



SENAI CIMATEC

**PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM
COMPUTACIONAL E TECNOLOGIA INDUSTRIAL**
Mestrado em Modelagem Computacional e Tecnologia Industrial

Dissertação de Mestrado

**Reconhecimento de Objetos utilizando Redes
Neurais Artificiais e Geometria Fractal**

Apresentada por: Cândido Regis de Brito Bisneto
Orientador: Josemar Rodrigues de Souza

Maio de 2011

Cândido Regis de Brito Bisneto

Reconhecimento de Objetos utilizando Redes Neurais Artificiais e Geometria Fractal

Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Modelagem Computacional e Tecnologia Industrial, Curso de Mestrado em Modelagem Computacional e Tecnologia Industrial do SENAI CIMATEC, como requisito parcial para a obtenção do título de **Mestre em Modelagem Computacional e Tecnologia Industrial**.

Área de conhecimento: Interdisciplinar

Orientador: Josemar Rodrigues de Souza
SENAI CIMATEC

Salvador
SENAI CIMATEC
2011

B862r

Brito Bisneto, Cândido Regis de.

Reconhecimento de objetos utilizando redes neurais artificiais e geometria fractal. / Cândido Regis de Brito Bisneto. 2011. 91f.; il.; color.

Orientador: Prof^o Dr^o. Josemar Rodrigues de Souza.

Dissertação - Faculdade de Tecnologia Senai-CIMATEC, Mestrado em Modelagem Computacional e tecnologia Industrial, 2011.

1. Redes neurais artificiais. 2. Processamento de imagens. 3. Reconhecimento de objetos. I. Faculdade de Tecnologia Senai-CIMATEC. II. Souza, Josemar Rodrigues de. IV. Título.

CDD: 006.3

Nota sobre o estilo do PPGMCTI

Esta dissertação de mestrado foi elaborada considerando as normas de estilo (i.e. estéticas e estruturais) propostas aprovadas pelo colegiado do Programa de Pós-graduação em Modelagem Computacional e Tecnologia Industrial e estão disponíveis em formato eletrônico (*download* na Página Web http://ead.fieb.org.br/portal_faculdades/dissertacoes-e-teses-mcti.html ou solicitação via e-mail à secretaria do programa) e em formato impresso somente para consulta.

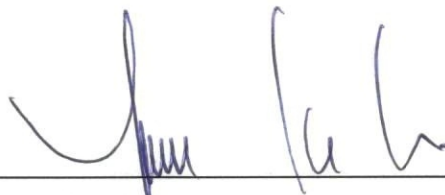
Ressalta-se que o formato proposto considera diversos itens das normas da Associação Brasileira de Normas Técnicas (ABNT), entretanto opta-se, em alguns aspectos, seguir um estilo próprio elaborado e amadurecido pelos professores do programa de pós-graduação supracitado.

SENAI CIMATEC

Programa de Pós-graduação em Gestão e Tecnologia Industrial
Mestrado em Modelagem Computacional e Tecnologia Industrial

A Banca Examinadora, constituída pelos professores abaixo listados, leram e recomendam a aprovação da Dissertação de mestrado, intitulada “Reconhecimento de Objetos utilizando Redes Neurais Artificiais e Geometria Fractal”, apresentada no dia 12 de maio de 2011, como requisito parcial para a obtenção do Título de **Mestre em Modelagem Computacional e Tecnologia Industrial**.

Orientador:



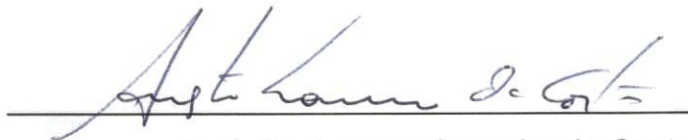
Prof. Dr. Josemar Rodrigues de Souza
Faculdade de Tecnologia Senai Cimatec

Membro interno:



Prof. Dr. Marcelo Albano Moret Simões Gonçalves
Faculdade de Tecnologia Senai Cimatec

Membro externo:



Prof. Dr. Augusto Loureiro da Costa
Universidade Federal da Bahia

*Dedico este trabalho a toda minha família,
em especial, aos meus pais,
minha amada mãe Vasti e
meu pai Henrique, e
minhas irmãs Lorena, Patrícia e Rose.
Amo vocês.*

Aos que passam pela nossa vida...

