas computacionais com a função extrair as características mais relevantes de cada fotomicrografia, reduzindo de forma considerável a grande quantidade de dados redundantes na imagem transformando-os em um vetor de características. Esses algoritmos detectaram e isolaram as características mais importantes das imagens digitais. A correta extração das características permite a construção de um classificador robusto, com alta taxa de acerto. Para a extração dos atributos foram utilizadas ferramentas computacionais presentes na biblioteca Opencv (Open Source Computer Vision Library) integrada à linguagem de programação C. A Opencv é uma biblioteca livre que permite ao programador, de nível acadêmico ou profissional, o desenvolvimento de aplicativos relacionados à visão computacional. Os extratores utilizados e a respectiva quantidade de atributos foram: momentos centrais com 7 atributos, momentos estatísticos com 10 atributos, momentos de HU com 7 atributos, GLCM com 14 atributos e LBP com 48 atributos, formando um banco de dados composto pelas características de 93 imagens.

O banco de dados resultante dos métodos de extração utilizados foi dividido em dois grupos distintos, um grupo para o treinamento do classificador e um grupo para o teste, a distribuição desses dados foi realizada por um processo chamado validação cruzada. [Kohavi et al. \(1995\)](#) afirmam que a validação cruzada permite avaliar a capacidade do classificador apresentar um elevado nível de precisão no desempenho com um novo grupo de dados. Nesse trabalho a partição e escolha dos dados utilizados para treinamento e teste dos classificadores foi realizada utilizando dois métodos distintos, o Leave One Out e o Hold Out. O método Hold out particiona o conjunto de dados para treino e teste de forma aleatória, o percentual de dados destinado para cada grupo é definido pelo usuário, comumente são utilizados 2/3 dos dados para o treinamento do classificador e 1/3 para o teste e validação. Nesse trabalho foram utilizados 50% do total de dados para treino e 50% para teste, esse percentual maior para teste garante maior precisão nos resultados

alcançados. O método Leave on out realiza a seleção dos dados de treinamento por classe, onde uma parte dos dados referentes aos elementos de cada classe são utilizados para treino, o percentual restante se destina ao teste. O leave one out é computacionalmente dispendioso e geralmente utilizado para pequenas quantidades de dados ([Monard e Baranauskas, 2003](#)) . Com o intuito de minimizar a variabilidade foram realizadas cinco iterações, com cada combinação de extrator, classificador e método de partição de dados.

5.2.4 Classificação das amostras com base em suas fotomicrografias

O classificador é o responsável por atribuir uma classe à imagem testada. Foram utilizadas técnicas de reconhecimento de padrões para processar as informações relevantes constantes no vetor de características, após o reconhecimento desses padrões foram utilizadas técnicas de inteligência computacional aplicada para identificar qual a classe que mais se parece com a nova amostra que se quer identificar. Essa etapa também contou com o uso constante de ferramentas computacionais disponíveis na Opencv. Os classificadores utilizados nesse trabalho foram: KNN (K- Nearest Neighbors) com K assumindo valores de 1, 3 e 5; K-Médias(K-Means) configurado para utilização de três grupos; Bayes com a configuração padrão; SVM (Support Vector Machine) configurado com ajustes de kernel linear, RBF, polinomial e sigmóide; MLP(Multi Layer Perceptron) com a quantidade de neurônios na camada oculta variando de acordo com o método de extração de atributos utilizado. Foram 250 neurônios para momentos estatísticos, 90 para momentos centrais, 80 para GLCM, 35 para LBP e 25 neurônios para momentos de Hu. Na classificação 50% das fotomicrografias de cada classe foi utilizado para o treinamento do sistema, em seguida foram executados os testes do classificador com o percentual restante das imagens, aferindo a taxa de acerto final do classificador.

5.2.5 Validação dos resultados gerados utilizando a análise do especialista

Todos os métodos de extração de atributos foram utilizados com todos os classificadores, combinados ainda com os dois métodos de partição de dados para treino e teste, leave one out e hold out. Como resultado dessa metodologia, os classificadores apresentaram diferentes respostas com diferentes taxas de acerto e confiabilidade. A validação dos modelos utilizados foi realizada através das métricas de avaliação de modelos de classificação, calculadas a partir dos dados extraídos das matrizes de confusão de cada combinação extrator/classificador, as métricas aqui utilizadas foram acurácia, sensibilidade, ppv(positive predictive values) e f-score. A acurácia revela a proporção de predições realizada de forma correta, não levando em consideração o que é positivo ou negativo na classificação dos aços, é calculada através da divisão do numero de acertos pelo numero total de dados do conjunto. A métrica ppv, também conhecida como precisão é uma medida de fidelidade e indica a taxa com que cada amostra de aço elétrico classificada como pertencente a uma classe realmente pertence àquela classe, essa métrica é calculada pela divisão do numero total de acertos na classificação pelo numero total de predições dessa classificação. A sensibilidade indica a taxa com que as amostras pertencentes a uma classe foram corretamente classificadas se comparadas ao total de amostras dessa classe. É calculada pela divisão dos acertos na classificação de uma só classe pelo numero total de amostras dessa classe. A média harmônica dos valores da precisão(ppv) e sensibilidade é apresentada pela F-score. O trabalho aqui desenvolvido não afirma se uma combinação extrator/classificador é melhor ou pior que outra, apenas responde quais são os mais indicados para essa aplicação confirmando o estudo de [Kohavi et al. \(1996\)](#) e [Dietterich \(1997\)](#).

Os resultados gerados pelo sistema computacional de classificação foram comparados aos resultados gerados pelos métodos tradicionais de analise realizados por um especialista, este utiliza as funções de distribuição de orientação cristalográficas (FDOC) e a

análise da área interna das curvas de histerese das amostras para determinar o desempenho eletromagnético do aço elétrico em estudo. Com base nas informações constantes nas matrizes de confusão para cada um dos classificadores combinados com cada extrator foi possível aferir taxas de acerto, precisão e confiabilidade dos métodos.

Capítulo 6

RESULTADOS E DISCUSSÕES

Esse capítulo tem início com os resultados metalúrgicos alcançados, apresentados pelas características das amostras de cada classe, por suas respectivas fotomicrografias, e pela relação das imagens com a evolução microestrutural indicativa de cada classe. Em seguida são apresentados os resultados computacionais, estes foram divididos em dois grupos distintos, diferenciados pelos métodos de partição dos dados para treinamento e teste dos classificadores, no primeiro grupo a partição foi realizada pelo método hold out, enquanto o segundo utilizou o método leave one out. Cada grupo mostra os resultados de acurácia, precisão(PPV), sensibilidade e f-score de 11 classificadores que utilizam os diferentes bancos de dados obtidos pelos 5 extratores, totalizando 220 resultados para hold out e a mesma quantidade para leave one out. Os resultados são apresentados em tabelas com seus respectivos desvios padrões, e em forma de gráfico, permitindo uma rápida análise do desempenho do conjunto formado por extrator, classificador e método de partição de dados. Ao final são apresentados os tempos necessários para a extração dos dados, além dos tempos de treino e teste para cada conjunto extrator, classificador e método de partição.

6.1 Resultados metalúrgicos

Segundo [Landgraf et al. \(2001\)](#), os aços elétricos de grãos não orientados estão divididos em duas classes: os aços totalmente processados e os aços semiprocessados. Os totalmente processados tem suas características microestruturais finais desenvolvidas na usina siderúrgica, que entrega o material já pronto para sua aplicação final. Os semiprocessados são geralmente aços laminados a frio, com baixo teor de carbono e fornecidos de modo que o cliente final possa realizar o tratamento térmico de recozimento com a finalidade de conseguir um crescimento de grão da ordem de $100\mu\text{m}$ a $150\mu\text{m}$.

6.1.1 Imagens classe 0 - Grãos recristalizados pequenos

As Figuras [6.1](#), [6.3](#) e [6.5](#) são fotomicrografias referentes a classe 0. Essa classe é composta pelas amostras AE-50 e AE-70 submetidas ao tratamento térmico de recozimento com o intuito de crescimento de grão, nas temperaturas de 620°C e 730°C . As amostras da classe 0 não apresentaram mudanças consideráveis em sua microestrutura se comparadas ao material sem o tratamento. O tamanho do grão resultante desse tratamento foi muito inferior ao ideal definido por [Shimanaka et al. \(1982\)](#), que compreende a faixa entre $100\mu\text{m}$ e $150\mu\text{m}$. A textura cristalográfica dessas amostras pode ser analisada por meio das Figuras [6.2](#), [6.4](#) e [6.6](#), estas apresentam as Funções de Distribuição de Orientações cristalográficas (FDOC's) em seções de $\varphi_2=45^{\circ}$ de acordo com a notação de Bunge, seu aspecto apresenta apenas a formação da fibra γ ($\langle 111 \rangle // \text{DN}$), sem a formação da componente Goss. As amostras que compõem essa classe são as seguintes:


- AE-50% recozidas a 620°C por 1, 10, 100 e 1000 minutos;
- AE-50% recozidas a 730°C por 1, 10, 100 e 1000 minutos;
- AE-70% recozidas a 620°C por 1, 10, 100 e 1000 minutos;
- AE-70% recozidas a 730°C por 1, 10, 100 e 1000 minutos;

Figura 6.1: Fotomicrografia de amostra da classe 0 - AE-50%-620°-1min




Fonte: Elaborada pelo autor.

Figura 6.2: FDOC de amostra da classe 0 - AE-50%-620°-1min




Fonte: Adaptado de Freitas (2011)

Figura 6.3: Fotomicrografia de amostra da classe 0 - AE-50%-730°-1000min




Fonte: Elaborada pelo autor.

Figura 6.4: FDOC de amostra da classe 0 - AE-50%-730°-1000min




Fonte: Adaptado de [Freitas \(2011\)](#)

Figura 6.5: Fotomicrografia de amostra da classe 0 - AE-50%-730°-100min



Fonte: Elaborada pelo autor.

Figura 6.6: FDOC de amostra da classe 0 - AE-50%-730°-100min



Fonte: Adaptado de [Freitas \(2011\)](#)

6.1.2 Imagens classe 1 - Grãos recristalizados de tamanho médio


As Figuras 6.7, 6.9 e 6.11 mostram algumas imagens pertencentes às amostras da classe 1, essas amostras são de um aço elétrico semiprocessado que foram submetidas a tratamento térmico de recozimento para alcançar o tamanho de grão necessário à sua aplicação. Suas fotomicrografias revelam um crescimento de grão considerável se comparadas às amostras da classe 0, apresentando grãos uniformes e equiaxiais, admitindo-se então que o aumento na temperatura e no tempo de recozimento está diretamente relacionada com o aumento do tamanho de grão das amostras dessa classe. Pertencem à essa classe as amostras de:

- AE-50% recozidas a 840°C por 1, 10 e 100 minutos;
- AE-50% recozidas a 900°C por 1 e 10 minutos;
- AE-70% recozidas a 840°C por 1, 10 minutos.

O tratamento térmico das amostras com laminação e redução de 50% em sua espessura apresentaram comportamento diferente das amostras laminadas com 70% de redução, para condições iguais de tempo e temperatura, o tamanho do grão resultante do recozimento do material laminado 50% foi maior que do material laminado com redução de 70%, confirmando o estudo de Burgers (1963) que afirma que para condições iguais de tempo e temperatura utilizados no tratamento térmico de recozimento aplicados à aços elétricos, o aço laminado mais deformado apresentará menor tamanho de grão na recristalização primária.


As Figuras 6.8, 6.10 e 6.12 apresentam as Funções de Distribuição de Orientações cristalográficas (FDOC's) em seções de $\varphi_2=45^\circ$ de acordo com a notação de Bunge para as mesmas 3 amostras da classe 1. A análise de sua textura cristalográfica revela apenas a formação da fibra γ ($\langle 111 \rangle // \text{DN}$), ainda sem a formação da componente Goss que caracteriza a recristalização secundária.

Figura 6.7: Fotomicrografia de amostra da classe 1 - AE-50%-840°-100m




Fonte: Elaborada pelo autor.

Figura 6.8: FDOC de amostra da classe 1 - AE-50%-840°-100min




Fonte: Freitas (2011)

Figura 6.9: Fotomicrografia de amostra da classe 1 - AE-50%-900°-10min




Fonte: Elaborada pelo autor.

Figura 6.10: FDOC de amostra da classe 1 - AE-50%-900°-10min




Fonte: [Freitas \(2011\)](#)

Figura 6.11: Fotomicrografia de amostra da classe 1 - AE-70%-840°-10min



Fonte: Elaborada pelo autor.

Figura 6.12: FDOC de amostra da classe 1 - AE-70%-840°-10min



Fonte: Freitas (2011)

6.1.3 Imagens classe 2 - Grãos com crescimento anormal (recristalização secundária)


As imagens das Figuras 6.13, 6.15 e 6.17 são pertencentes a classe 2. As amostras dessa classe apresentam o fenômeno da recristalização secundária, caracterizada pelo crescimento anormal de alguns grãos (Humphreys e Hatherly, 2004), esse fenômeno é o resultado de um desvio do padrão de crescimento convencional dos grãos que ocorre quando a microestrutura se torna instável e o crescimento acontece apenas em um pequeno número de grãos, os demais grãos da amostra permanecem inalterados até que sejam consumidos pelos grãos com crescimento anormal. Aqui pode-se observar que o aumento da temperatura e do tempo de recozimento foram os responsáveis pela recristalização secundária. A análise da textura cristalográfica dessas amostras pode ser realizado através das figuras 6.14, 6.16 e 6.18, suas FDOC's apresentam o surgimento da componente (110)[001] conhecida como Goss. A formação dessa componente coincide com o surgimento da recristalização secundária.

As amostras pertencentes à essa classe são:

- AE-50% recozidas a 840°C por 1000 minutos;
- AE-50% recozidas a 900°C por 100 e 1000 minutos;
- AE-70% recozidas a 840°C por 100, 1000 minutos;
- AE-70% recozidas a 900°C por 1, 10, 100 e 1000 minutos.


As amostras laminadas com redução de 50% em sua espessura obtiveram um crescimento de grão consideravelmente maior que as amostras com redução de 70%, confirmando o estudo de Burgers (1963) que afirma em seu diagrama de recristalização, Figura 2.12, que quanto maior a deformação sofrida pelo aço, menor será o tamanho final de seu grão.

Figura 6.13: Fotomicrografia de amostra da classe 2 - AE-70%-840°-100min




Fonte: Elaborada pelo autor.

Figura 6.14: FDOC de amostra da classe 2 - AE-70%-840°-100min




Fonte: Freitas (2011)

Figura 6.15: Fotomicrografia de amostra da classe 2 - AE-70%-840°-1000min




Fonte: Elaborada pelo autor.

Figura 6.16: FDOC de amostra da classe 2 - AE-70%-840°-1000min




Fonte: Freitas (2011)

Figura 6.17: Fotomicrografia de amostra da classe 2 - AE-50%-840°-1000min



Fonte: Elaborada pelo autor.

Figura 6.18: FDOC de amostra da classe 2 - AE-50%-840°-1000min



Fonte: Freitas (2011)

6.2 Resultados computacionais

6.2.1 Grupo 1 - Hold out

A Tabela [6.1](#) apresenta os resultados de acurácia, precisão, sensibilidade e f-score para a classificação dos aços elétricos, acompanhados de seu desvio padrão, para o método hold out. As Figuras [6.19](#) à [6.22](#) mostram esses resultados graficamente.

Tabela 6.1: Métricas obtidas por extração e classificação utilizando o método Hold out

Extrator	Classificador	Configuração	PPV (%)	Sens (%)	F-Score (%)	Acc (%)
GLCM	Bayes	Normal	63.95±0.65	65.80±0.00	61.80±0.00	45.80±0.00
	SVM	Linear	71.98±0.00	76.08±0.00	82.96±0.00	71.15±0.08
		RBF	94.59±0.00	96.49±0.00	96.49±0.00	93.27±0.00
		Polinomial	77.53±0.00	86.57±0.00	85.96±0.00	79.49±0.00
		Sigmoide	67.50±0.00	65.40±0.00	61.80±0.00	65.80±0.00
	MLP	Conf. 1	87.93±0.80	90.41±0.00	92.28±0.00	87.72±0.00
		Conf. 2	90.40±0.00	90.39±0.09	94.04±0.00	91.32±0.30
KNN	N = 1	96.51±0.00	96.30±0.00	98.55±0.00	97.44±0.00	
	N = 3	94.49±0.00	93.74±0.00	96.49±0.00	92.48±0.00	
	N = 5	86.79±0.00	86.30±0.00	91.23±0.00	87.78±0.00	
K-means			65.32±0.00	60.50±0.00	50.32±0.00	50.21±0.00
LBP	Bayes	Normal	69.33±0.22	82.06±0.00	82.46±0.11	67.23±0.26
	SVM	Linear	82.53±0.03	85.28±0.06	89.47±0.02	81.41±0.00
		RBF	85.56±0.00	83.19±0.00	88.36±0.08	82.40±0.00
		Polinomial	83.24±0.00	84.17±0.00	89.47±0.00	82.62±0.00
		Sigmoide	63.18±0.08	60.30±0.08	59.10±0.08	60.40±0.00
	MLP	Conf. 1	81.85±0.38	83.23±0.38	88.77±0.20	81.43±0.47
		Conf. 2	80.24±0.21	81.17±0.32	88.07±0.12	80.64±0.37
	KNN	N = 1	90.12±0.00	89.60±0.00	92.98±0.00	90.95±0.00
		N = 3	71.38±0.00	71.88±0.00	82.96±0.00	72.57±0.00
		N = 5	74.89±0.00	75.07±0.00	85.96±0.00	74.89±0.00
K-means			68.98±0.00	67.00±0.00	53.10±0.08	53.34±0.00
M. Centrais	Bayes	Normal	29.00±0.00	27.43±0.00	48.21±0.09	42.86±0.00
	SVM	Linear	51.34±0.00	50.32±0.00	52.34±0.44	68.22±0.00
		RBF	49.31±0.00	46.75±0.08	55.75±0.00	67.31±0.00
		Polinomial	50.08±0.00	48.21±0.08	49.64±0.00	69.42±0.00
		Sigmoide	30.52±0.00	29.75±0.99	23.53±0.02	15.42±0.00
	MLP	Conf. 1	37.90±0.00	36.21±0.00	38.37±0.00	78.32±0.00
		Conf. 2	32.45±0.00	36.51±0.00	36.51±0.00	77.42±0.00
	KNN	N = 1	34.13±0.08	34.16±0.07	50.21±0.00	56.86±0.00
		N = 3	33.18±0.00	34.56±0.08	44.47±0.00	58.53±0.00
		N = 5	37.73±0.98	35.23±0.00	46.09±0.58	58.34±0.00
K-means			30.53±0.00	28.53±0.00	45.64±0.00	43.22±0.00
M. HU	Bayes	Normal	51.24±0.00	53.21±0.00	51.34±0.00	56.32±0.00
	SVM	Linear	60.31±0.00	61.34±0.00	64.12±0.61	66.03±0.83
		RBF	59.31±0.00	55.42±0.98	53.56±0.68	59.76±0.58
		Polinomial	69.32±0.57	70.42±0.85	63.31±0.68	61.96±0.98
		Sigmoide	34.61±0.00	32.53±0.95	33.96±0.00	63.45±0.00
	MLP	Conf. 1	76.43±0.00	71.34±0.00	72.98±0.00	76.03±0.00
		Conf. 2	75.23±0.05	70.43±0.00	71.31±0.00	81.89±0.00
	KNN	N = 1	42.34±0.00	35.32±0.00	42.87±0.00	60.43±0.00
		N = 3	43.42±0.00	35.14±0.00	44.09±0.00	55.23±0.00
		N = 5	43.87±0.00	45.03±0.00	44.66±0.00	58.31±0.00
K-means			50.31±0.00	50.31±0.00	50.31±0.00	56.03±0.02
M. Estatísticos	Bayes	Normal	26.54±0.00	25.90±0.08	42.57±0.00	58.08±0.00
	SVM	Linear	29.05±0.00	30.01±0.26	40.13±0.58	71.85±0.95
		RBF	45.64±0.08	40.31±0.12	47.99±0.98	61.54±0.27
		Polinomial	40.35±0.00	39.54±0.96	39.63±0.00	79.43±0.00
		Sigmoide	24.56±0.43	20.04±0.86	25.77±0.00	14.53±0.00
	MLP	Conf. 1	48.54±0.00	45.64±0.76	46.42±0.00	81.86±0.00
		Conf. 2	37.45±0.02	35.09±0.76	49.74±0.00	70.32±0.00
	KNN	N = 1	30.56±0.00	30.00±0.00	52.56±0.00	61.53±0.00
		N = 3	31.09±0.00	34.53±0.00	47.53±0.00	60.31±0.00
		N = 5	35.56±0.08	32.13±0.02	42.10±0.00	60.83±0.00
K-means			29.56±0.00	28.43±0.00	44.01±0.00	50.09±0.00