*Cada um que passa em nossa vida
passa sozinho...
Porque cada pessoa é única para nós,
e nenhuma substitui a outra...
Cada um que passa em nossa vida
passa sozinho,
mas não vai só...
Cada um que passa em nossa vida
leva um pouco de nós mesmos
e nos deixa um pouco de si mesmo...
Há os que levam muito,
mas não há os que não levam nada...
Há os que deixam muito,
mas não há os que não deixam nada...
Esta é a mais bela realidade da vida,
a prova tremenda de que cada um é importante
e que ninguém se aproxima do outro por acaso...*

SAINT-EXUPERRY

Agradecimentos

“O degrau de uma escada não serve simplesmente para que alguém permaneça em cima dele, destina-se a sustentar o pé de um homem pelo tempo suficiente para que ele coloque o outro um pouco mais alto”. THOMAS HUXLEY

Em primeiro lugar, agradeço a Deus pela vida e por ajudar-me em mais uma das minhas caminhadas, pois sem ele nada disso seria possível.

À minha mãe, meu pai (*in memoriam*), minhas irmãs, que são o chão que me sustenta e o ar que respiro, obrigado pelo carinho, compreensão, por compartilhar comigo minhas alegrias e tristezas, aflições e alívios e estarem comigo nos momentos difíceis. Em especial à minha mãe, Vasti, que foi, é e sempre será a estrela que me guia nesta vida, o meu exemplo de competência pessoal e profissional. À minha irmã Lorena, que sempre me apoiou, ajudou e incentivou. Ao meu pai Henrique e minhas queridas irmãs Patrícia e Rose, que apesar das circunstâncias foram um apoio essencial para mim.

À minha família como um todo, em especial à minha tia Nega, que me deu o empurrãozinho necessário para iniciar esta etapa na minha vida. E à minha tia Bete, por ceder parte de seu refúgio, para abrigar uma mente que precisava de um pouco de silêncio.

Aos amigos-irmãos Abércio, Alex, Carol, Lucas e Mirna que apesar da falta dos laços sanguíneos, são irmãos de coração, grandes amigos e parceiros de todas as horas. Obrigado pela compreensão nos diversos não recebidos pelos convites de saídas e festas ao longo desse tempo, e pelo incentivo em continuar. Aos grandes amigos Irani, Márcia, Samara, Andressa, Fabrício e aos aqui não citados, mas que de uma forma ou outra, me ajudaram a conquistar mais uma vitória na minha vida.

À Faculdade de Tecnologia Senai Cimatec, pela oportunidade de realização do curso de mestrado.

Ao Prof. Josemar Rodrigues de Souza, pela confiança, orientação, disposição, bom humor, amizade e paciência.

À Fundação de Amparo e Pesquisa do Estado da Bahia (FAPESB), pelo suporte financeiro durante a pesquisa e execução do trabalho.

Aos Membros da Banca Examinadora, por aceitarem o convite para avaliar este trabalho, e pelas críticas e sugestões apresentadas.

Aos tantos professores do instituto, que ao longo desses dois anos, puderam transmitir um pouco do conhecimento inestimável deles.

Aos colegas de mestrado, pela companhia nas aulas, pelas boas conversas e pela troca de conhecimento. Em especial, a minha querida amiga e colega de mestrado e curso, Patrícia, por todo o apoio dado e idéias compartilhadas.

À todos os funcionários do Senai Cimatec, em especial a Secretaria e Coordenação da Pós-Graduação, pela assistência e paciência ao longo do curso.

Enfim, a todos vocês que fizeram parte desta etapa da minha vida, por este período de crescimento pessoal, profissional e intelectual, e que souberam compreender a dedicação e, por vezes, o isolamento necessário a conclusão deste trabalho perdoando minha omissão como filho, irmão, sobrinho, neto, e amigo, deixo aqui registrado, de alma e coração, o meu...

MUITO OBRIGADO.