De maneira geral as classificações realizadas utilizando os bancos de dados formados pelos extratores GLCM e LBP apresentaram taxas de acerto superiores, a principal diferença desses extratores para os demais é que eles geram os dados para classificação a partir da textura das imagens digitais, enquanto que os momentos de Hu, momentos centrais e momentos estatísticos se utilizam de descritores de forma dos objetos. A Tabela 6.1 e o gráfico da Figura 6.19 nos mostram que o maior valor de acurácia obtido foi na utilização do classificador KNN-1 alimentado pelo banco de dados gerado pelo extrator GLCM e método de partição de dados Hold out, alcançando a elevada taxa de 97,44%, a acurácia pode ser definida como a soma dos dados positivos e negativos classificados corretamente dividido pela soma de todos os dados positivos e negativos, entenda-se positivos e negativos como pertencentes ou não àquela classe. a classificação realizada com essa configuração ainda apresentou excelentes resultados de precisão com 96,51%, sensibilidade 96,30% e f-score 98,55%.

Altos valores de acurácia, acima de 90%, também foram obtidos utilizando o banco de dados GLCM e os classificadores SVM-rbf com 93,27%, KNN-3 com 92,48%, MLP-2 com 91,32% e o classificador KNN-1 com o extrator LBP aferindo 90,95%.

Taxas expressivas de acurácia, acima de 80%, foram geradas pelos classificadores: KNN-5 87,78% e MLP-1 87,72% utilizando o extrator GLCM; SVM polinomial 82,62%, SVM rbf 82,40%, SVM linear 81,41%, MLP-1 81,43% e MLP-2 80,64%, estes utilizando o banco de dados gerados pelo extrator LBP; MLP-2 e extrator momentos de Hu 81,89%; MLP-1 e extrator momentos estatísticos 81,86%.

Todos os demais resultados de acurácia ficaram abaixo de 80%, ressaltando-se que a maioria das classificações utilizando os dados extraídos pelos métodos: momentos centrais, momentos estatísticos e momentos de Hu obtiveram acurácia próximas ou abaixo de 60%. A exceção à esse baixo rendimento está na combinação momentos de Hu com MLP-2 e momentos estatísticos e classificador MLP-1 com as taxas de acurácia acima citados.




Figura 6.19: Gráfico de acurácia - Método Hold out




Figura 6.20: Gráfico de sensibilidade - Método Hold out

Alem da acurácia, foram apresentados valores de sensibilidade, precisão e f-score para cada classificação, essas métricas tem a função de validar o processo aferindo confiabilidade aos classificadores, os gráficos das Figuras 6.20 à 6.22 apresentam esses resultados para o método hold out. A métrica PPV também conhecida como precisão, indica a taxa em que todos as fotomicrografias consideradas como pertencentes a uma classe são realmente daquela classe, nesse calculo não são incluídos nenhum valor classificado erroneamente, ja a sensibilidade indica a taxa de acerto na classificação se comparado apenas às amostras pertencentes àquela classe, enquanto que a métrica f-score é a média harmônica das métricas ppv e sensibilidade. Para essas medidas, novamente as classificações realizadas utilizando o banco de dados dos extratores GLCM e LBP obtiveram os melhores resultados. As classificações que obtiveram acurácia acima de 90% também apresentaram valores de precisão, sensibilidade e f-score acima de 90% com exceção apenas da medida de sensibilidade do classificador KNN-1 com extrator LBP que apresentou 89,60%. Seguindo a ordem de precisão, sensibilidade e f-score os resultados apresentados pelas classificações utilizando o banco de dados do extrator GLCM foram 96,51%, 96,30% e 98,55% para o classificador KNN-1, para SVM-rbf os resultados foram 95,59%, 96,49% e 96,49%, utilizando o classificador KNN-3 temos 94,49%, 93,74% e 96,49% respectivamente para ppv, sensibilidade e f-score, ainda utilizando o extrator GLCM obtivemos com o classificador MLP-2 90,40%, 90,39% e 94,04%, a ultima classificação com acurácia acima de 90% foi com o extrator LBP e classificador KNN-1, seus valores para ppv, sensibilidade e f-score são 90,12%, 89,60% e 92,98% respectivamente. Os classificadores KNN-5 e MLP-1 com os dados extraídos pelo GLCM, e SVM-polinomial, SVM-rbf, SVM-linear, MLP-1 e MLP-2 com o extrator LBP obtiveram acurácia acima de 80%, e seus valores de sensibilidade, precisão e f-score foram todos acima de 80%. Os extratores momentos de Hu com MLP-2 e momentos estatísticos com MLP-1 apresentaram acurácia acima de 80% contudo suas demais métricas ficaram bem abaixo desse valor, diminuindo a confiabilidade nos seus valores percentuais de acerto.




Figura 6.21: Gráfico de fscore - Método Hold out




Figura 6.22: Gráfico de precisão - Método Hold out

6.2.2 Tempos de classificação método hold out

Os tempos necessários para treino e teste dos classificadores utilizando o método hold out são apresentados pela Tabela 6.2. Assim como o resultado das métricas, os melhores tempos de aprendizado e classificação foram obtidos utilizando os bancos de dados GLCM e LBP. Os menor tempo obtido foi na utilização do classificador KNN-5 com extrator GLCM, este necessitou de apenas 0,2 milissegundos para treino e teste, em seguida vieram KNN-3 e extrator LBP com 1,2 ms, KNN-5 e LBP com 1,8 ms e KNN-3 e extrator GLCM com 2,6 ms. As classificações que obtiveram os resultados de acurácia acima de 90% necessitaram dos seguintes tempos para aprendizado e classificação: KNN-1 e extrator GLCM 22,60 ms, SVM-rbf e GLCM 11,20 ms, KNN-3 e GLCM 2,60 ms, MLP-2 e extrator GLCM 3314,00 ms e KNN-1 com banco de dados extraído por LBP 6,80 ms. Dentre essas classificações destaca-se negativamente o tempo apresentado pelo classificador MLP-2 e extrator GLCM, a melhor classificação, obtida pelo classificador KNN-1 e GLCM, foi 146 vezes mais rápida.

As classificações realizadas utilizando os bancos de dados formados pelos extratores momentos estatísticos, momentos centrais e momentos de Hu, apresentaram tempos bastante elevados se comparados aos tempos de classificação utilizando os extratores GLCM e LBP. Utilizando momentos centrais, o tempo total de treino e teste para o classificador KNN-1 foi de 51 minutos, para KNN-3 53 minutos e KNN-4 54 minutos, com o extrator momentos de Hu os tempos foram KNN-1 1 hora e 11 minutos, KNN-3 1 hora e 14 minutos, KNN-5 1 hora e 15 minutos, para o extrator momentos estatísticos os tempos foram praticamente iguais para KNN-1, KNN-3 e KNN-5, sendo necessários para treino e teste aproximadamente 1 hora e 18 minutos. A partir desses tempos, e ainda considerando os excelentes resultados de acurácia e confiabilidade obtidos, é possível afirmar que os extratores baseados na textura das imagens (*GLCM e LBP*) são bem superiores, para essa aplicação, que os extratores baseados no formato dos objetos que compõem as imagens.

Tabela 6.2: Tabela de tempos em milisegundos para treino e teste dos classificadores utilizando o método Hold out

Extrator	Classificador	Configuração	Treino(ms)	Teste(ms)	Total(ms)
GLCM	Bayes	Normal	3,8	4,8	8,6
	SVM	Linear	8,2	0	8,2
		RBF	10,4	0,8	11,2
		Polinomial	8,8	0,8	9,6
		Sigmoide	12,2	1,2	13,4
	MLP	Conf. 1	4108,6	1,2	4109,8
		Conf. 2	3312,8	1,2	3314
	KNN	N = 1	7,2	15,4	22,6
		N = 3	0	2,6	2,6
		N = 5	0	0,2	0,2
	K-means		3,8	4,8	8,6
LBP	Bayes	Normal	274,2	9,4	283,6
	SVM	Linear	9,2	0,2	9,4
		RBF	7,6	2,2	9,8
		Polinomial	9,8	1	10,8
		Sigmoide	3,8	1,2	5
	MLP	Conf. 1	3460,2	1,8	3462
		Conf. 2	6217	4,6	6222,2
	KNN	N = 1	0,2	6,6	6,8
		N = 3	0,2	1,0	1,2
		N = 5	0,0	1,8	1,8
	K-means		4,8	3,8	8,6
M. Centrais	Bayes	Normal	62,54	141,45	203,99
	SVM	Linear	12413,6	76	12489,6
		RBF	20046,801	23837,6	43884,398
		Polinomial	7768,2	9233,8	17001,4
		Sigmoide	29552	23860	53412
	MLP	Conf. 1	156830,203	374,2	157204,406
		Conf. 2	122489,797	382,8	122872,594
	KNN	N = 1	6,333	3102581	3102587,25
		N = 3	5	3226295,25	3226300,25
		N = 5	5	3295157	3295162
	K-means		43,91	36978,25	37022,16
M. HU	Bayes	Normal	74,805	166,451	241,256
	SVM	Linear	15946,6	90,8	16037,399
		RBF	16612,6	17199,199	33811,797
		Polinomial	5470,4	4080,4	9550,8
		Sigmoide	35113	28303,199	63416,199
	MLP	Conf. 1	511205,594	447,6	511653,188
		Conf. 2	346479,594	452	346931,594
	KNN	N = 1	6,333	4298305	4298311,5
		N = 3	6,333	4440274	4440280,5
		N = 5	6	4518090,5	4518096,5
	K-means		51,42	12053,67	12105,09
M. Estatísticos	Bayes	Normal	133,496	224,991	358,487
	SVM	Linear	13190,4	93,8	13284,2
		RBF	25281	27834	53115
		Polinomial	6355,8	4197,8	10553,6
		Sigmoide	39253,398	31429	70682,398
	MLP	Conf. 1	286948,812	463,2	287412
		Conf. 2	251243,522	498,7	251742,222
	KNN	N = 1	8	4697294,5	4697302,5
		N = 3	7,333	4703470,5	4703478
		N = 5	7	4704359,5	4704366,5
	K-means		82,33	47061,92	47144,25

6.2.3 Grupo 2 - Leave one out

A Tabela 6.3 apresenta os resultados de acurácia, precisão, sensibilidade e f-score para a classificação dos aços elétricos, acompanhados de seu desvio padrão, para o método leave one out. As Figuras 6.23 à 6.26 mostram esses resultados graficamente.

O Gráfico 6.23 mostra que utilizando o método de validação cruzada leave one out os classificadores que apresentaram os maiores níveis de acurácia foram MLP-1 e MLP-2 utilizando o banco de dados GLCM, aqui os percentuais são inferiores aos obtidos utilizando o método hold out tendo como valores de acurácia 86,44% e 82,64% respectivamente para os classificadores MLP-1 e MLP-2. Considerando apenas os valores de acurácia acima de 80% temos ainda os classificadores KNN-1 e extrator LBP com 80,51%, MLP-2 e LBP com 80,87%, SVM-polinomial e extrator momentos estatísticos com 81,79% e classificador MLP-1 também com extrator momentos estatísticos apresentando 81,89% de acurácia. Na análise desse grupo, se comparado aos resultados de acurácia do grupo que utilizou o método hold out, vale destacar a presença de classificadores que utilizaram o banco de dados formado pelo extrator momentos estatísticos, entretanto os valores das demais métricas sensibilidade, precisão e f-score para as classificações utilizando esse banco de dados são bem menores que os valores das mesmas métricas para os extratores GLCM e LBP, como mostram os gráficos das Figuras 6.24, 6.25 e 6.26, esses valores baixos para as métricas implicam diretamente na confiabilidade da classificação, indicando que existe a possibilidade dos bons valores de acurácia apresentados pelas classificações com momentos estatísticos serem falsos. Ainda analisando a acurácia 8 classificações obtiveram valores entre 78% e 80%, são eles: KNN-1 e extrator GLCM com 78,49%, SVM-polinomial e GLCM com 78,26%, SVM-linear e LBP com 79,85%, MLP-1 e extrator momentos de Hu com 78,98%, MLP-2 e momentos de Hu com 79,42%, MLP-2 e extrator momentos centrais com 79,50%, SVM-rbf e momentos estatísticos 78,53%, e MLP-2 com banco de dados gerado pelo extrator momentos estatísticos 79,54%.

Tabela 6.3: Resultado das métricas obtidas por extração e classificação utilizando o método Leave one out

Extrator	Classificador	Configuração	PPV (%)	Sens (%)	F-Score (%)	Acc (%)
GLCM	Bayes	Normal	60.42±0.00	61.09±0.00	63.16±0.00	67.08±0.00
	SVM	Linear	70.50±0.00	65.40±0.00	68.42±0.00	74.23±0.00
		RBF	72.99±0.00	79.32±0.00	78.95±0.00	71.22±0.00
		Polinomial	66.51±0.00	62.78±0.00	68.42±0.00	78.26±0.00
		Sigmoide	61.01±0.00	60.45±0.00	63.16±0.00	33.33±0.00
	MLP	Conf. 1	69.08±0.00	75.04±0.00	76.84±0.00	86.44±0.00
		Conf. 2	68.79±0.00	70.64±0.00	75.79±0.00	82.64±0.00
	KNN	N = 1	79.67±0.00	83.50±0.00	85.96±0.00	78.49±0.00
		N = 3	66.81±0.00	74.07±0.00	78.95±0.00	65.03±0.00
		N = 5	52.68±0.00	69.44±0.00	73.68±0.00	52.53±0.00
	K-means		53.21±0.00	45.77±0.00	48.45±0.00	50.98±0.00
LBP	Bayes	Normal	67.04±0.00	68.95±0.00	53.59±0.00	62.31±0.00
	SVM	Linear	81.40±0.00	85.00±0.00	87.72±0.00	79.85±0.00
		RBF	73.53±0.00	74.21±0.00	76.09±0.00	75.00±0.00
		Polinomial	78.86±0.00	82.97±0.00	85.96±0.00	76.89±0.00
		Sigmoide	68.40±0.00	69.43±0.00	61.35±0.00	60.74±0.00
	MLP	Conf. 1	63.18±0.13	74.81±0.66	78.60±0.63	61.51±0.01
		Conf. 2	65.18±0.10	75.19±0.31	78.60±0.02	80.87±0.13
	KNN	N = 1	73.05±0.00	83.61±0.00	84.21±0.00	80.51±0.00
		N = 3	70.52±0.00	82.97±0.00	84.21±0.00	68.91±0.00
		N = 5	65.32±0.00	83.27±0.00	82.68±0.00	74.74±0.00
	K-means		56.21±0.00	44.12±0.00	45.66±0.00	49.21±0.00
M. Centrais	Bayes	Normal	29.99±0.00	27.43±0.00	48.21±0.00	51.08±0.00
	SVM	Linear	51.34±0.00	27.43±0.00	52.34±0.00	69.31±0.00
		RBF	49.31±0.00	46.75±0.00	57.99±0.00	69.98±0.00
		Polinomial	51.28±0.00	48.21±0.00	47.24±0.00	63.13±0.00
		Sigmoide	30.52±0.00	25.20±0.00	23.53±0.09	15.42±0.00
	MLP	Conf. 1	31.42±0.00	39.31±0.08	48.01±0.04	75.43±0.00
		Conf. 2	41.90±0.00	37.21±0.00	46.71±0.00	79.50±0.00
	KNN	N = 1	34.13±0.00	34.16±0.00	40.21±0.00	50.90±0.00
		N = 3	33.18±0.00	31.09±0.00	46.89±0.00	58.52±0.00
		N = 5	39.32±0.00	34.09±0.00	49.12±0.00	58.11±0.00
	K-means		31.53±0.00	28.53±0.00	40.09±0.00	44.22±0.00
M. HU	Bayes	Normal	62.14±0.00	51.31±0.00	39.97±0.00	52.32±0.00
	SVM	Linear	55.32±0.00	57.97±0.00	63.87±0.00	76.43±0.00
		RBF	55.41±0.00	58.42±0.00	57.54±0.00	72.41±0.00
		Polinomial	43.11±0.00	42.45±0.00	44.07±0.00	65.43±0.00
		Sigmoide	31.76±0.00	30.01±0.00	30.55±0.00	16.53±0.00
	MLP	Conf. 1	59.78±0.00	59.07±0.00	63.33±0.00	78.98±0.00
		Conf. 2	57.63±0.00	58.75±0.00	65.42±0.00	79.42±0.00
	KNN	N = 1	42.57±0.00	34.92±0.00	46.32±0.00	60.43±0.00
		N = 3	33.55±0.00	34.61±0.00	44.40±0.00	58.32±0.00
		N = 5	43.85±0.00	34.32±0.00	44.90±0.00	48.53±0.00
	K-means		60.14±0.00	33.56±0.00	38.45±0.00	57.32±0.00
M. Estatísticos	Bayes	Normal	25.87±0.00	27.54±0.00	43.15±0.00	45.68±0.00
	SVM	Linear	27.53±0.00	26.53±0.00	41.56±0.00	71.09±0.00
		RBF	40.53±0.00	34.56±0.00	49.65±0.00	78.53±0.00
		Polinomial	37.53±0.00	36.45±0.00	40.98±0.00	81.79±0.00
		Sigmoide	20.56±0.00	19.35±0.00	20.53±0.00	14.53±0.00
	MLP	Conf. 1	45.65±0.00	40.34±0.00	50.23±0.00	81.80±0.00
		Conf. 2	34.00±0.00	34.67±0.00	44.78±0.78	79.54±0.00
	KNN	N = 1	30.50±0.00	29.56±0.00	50.31±0.00	60.26±0.00
		N = 3	31.00±0.00	34.14±0.00	50.00±0.00	62.41±0.00
		N = 5	32.46±0.00	31.09±0.00	50.00±0.00	64.32±0.00
	K-means		28.45±0.00	25.67±0.00	44.98±0.00	49.56±0.00