Salvador, Brasil
12 de Maio de 2011

Cândido Regis de Brito Bisneto

Resumo

Esta dissertação apresenta um modelo computacional aplicado à Visão Computacional de um equipamento robótico. O modelo foi desenvolvido utilizando uma abordagem de Redes Neurais Artificiais e Geometria Fractal. O principal problema abordado foi o de reconhecimento e classificação de objetos por um robô autônomo. Este trabalho concentrou-se especificamente na visão artificial do dispositivo. As Redes Neurais foram desenvolvidas usando a arquitetura Multilayer Perceptron com o algoritmo de Retropropagação de Erro. Dentro do Processamento de Imagens Digital, a Dimensão Fractal pode ser utilizada como uma medida de características da complexidade de uma imagem, o que possibilita seu uso no reconhecimento de padrões e nas análises de formas e texturas. Em alguns trabalhos nota-se o uso das Redes Neurais Artificiais, do Processamento de Imagens Digitais e da Geometria Fractal como classificadores de dados, neste trabalho, procurou-se utilizá-las em conjunto para a classificação e reconhecimento dos objetos. O objetivo do trabalho foi desenvolver uma Rede Neural capaz de reconhecer o objeto e classificá-lo, segundo suas características, ao grupo o qual pertence. Inicialmente foram capturadas imagens através de equipamentos eletrônicos e via internet, o alvo da busca foram quatro diferentes tipos de parafusos. Nos grupos formados pelas imagens capturadas, 30% delas foram manipuladas manualmente para que apresentassem defeitos ou de fabricação ou de aquisição. Para as análises, a arquitetura da Rede Neural foi desenvolvida em três versões nas quais difere somente na quantidade de saídas. Como dados de entrada para o treinamento, as imagens adquiridas foram pré-processadas e transformadas em tons de cinza. Para a Dimensão Fractal, utilizou-se o método Box-Counting que utilizou o contorno do objeto para calcular o valor. Foram feitas duas simulações, a primeira utilizou a Dimensão Fractal como um dos parâmetros da Rede, na segunda esse dado foi descartado, para uma posterior comparação. Os resultados obtidos foram satisfatórios, atingindo uma média de 79% de acertos para o primeiro teste e de 67% para o segundo, diferença esta responsável pela Dimensão Fractal. A avaliação demonstra que o uso da fractalidade neste tipo de teste é válida e que o sistema visual desenvolvido é viável.

Palavras-chave: Redes Neurais Artificiais, Processamento de Imagens Digitais, Dimensão Fractal, Reconhecimento de Objetos.

Abstract

This masters thesis presents a computational model applied to Computer Vision of mechanical robot. The model was developed using an approach of Artificial Neural Networks and Fractal Geometry. The main problem was the recognition and classification of objects by an autonomous robot. This work focuses specifically on the artificial vision of the device. The Neural Networks were developed using the Multilayer Perceptron architecture and the Error Backpropagation algorithm. Inside the Digital Image Processing, the Fractal Dimension can be used like a measure of image's complex characteristics, allowing its use on the pattern recognition and on the analysis of shapes and textures. In some papers, the usage of Neural Networks, Digital Image Processing and Fractal Geometry are like data classifiers, and in this thesis, they're being used together for the recognition and classification of objects. This thesis's objective was to develop a Neural Network capable of recognize objects and classify them according to their characteristics to the group that they belong. Initially, images were captured through electronic devices and internet, the targets were four different types of screws. In the formed groups, 30% of them were manipulated manually to present some kind of defect by manufacturing or on the acquisition. To the analysis, the Neural Network architecture was developed in three versions, which differ in the output quantity. For the data entry to the training stage, the acquired images were preprocessed and transformed into greyscale images. For the Fractal Dimension, the Box-Counting method was used, it uses the object's edge to calculate the number of the dimension. Were made two simulations, the first one used the fractal dimension like one of the parameters for the Neural Network, and on the second, this number was discarded, for a further comparison. The obtained results were satisfactory, reaching an average of 79% of hit ratios for the first simulation and 67% for the second, and the fractal dimension was the responsible for this difference. The evaluation shows that the use of fractals is valid and the visual system developed is viable.

Keywords: Artificial Neural Networks, Digital Image Processing, Fractal Dimension, Object Recognition.

Sumário

1	Introdução	1
1.1	Definição do problema	5
1.2	Objetivo	6
1.3	Importância e Motivação da Pesquisa	6
1.4	Organização da Dissertação de Mestrado	6
2	Fundamentação Teórica e Estado da Arte no uso de Reconhecimento de Padrões e Objetos, Redes Neurais e Geometria Fractal	8
2.1	As Redes Neurais Artificiais	8
2.1.1	Topologias de Redes	9
2.1.2	Paradigmas de Aprendizagem	11
2.1.3	Avanços na utilização das Redes Neurais	12
2.2	Processamento Digital de Imagens para o Reconhecimento de Padrões . . .	13
2.2.1	Imagem Digital e o Pixel	14
2.2.1.1	Propriedade dos Pixels	15
2.2.2	Etapas do Processo	16
2.2.2.1	Aquisição da Imagem	16
2.2.2.2	Pré-Processamento e Segmentação	17
2.2.2.3	Representação e Descrição	18
2.2.2.4	Interpretação e Reconhecimento	18
2.2.3	A necessidade do Reconhecimento de Padrões	18
2.3	O uso da Dimensão Fractal em Pesquisas	19
2.3.1	Os Avanços	20
3	Modelo Computacional	21
3.1	Apresentação do Modelo	21
3.1.1	Objeto de Pesquisa	21
3.1.2	Diferencial da Pesquisa	23
3.2	Composição do Modelo	23
3.3	Etapas do Modelo	25
3.3.1	Processamento de Imagens	25
3.3.2	Geometria Fractal e sua Dimensão	25
3.3.3	Redes Neurais Artificiais	26
4	Trabalho Experimental e Desenvolvimento do Sistema	27
4.1	Desenvolvimento do Sistema	27
4.1.1	Implementação do Processamento de Imagens	27
4.1.1.1	Métodos de Processamento	28
4.1.2	Implementação da Dimensão Fractal	31
4.1.3	Rede Neural	32
4.2	O Sistema	32
4.2.1	Dados de Entrada	32
4.2.2	Componentes do Aplicativo	33