Os gráficos das Figuras 6.24, 6.25 e 6.26, apresentam os resultados das métricas sensibilidade, precisão e f-score para o grupo de classificações realizadas utilizando o método de partição de dados leave one out, essas métricas indicam o quão confiável é o valor de acurácia extraído de cada classificação.

Seguindo a ordem precisão, sensibilidade e f-score temos para o grupo com acurácia acima de 80% os seguintes valores: classificador MLP-1 e extrator GLCM 69,08%, 75,04%, 76,84%, MLP-2 e GLCM 68,79%, 70,64% e 75,79%, KNN-1 e extrator LBP 73,05%, 83,61%, 84,21%, MLP-2 e LBP 65,18%, 75,19%, 78,60%, classificador SVM-polinomial e extrator momentos estatísticos 37,53%, 36,45%, 40,98% e MLP-1 com momentos estatísticos 45,65%, 40,34% e 50,23. É notável o baixo valor apresentado por essas métricas quando se utilizou o extrator momentos estatísticos.

Para o grupo que obteve acurácia entre 78% e 80%, e ainda seguindo a ordem precisão, sensibilidade e f-score os valores de métricas são: KNN-1 e extrator GLCM 79,67%, 83,50%, 85,96%, SVM-polinomial e GLCM 66,51%, 62,78%, 68,42%, classificador SVM-linear e extrator LBP 81,40%, 85,00%, 87,72%, MLP-1 e extrator momentos de Hu 59,78%, 59,07%, 63,33%, MLP-2 e momentos de Hu 57,63%, 58,75%, 65,42%, MLP-2 e momentos centrais 41,90%, 37,21%, 46,71%, SVM-rbf e extrator momentos estatísticos 40,53%, 34,56%, 49,65% e MLP-2 com momentos estatísticos 34,00%, 34,67%, 44,78%.

Em sua maioria as métricas precisão, sensibilidade e f-score apresentadas pelas classificações utilizando os bancos de dados GLCM e LBP foram superiores aos valores apresentados pelas classificações que utilizaram os demais bancos de dados, isso também ocorreu quando se utilizou o método hold out, comprovando a superioridade, para essa aplicação, dos extratores baseados na textura das imagens. De maneira geral os baixos resultados para essas 3 últimas métricas, apresentados pelas classificações utilizando os dados dos extratores momentos centrais, momentos de Hu e momentos estatísticos comprovam a baixa confiabilidade nas taxas de acurácia apresentados por eles.




Figura 6.23: Gráfico de acurácia - Método Leave one out




Figura 6.24: Gráfico de sensibilidade - Método Leave one out




Figura 6.25: Gráfico de precisão - Método Leave one out




Figura 6.26: Gráfico de fscore - Método Leave one out

6.2.4 Tempos de classificação método leave one out

A Tabela 6.4 apresenta os tempos necessários para treino e teste dos classificadores utilizando o método leave one out. De forma análoga aos resultados apresentados pelos tempos de treino e teste dos classificadores que utilizaram o método de partição hold out e ainda pelos resultados das métricas dos métodos hold out e leave one out, os melhores tempos de treinamento e teste dos classificadores que utilizaram o método de partição de dados leave one out, foram apresentados pelas classificações realizadas utilizando os bancos de dados gerados pelos extratores GLCM e LBP, comprovando para essa aplicação, a eficiência dos extratores de atributos baseados na textura das imagens. Os menores tempos de treino e teste, abaixo de 10 milissegundos, foram obtidos pelas seguintes combinações de classificador e extrator: KNN-3 e GLCM com 1,0 ms, KNN-3 e LBP com 1,4 ms, KNN-5 e LBP com 1,6 ms, KNN-5 e GLCM 3,4 ms, SVM-sigmoide e GLCM 6,4 ms, KNN-1 e GLCM 7,2 ms, K-means e GLCM 8,6 ms, K-means e LBP com 8,6 ms, KNN-1 e LBP com 8,8 ms, SVM-sigmoide e LBP com 9,2 ms e SVM-linear e GLCM com tempo total de 9,4 ms.

Para as classificações que obtiveram acurácia acima de 80% os tempos foram: MLP-1 e extrator GLCM 3265,4 ms, MLP-2 e GLCM 2542,2 ms, classificador KNN-1 e extrator LBP 8,8 ms, MLP-2 e LBP 4642 ms, SVM-polinomial e extrator momentos estatísticos 10275,6 ms, MLP-1 e momentos estatísticos 345973,6 ms. Embora o melhor valor de acurácia para esse grupo tenha sido alcançado pela combinação MLP-1 e GLCM aferindo 86,44%, a classificação realizada pelo classificador KNN-1 com dados do extrator LBP obteve a acurácia de 80,51%, e o tempo total necessário para aprendizado e teste deste último foi 371 vezes mais rápido. Novamente destaca-se o elevado tempo de treino e teste dos classificadores que utilizaram os dados gerados pelos extratores momentos de Hu, momentos centrais e momentos estatísticos. Assim como na classificação utilizando o método hold out, o tempo para treino e teste de alguns classificadores que utilizaram os dados desses extratores superou 1 hora.

Tabela 6.4: Tabela de tempos em milisegundos para extração e classificação utilizando o método Leave one out

Extrator	Classificador	Configuração	Treino(ms)	Teste(ms)	Total(ms)
GLCM	Bayes	Normal	12,8	9,4	22,2
	SVM	Linear	8,8	0,6	9,4
		RBF	11,6	1,0	12,6
		Polinomial	12,4	0,6	13,0
		Sigmoide	4,6	1,8	6,4
	MLP	Conf. 1	3264,2	1,2	3265,4
		Conf. 2	2541,0	1,2	2542,2
KNN	N = 1	0,2	7,0	7,2	
	N = 3	0,4	0,6	1,0	
	N = 5	1,0	2,4	3,4	
K-means			3,8	4,8	8,6
LBP	Bayes	Normal	147,6	12,8	160,4
	SVM	Linear	13,0	0,4	13,4
		RBF	8,4	2,2	10,6
		Polinomial	15,2	1,0	16,2
		Sigmoide	7,0	2,2	9,2
	MLP	Conf. 1	2210,0	1,8	2211,8
		Conf. 2	4640,4	2	4642,4
KNN	N = 1	0,2	8,6	8,8	
	N = 3	0,0	1,4	1,4	
	N = 5	0,2	1,4	1,6	
K-means			4,8	3,8	8,6
M. Centrais	Bayes	Normal	67,14	135,80	199,94
	SVM	Linear	12464,2	77,0	12541,2
		RBF	19840,6	23411,6	43252,199
		Polinomial	7665,2	9875,6	17540,801
		Sigmoide	29500,199	22983,6	52483,797
	MLP	Conf. 1	230502,203	366,0	230868,203
		Conf. 2	397162,594	371,8	397534,406
KNN	N = 1	5,4	3094500,5	3094506,0	
	N = 3	4,2	3212955,25	3212959,5	
	N = 5	4,2	3278905,5	3278909,75	
K-means			43,91	36978,25	37022,16
M. HU	Bayes	Normal	72,665	159,477	232,132
	SVM	Linear	14435,2	91,4	14526,601
		RBF	17941,199	18098,0	36039,199
		Polinomial	5108,4	2840,6	7949,0
		Sigmoide	35201,602	27293,0	62494,602
	MLP	Conf. 1	114089,797	434,6	114524,398
		Conf. 2	258006,594	443,2	258449,797
KNN	N = 1	5,4	4298112,5	4298117,9	
	N = 3	5,0	4437221,0	4437226,0	
	N = 5	5,2	4515119,0	4515124,2	
K-means			51,42	12053,67	12105,09
M. Estatísticos	Bayes	Normal	141,584	226,214	367,798
	SVM	Linear	12431,6	93,2	12524,8
		RBF	25554,4	28241,801	53796,203
		Polinomial	6322,8	3952,8	10275,6
		Sigmoide	39431,0	31745,4	71176,4
	MLP	Conf. 1	345515,812	457,8	345973,625
		Conf. 2	815079,188	455,2	815534,375
KNN	N = 1	7,667	4725178,0	4725185,667	
	N = 3	7,0	4707717,5	4707724,5	
	N = 5	7,0	4708149,0	4708156,0	
K-means			82,33	47061,92	47144,25

6.2.5 Comparação entre métodos Hold out e Leave one out

No que tange à utilização dos dados extraídos, o comportamento dos classificadores dos métodos hold out e leave one out foi idêntico. A classificação utilizando os bancos de dados gerados pelos extratores baseados nas texturas das imagens obteve valores superiores de acurácia, precisão, sensibilidade e f-score, além de tempos bastante reduzidos para treino e teste. Todavia as maiores taxas de acerto e precisão foram alcançadas pelas classificações que utilizaram o método de partição de dados hold out, as Tabelas 6.5 e 6.6 mostram as métricas das 3 melhores classificações do método hold out e as 3 melhores classificações do método leave one out. A melhor acurácia obtida pelo método hold out foi com o classificador KNN-1 e GLCM com 97,44% enquanto que o melhor resultado dessa métrica para o método leave one out foi obtido pelo classificador MLP-1 e GLCM com 86,44%. Ao analisar o tempo para aprendizado e teste dessas duas classificações, novamente o classificador que utilizou os dados particionados pelo método hold out obteve ampla vantagem realizando seu treino e teste 144 vezes mais rápido que o classificador com melhor acurácia do grupo leave one out.

Tabela 6.5: Métricas das 3 melhores classificações hold out

EXTRATOR	CLASSIFICADOR	ACURÁCIA	PPV	SENS	F-SCORE
GLCM	KNN-1	97,44%	96,71%	96,30%	98,25%
GLCM	KNN-3	95,48%	94,47%	93,73%	96,49%
GLCM	SVM-rbf	93,27%	94,59%	96,49%	96,49%

Tabela 6.6: Métricas das 3 melhores classificações leave one out

EXTRATOR	CLASSIFICADOR	ACURÁCIA	PPV	SENS	F-SCORE
GLCM	MLP-1	86,44%	69,08%	75,04%	76,84%
GLCM	MLP-2	82,64%	68,79%	70,64%	75,79%
Mom. estat.	SVM-rbf	81,80%	45,65%	40,34%	50,23%

6.2.6 Tempos de extração

A Tabela 6.7 apresenta os tempos de extração dos dados das imagens para cada um dos extratores utilizados, na Figura 6.27, temos esses mesmos dados apresentados em um diagrama de caixas.

Tabela 6.7: Tempos de extração de dados das fotomicrografias

EXTRATOR	TEMPO DE EXTRAÇÃO
GLCM	25,407 seg
LPB	7,475 seg
Momentos Centrais	13,727 seg
Momentos Estatísticos	22,635 seg
Momentos de Hu	17,290 seg

O banco de dados foi construído a partir das características relevantes de 93 fotomicrografias e a quantidade de dados gerados por cada extrator foi: momentos centrais com 7 atributos, momentos estatísticos 10 atributos, momentos de HU 7 atributos, GLCM 14 atributos e LBP 48 atributos. Realizando uma comparação direta entre os dois extratores que obtiveram os melhores resultados nas métricas de classificação, o extrator LBP, mesmo com uma quantidade bem maior de atributos extraídos, foi 3,4 vezes mais rápido que o extrator GLCM.




Figura 6.27: Diagrama de caixas dos tempos de extração

6.2.7 Matrizes de confusão

A matriz de confusão é uma ferramenta bastante efetiva na avaliação da eficiência de um classificador computacional. De acordo com [Monard e Baranauskas \(2003\)](#) essa matriz tem a função de validar o aprendizado supervisionado. De forma prática essa matriz permitiu comparar a base de dados utilizada para teste com os dados utilizados para treino, indicando seu percentual de acerto e erro na classificação dos aços elétricos. Os valores constantes na diagonal principal indicam os acertos enquanto que os demais dados são referentes aos erros de classificação. A partir dos dados extraídos da matriz de confusão são calculadas as métricas utilizadas para avaliação dos classificadores, essas são acurácia, sensibilidade, f-score, e ppv(positive predictive values).

As Tabelas 6.8 e 6.9 apresentam as matrizes de confusão com as combinações de classificadores e extratores para os métodos de validação cruzada hold out e leave one out que apresentaram os melhores resultados de acurácia.

Tabela 6.8: Matrizes confusão método Hold out

MATRIZ DE CONFUSÃO - MÉTODO HOLD OUT - AÇO ELÉTRICO GNO												
MLP 1 - GLCM							MLP 2 - GLCM					
classe	0	1	2				0	1	2			
0	42,11	4,21	0,00				43,16	2,63	0,00			
1	2,63	27,89	2,63				1,58	27,37	0,53			
2	0,00	2,11	18,42				0,00	4,21	20,53			
KNN 5 - GLCM							SVM rbf - GLCM					
classe	0	1	2				0	1	2			
0	42,11	5,26	0,00				44,74	2,63	2,63			
1	2,63	23,68	0,00				0,00	31,58	0,00			
2	0,00	5,26	21,05				0,00	0,00	18,42			

Tabela 6.9: Matrizes confusão método Leave one out

MATRIZ DE CONFUSÃO - MÉTODO LEAVE ONE OUT - AÇO ELÉTRICO GNO															
MLP 1 - GLCM					MLP 2 - GLCM				MLP 2 - LBP				KNN 1 - LBP		
classe	0	1	2		0	1	2		0	1	2		0	1	2
0	34,21	15,79	0,00		33,68	16,84	0,00		42,63	16,32	0,00		44,74	13,16	5,26
1	10,53	18,42	8,42		11,05	16,84	7,89		2,11	17,89	13,68		0,00	21,05	5,26
2	0,00	0,00	12,63		0,00	0,53	13,16		0,00	0,00	7,37		0,00	0,00	10,53
SVM linear - LBP					MLP 1 - MOM estat				MLP 2 - MOM est				SVM poly-MOM est		
classe	0	1	2		0	1	2		0	1	2		0	1	2
0	42,11	10,53	0,00		81,85	17,21	0,94		81,85	17,21	0,94		81,85	17,21	0,94
1	2,63	23,68	5,26		0,00	0,00	0,00		0,00	0,00	0,00		0,00	0,00	0,00
2	0,00	0,00	15,79		0,00	0,00	0,00		0,00	0,00	0,00		0,00	0,00	0,00

Capítulo 7

CONCLUSÕES E CONTRIBUIÇÕES

O presente trabalho apresenta uma inovadora metodologia na classificação de aços elétricos de grãos não orientados quanto à sua eficiência eletromagnética. Tradicionalmente essa classificação é realizada com base na análise da textura cristalográfica e da curva de histerese desse material. O estudo realizado obteve êxito no desenvolvimento, implementação e teste de uma solução computacional com elevado percentual de acerto e confiabilidade na classificação desses aços elétricos, utilizando apenas a análise de suas fotomicrografias, suplantando as limitações referentes à análise convencional realizada por especialistas, apresentando como maior contribuição a automatização rápida e precisa desse processo de classificação.

Após as etapas referentes à preparação metalográfica das amostras e aquisição das imagens por microscopia ótica, as classes foram definidas com base no estado de recristalização do aço estudado, as informações a respeito dessas classes foram utilizadas para o treinamento do sistema. Em seguida foram realizados testes, utilizando a biblioteca Opencv na plataforma de programação C, combinando 5 extratores de atributos: GLCM, LBP, momentos centrais, momentos estatísticos e momentos de Hu, com 11 classificadores:

KNN com 1, 3 e 5 vizinhos, SVM com kernel sigmoide, polinomial, rbf e linear, K-means, Bayes, MLP 1 e MLP 2, combinados ainda com 2 métodos distintos para separação e seleção de dados para treino e teste: hold out e leave one out. Todos os classificadores foram testados com todos os extratores e ainda com os métodos de partição de dados, de modo a encontrar a melhor combinação para essa aplicação.

O melhor resultado em termos de acerto na classificação foi com a utilização do banco de dados gerado pelo extrator GLCM e método de partição de dados hold out, combinados com o classificador KNN com 1 vizinho mais próximo. As métricas de avaliação para esse modelo foram 97,44% de acurácia, 96,71% de precisão, sensibilidade de 96,3% e f-score de 98,21%. A classificação utilizada foi a supervisionada, o classificador foi treinado com base nas análises das curvas de histerese e textura cristalográfica do material. O tempo para treino foi de 7.200 ms e o tempo de teste 15.400 ms totalizando 22.600 ms, o que demonstra que o sistema obteve excelentes níveis de precisão e confiabilidade com tempo bastante reduzido de processamento.

A partir dos dados de validação do sistema de extração de características e classificação acima descrito, conclui-se que o modelo é eficaz, dentro da faixa de tolerância admitida, para utilização a nível acadêmico por estudantes, engenheiros, pesquisadores e especialistas, das áreas de energias renováveis com foco em eficiência energética, engenharia e ciência dos materiais ou como caso de estudo na área de visão computacional, sendo uma opção viável, confiável e rápida na obtenção de resultados precisos de classificação.

7.1 Trabalhos futuros

A perspectiva para trabalhos futuros está associada ao desenvolvimento de estudos nas áreas de ciência dos materiais e processamento e análise digital de imagens, são eles:

- Processamento e análise digital das imagens de aços elétricos de grãos não orientados, adquiridas com microscópio eletrônico de varredura(MEV);

- Sistema de visão computacional para identificação da componente Goss nas imagens de textura cristalográfica de aços elétricos de grãos não orientados;
- Sistema de visão computacional para cálculo da área interna das curvas de histerese de aços elétricos de grãos não orientados;
- Classificação de aços elétricos de grãos não orientados, quanto a sua eficiência eletromagnética utilizando processamento e análise digital de imagens de suas curvas de histerese e textura cristalográfica;
- Determinação das faixas de valores percentuais de perdas magnéticas totais para cada uma das três classes de aços elétricos utilizadas nesse trabalho.

Referências Bibliográficas

- Ahonen, T., Hadid, A., e Pietikainen, M. (2006). Face description with local binary patterns: Application to face recognition. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 28(12):2037–2041.
- Al-Kadi, O. S. (2015). A multiresolution clinical decision support system based on fractal model design for classification of histological brain tumours. *Computerized Medical Imaging and Graphics*, 41:67–79.
- Albuquerque, V. d. et al. (2007). *Sistema de visão computacional para a caracterização da grafita usando microfotografias*. PhD thesis, Dissertação (Departamento de Engenharia de Teleinformática) Universidade Federal do Ceará, Fortaleza, Ceará.
- Almeida, T. A. e Yamakami, A. (2011). Redução de dimensionalidade aplicada na classificação de spams usando filtros bayesianos. *Revista Brasileira de Computação Aplicada*, 3(1):16–29.
- Bagesteiro, L. D. (2015). *Classificação de Padroes Radiológicos por Blocos em Imagens não Segmentadas de Tomografia Computadorizada*. PhD thesis, Universidade Federal do Paraná.
- Baraldi, A. e Parmiggiani, F. (1995). An investigation of the textural characteristics associated with gray level cooccurrence matrix statistical parameters. *IEEE Transactions on Geoscience and Remote Sensing*, 33(2).

- Bertotti, G. (1998). *Hysteresis in magnetism: for physicists, materials scientists, and engineers*. Academic press.
- Bezdek, J. C., Chuah, S. K., e Leep, D. (1986). Generalized k-nearest neighbor rules. *Fuzzy Sets and Systems*, 18(3):237–256.
- Billy, L., Arvisenet, G., Poinot, P., Chevallier, S., Royer, G., Vigneau, E., e Prost, C. (2006). Image texture analysis of apples broken down in a mastication simulator prototype. Em *13th World Congress of Food Science & Technology 2006*, pgs. 1358–1358.
- Bishop, C. M. (2006). Pattern recognition. *Machine Learning*.
- Bohn, F., Gündel, A., Severino, A., Landgraf, F., e Sommer, R. (2004). Propriedades magnéticas de aços elétricos de grão não-orientado. Em *Anais do XVI Congresso Brasileiro de Engenharia e Ciências dos Materiais*.
- Bozorth, R. (1951). Ferromagnetism new york. *Van No strand*, pg. 763.
- Braga, A. d. P., Carvalho, A., e Ludermir, T. B. (2000). *Redes neurais artificiais: teoria e aplicações*. Livros Técnicos e Científicos.
- Bresciani Filho, E., Zavaglia, C., Button, S., Gomes, E., e Nery, F. (1991). *Conformação plástica dos metais*. Unicamp.
- Brissonneau, P. (1984). Non-oriented electrical sheets. *Journal of magnetism and magnetic materials*, 41(1):38–46.
- Bunge, H.-J. (2013). *Texture analysis in materials science: mathematical methods*. Elsevier.
- Burgers, W. (1963). Principles of recrystallization. Em *The Art and Science of Growing Crystals*, pgs. 416–450. Wiley New York.

- Callister, W. D. e Rethwisch, D. G. (2007). *Materials science and engineering: an introduction*, volume 7. Wiley New York.
- Campos, M. d. (2000). Microestrutura, textura e propriedades magnéticas em aços elétricos. *Escola Politécnica da Universidade de São Paulo*, pg. 303.
- Campos, M. F. d., Yonamine, T. F., Fukuhara, M., e Missell, F. P. (2006). Aços elétricos semiprocessados para motores elétricos.
- Cavalcante, T. d. S., Rebouças Filho, P., de Albuquerque, V. H. C., e da Silva, J. M. R. (2009). Aplicação de técnicas de processamento e análise de imagem na análise automática da quantidade e do tamanho do grão em imagens metalográficas. Em *Congresso de Métodos Numéricos en Ingeniería 2009 (MetNum2009)*.
- Chin, G. e Wernick, J. (1980). Soft magnetic metallic materials. *Handbook of Ferromagnetic Materials*, 2:55–188.
- Connell, S. D. e Jain, A. K. (2001). Template-based online character recognition. *Pattern Recognition*, 34(1):1–14.
- Cortez, P. C., de Albuquerque, V. H. C., de Alexandria, A. R., , e Tavares, J. M. R. (2009). Evaluation of multilayer perceptron and self-organizing map neural network topologies applied on microstructure segmentation from metallographic images. *NDT & E International*, 42(7):644–651.
- Cover, T. e Hart, P. (1967). Nearest neighbor pattern classification. *IEEE transactions on information theory*, 13(1):21–27.
- Crammer, K. e Singer, Y. (2002). On the algorithmic implementation of multiclass kernel-based vector machines. *The Journal of Machine Learning Research*, 2:265–292.
- Czachorski, T., Kozielski, S., e Stanczyk, U. (2011). *Man-Machine Interactions 2*. Advances in Intelligent and Soft Computing. Springer Berlin Heidelberg.

- de Albuquerque, V. H. C., Tavares, J. M. R., e Cortez, P. C. (2011). Uma abordagem computacional para segmentação das microestruturas do ferro fundido branco hipoeutético baseado em morfologia matemática. Em *Actas do 10º Congresso Iberoamericano de Engenharia Mecânica (CIBEM 10)*.
- de Sampaio, W. B., Silva, A. C., de Paiva, A. C., e Gattass, M. (2015). Detection of masses in mammograms with adaption to breast density using genetic algorithm, phylogenetic trees, lbp and svm. *Expert Systems with Applications*, 42(22):8911–8928.
- Dietterich, T. G. (1997). Machine-learning research. *AI magazine*, 18(4):97.
- Domingos, P. e Pazzani, M. (1997). On the optimality of the simple bayesian classifier under zero-one loss. *Machine learning*, 29(2-3):103–130.
- Duda, R. O., Hart, P. E., e Stork, D. G. (2012). *Pattern classification*. John Wiley & Sons.
- Engler, O. e Randle, V. (2009). *Introduction to texture analysis: macrotexture, microtexture, and orientation mapping*. CRC press.
- Falcão, A. X. (2005). Introdução ao processamento de imagens digitais. *Material disponível na Internet. UNICAMP, São Paulo*.
- Flusser, J., Suk, T., Boldys, J., e Zitova, B. (2015). Projection operators and moment invariants to image blurring. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 37(4):786–802.
- Freitas, F. N. C. (2003). Adequabilidade das condições de laminação de um aço baixo-carbono à estampagem profunda.
- Freitas, F. N. C. (2011). *Influencia da recristalizacao no comportamento da textura cristalografica e nas perdas magneticas por histerese de um aco eletrico GNO*. PhD thesis, Universidade Federal do Ceara.

- Furey, T. S., Cristianini, N., Duffy, N., Bednarski, D. W., Schummer, M., e Haussler, D. (2000). Support vector machine classification and validation of cancer tissue samples using microarray expression data. *Bioinformatics*, 16(10):906–914.
- Gnecco, B. B., Cabral, M. C., de Moraes, R. M., e dos Santos Machado, L. (2001). Um sistema de visualização imersivo e interativo de apoio ao ensino de classificação de imagens. *SVR 2001*, pgs. 291–301.
- Gomes, F. O. e Paciornik, S. (2005). Automatic classification of graphite in cast iron. *Microscopy and Microanalysis*, 11(04):363–371.
- Gomes, O. (2007). *Microscopia co localizada, novas possibilidades na caracterizacao dos minérios*. PhD thesis, Pontificia Universidade catolica do Rio de Janeiro.
- Gonzalez, R. C. e Woods, R. E. (2000). *Processamento de imagens digitais*. Edgard Blucher.
- Goss, N. P. (1934). Electrical sheet and method and apparatus for its manufacture and test. US Patent 1,965,559.
- Guo, G., Li, S. Z., e Chan, K. (2000). Face recognition by support vector machines. Em *Automatic Face and Gesture Recognition, 2000. Proceedings. Fourth IEEE International Conference on*, pgs. 196–201. IEEE.
- Haralick, R., Shanmugam, K., e Dinstein, I. (1973). Textural features for image classification. *Systems, Man and Cybernetics, IEEE Transactions on*, SMC-3(6):610–621.
- Haralick, R. M. (1979). Statistical and structural approaches to texture. *Proceedings of the IEEE*, 67(5):786–804.
- Hu, M.-K. (1962). Visual pattern recognition by moment invariants. *information Theory, IRE Transactions on*, 8(2):179–187.

- Hubert, O., Daniel, L., e Billardon, R. (2003). Experimental analysis of the magnetoelastic anisotropy of a non-oriented silicon iron alloy. *Journal of Magnetism and Magnetic Materials*, 254:352–354.
- Hug, E., Hubert, O., e Clavel, M. (1997). Some aspects of the magnetomechanical coupling in the strengthening of nonoriented and grain-oriented 3% sife alloys. *Magnetics, IEEE Transactions on*, 33(1):763–771.
- Humphreys, Rollett, A. a. M. a. R. G. S. e Hatherly (2004). *Recrystallization and related annealing phenomena*. Elsevier.
- Jain, A. K., Duin, R. P., e Mao, J. (2000). Statistical pattern recognition: A review. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 22(1):4–37.
- Joachims, T. (1998). *Text categorization with support vector machines: Learning with many relevant features*. Springer.
- Justino, E. J., Bortolozzi, F., e Sabourin, R. (2003). An off-line signature verification method based on svm classifier and graphometric features.
- Kohavi, R. et al. (1995). A study of cross-validation and bootstrap for accuracy estimation and model selection. Em *Ijcai*, volume 14, pgs. 1137–1145.
- Kohavi, R., Sommerfield, D., e Dougherty, J. (1996). Data mining using 𝓂 𝓁 𝒸++ a machine learning library in c++. Em *Tools with Artificial Intelligence, 1996., Proceedings Eighth IEEE International Conference on*, pgs. 234–245. IEEE.
- Kovac, F., Dzubinskỳ, M., e Sidor, Y. (2004). Columnar grain growth in non-oriented electrical steels. *Journal of Magnetism and Magnetic Materials*, 269(3):333–340.
- Landgraf, F. J., Takanohashi, R., e Campos, M. d. (2001). Tamanho de grão e textura dos aços elétricos de grão não-orientado. Em *Workshop sobre textura e relações de Orientação: Deformação Plástica, Recristalização, crescimento de Grão*.

- Landgraf, F. J. G. (2002). Propriedades magnéticas de aços para fins elétricos. *Aços: perspectivas para os próximos*, 10:109–128.
- Licciardi, G., Villa, A., Dalla Mura, M., Bruzzone, L., Chanussot, J., e Benediktsson, J. (2012). Retrieval of the height of buildings from worldview-2 multi-angular imagery using attribute filters and geometric invariant moments. *Selected Topics in Applied Earth Observations and Remote Sensing, IEEE Journal of*, 5(1):71–79.
- Liela Khobanizad, Mahmood Khobanizad, B. V. H. C. (2016). Implement of face recognition in android platform by using opencv and lbt algorithm. *International Journal of Wireless Communications and Mobile Computing*, 4:25–31.
- Linder, N., Konsti, J., Turkki, R., Rahtu, E., Lundin, M., Nordling, S., Haglund, C., Ahonen, T., Pietikäinen, M., e Lundin, J. (2012). Identification of tumor epithelium and stroma in tissue microarrays using texture analysis. *Diagnostic pathology*, 7(1):1.
- Luo, Y., Wu, C.-m., e Zhang, Y. (2013). Facial expression recognition based on fusion feature of pca and lbp with svm. *Optik-International Journal for Light and Electron Optics*, 124(17):2767–2770.
- Marques Filho, O. e Neto, H. V. (1999). *Processamento digital de imagens*. Brasport.
- Mathworks (2016). Matlab documentation, help online for matlab.
- Máximo, O. A. e Fernandes, D. (2003). Uso de graus de confiança das classes em classificadores bayesianos. *Simpósio Brasileiro de Sensoriamento Remoto*, 11:2083–2090.
- Melo, J., Pimenta, J., Silva, A., e Cunha, M. (1982). A produção de aços planos especiais da acesita: Inoxidáveis e siliciosos de grão orientado e de grão não orientado.
- Minsky, M. e Papert, S. (1969). Perceptrons.

- Mitchell, T. M. (1997). Machine learning. *Boston et al.*
- Monard, M. C. e Baranauskas, J. A. (2003). Conceitos sobre aprendizado de máquina. *Sistemas Inteligentes-Fundamentos e Aplicações*, 1(1).
- Moraes, R. M. d. (1992). *Implementação de um sistema contextual de classificação de imagens orbitais compatível com o sistema SITIM*. PhD thesis, Dissertação de Mestrado, UFPb, 1992, 100 pg.
- Moreira, M. A. (2005). *Fundamentos do sensoriamento remoto e metodologias de aplicação*. UFV.
- Ojala, T., Pietikäinen, M., e Harwood, D. (1996). A comparative study of texture measures with classification based on featured distributions. *Pattern recognition*, 29(1):51–59.
- Osuna, E., Freund, R., e Girosi, F. (1997). Training support vector machines: an application to face detection. Em *Computer vision and pattern recognition, 1997. Proceedings., 1997 IEEE computer society conference on*, pgs. 130–136. IEEE.
- Padilha, A. F. e Siciliano, F. J. (2005). *Encruamento, recristalização, crescimento de grão e textura*. ABM.
- Papa, J. P., De Albuquerque, V. H. C., Falcão, A. X., e Tavares, J. M. R. (2010). Fast automatic microstructural segmentation of ferrous alloy samples using optimum-path forest. Em *International Symposium Computational Modeling of Objects Represented in Images*, pgs. 210–220. Springer.
- Pedrini, H. e Schwartz, W. R. (2008). *Análise de imagens digitais: princípios, algoritmos e aplicações*. Thomson Learning.
- Peng, C. e Wen, X. (1999). Recent applications of artificial neural networks in forest resource management: an overview. *Transfer*, 1(X2):W1.

- Pratt, W. K. (1991). Digital image processing, new-york. NY: *John Wiley and Sons*.
- Ramalho, G. L. B., Rebouças Filho, P. P., Medeiros, F. N. S. d., e Cortez, P. C. (2014). Lung disease detection using feature extraction and extreme learning machine. *Revista Brasileira de Engenharia Biomédica*, 30(3):207–214.
- Reboucas Filho, Neto, E. C., Cortez, P., Cavalcante, T., da Silva Filho, P., e Holanda, M. (2015a). Supervised enhancement filter applied to fissure detection. Em *VI Latin American Congress on Biomedical Engineering CLAIB 2014, Paraná, Argentina 29, 30 & 31 October 2014*, pgs. 337–340. Springer.
- Reboucas Filho, P. P., Moreira, F. D. L., Xavier, F. G. d. L., Gomes, S. L., Santos, J. C. d., Freitas, F. N. C., Freitas, R. G., et al. (2015b). New analysis method application in metallographic images through the construction of mosaics via speeded up robust features and scale invariant feature transform. *Materials*, 8(7):3864–3882.
- Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, 65(6):386.
- S, S. e Haykin (2009). *Neural networks and learning machines*, volume 3. Pearson Education Upper Saddle River.
- Santos, A. A. e Schiel, U. (2012). Classificação contínua de documentos com vocabulários temáticos dinâmicos para a desambiguação de termos. *VIII Simpósio Brasileiro de Sistemas de Informação(SBSI 2012)*. p, pgs. 672–677.
- Shimanaka, H., Ito, Y., Matsumara, K., e Fukuda, B. (1982). Recent development of non-oriented electrical steel sheets. *Journal of Magnetism and Magnetic Materials*, 26(1):57–64.
- Soares, J. (2007). *Segmentação de vasos sanguíneos em imagens de retina usando*

- wavelets e classificadores estatísticos*. PhD thesis, Dissertação de Mestrado. Instituto de Matemática e Estatística. Universidade de São Paulo, São Paulo, Brasil.
- Steinwart, I. e Christmann, A. (2008). *Support vector machines*. Springer Science & Business Media.
- Stojakovic, D. (2008). *Microstructure evolution in deformed and recrystallized electrical steel*. PhD thesis, Drexel University.
- Theodoridis, S. e Koutroubas, K. (2003). Pattern recognition.
- Traina, A. J. M., Traina, C., Bueno, J. M., Chino, F. J. T., e Azevedo-Marques, P. (2003). Efficient content-based image retrieval through metric histograms. *World Wide Web*, 6(2):157–185.
- Trier, Ø. D., Jain, A. K., e Taxt, T. (1996). Feature extraction methods for character recognition-a survey. *Pattern recognition*, 29(4):641–662.
- Vapnik, V. N. (1999). An overview of statistical learning theory. *Neural Networks, IEEE Transactions on*, 10(5):988–999.
- Viana, S. (2001). Deformação, recristalização textura. *Apostila do curso de educação continuada da Associação Brasileira de metalurgia e materiais*, pg. 16.
- Werner, F. e Jaffee, R. (1992). Energy-efficient steels for motor laminations. *Journal of Materials Engineering and Performance*, 1(2):227–234.
- Wong, W.-H., Siu, W.-C., e Lam, K.-M. (1995). Generation of moment invariants and their uses for character recognition. *Pattern Recognition Letters*, 16(2):115–123.
- Yang, B. e Chen, S. (2013). A comparative study on local binary pattern (lbp) based face recognition: Lbp histogram versus lbp image. *Neurocomputing*, 120:365–379.

- Yang, J., Xiong, N., Vasilakos, A., Fang, Z., Park, D., Xu, X., Yoon, S., Xie, S., e Yang, Y. (2011). A fingerprint recognition scheme based on assembling invariant moments for cloud computing communications. *Systems Journal, IEEE*, 5(4):574–583.
- Yao, Y., Marcialis, G. L., Pontil, M., Frasconi, P., e Roli, F. (2001). A new machine learning approach to fingerprint classification. Em *AI* IA 2001: Advances in Artificial Intelligence*, pgs. 57–63. Springer.
- Zien, A., Rätsch, G., Mika, S., Schölkopf, B., Lengauer, T., e Müller, K.-R. (2000). Engineering support vector machine kernels that recognize translation initiation sites. *Bioinformatics*, 16(9):799–807.