5	Experimentos e Resultados	38
5.1	Base de Imagens	38
5.2	Preparação dos Dados e Configuração da Rede	38
5.2.1	Arquitetura da Rede Neural	39
5.2.2	Classes de Objetos	40
5.2.3	Métricas de Avaliação	40
5.2.3.1	Matriz de Confusão	40
5.2.3.2	Índice Kappa	41
5.2.3.3	Parâmetros de Avaliação dos Resultados	42
5.3	Descrição dos Experimentos Realizados	43
5.3.1	Descrição dos Cenários	43
5.3.1.1	Cenário 01	44
5.3.1.2	Cenário 02	45
5.3.1.3	Cenário 03	45
5.4	Análise e Discussão dos Resultados	46
5.4.1	Primeira Fase	46
5.4.1.1	Cenário 01	46
5.4.1.2	Cenário 02	47
5.4.1.3	Cenário 03	48
5.4.2	Segunda Fase	49
5.4.2.1	Cenário 01	49
5.4.2.2	Cenário 02	50
5.4.2.3	Cenário 03	51
5.4.3	Comparação dos Resultados	51
6	Considerações Finais	55
6.1	Conclusão	55
6.2	Atividades Futuras de Pesquisa	56
A	Algoritmo de Retropropagação de Erro	57
A.1	O Algoritmo	57
A.2	Os Passos do Algoritmo	57
B	Resultados Totais	60
B.1	Primeira Fase	60
B.1.1	Cenário 01	60
B.1.1.1	Cenário 01 - G01	60
B.1.1.2	Cenário 01 - G02	61
B.1.1.3	Cenário 01 - G03	61
B.1.1.4	Cenário 01 - G04	62
B.1.2	Cenário 02	62
B.1.3	Cenário 03	63
B.2	Segunda Fase	63
B.2.1	Cenário 01	64
B.2.1.1	Grupo G01	64
B.2.1.2	Grupo G02	64
B.2.1.3	Grupo G03	65
B.2.1.4	Grupo G04	65
B.2.2	Cenário 02	66
B.2.3	Cenário 03	66

Referências

68

Lista de Tabelas

4.1	Tabela da quantidade de quadrados para o método Box-Counting	31
5.1	Tabela de topologias de rede submetidas ao sistema.	39
5.2	Parâmetros de treinamento da rede neural	39
5.3	Matriz de Confusão com duas classes. FONTE: (CONGALTON, 1991)	41
5.4	Tabela de medidas avaliatórias do Índice Kappa. FONTE: (CRUZ ELEAN- DRO S.; CARVALHO, 2008)	42
5.5	Especificação do Cenário 01.	44
5.6	Distribuição da quantidade de dados nas fases da rede neural no primeiro cenário.	44
5.7	Especificação do Cenário 02.	45
5.8	Distribuição da quantidade de dados nas fases da rede neural no segundo cenário.	45
5.9	Especificação do Cenário 03.	45
5.10	Distribuição da quantidade de dados nas fases da rede neural no terceiro cenário.	46
B.1	Matriz Confusão G01 - Cenário 01.	60
B.2	Tabela de resultado dos parâmetros do G01 - Cenário 01.	60
B.3	Matriz Confusão G02 - Cenário 01.	61
B.4	Tabela de resultado dos parâmetros do G02 - Cenário 01.	61
B.5	Matriz Confusão G03 - Cenário 01.	61
B.6	Tabela de resultado dos parâmetros do G03 - Cenário 01.	61
B.7	Matriz Confusão G04 - Cenário 01.	62
B.8	Tabela de resultado dos parâmetros do G04 - Cenário 01.	62
B.9	Matriz Confusão do Cenário 02 - Testes 01 e 02.	62
B.10	Tabela de resultado dos parâmetros do Cenário 02 - Testes 01 e 02.	62
B.11	Matriz Confusão do Cenário 03 - Teste 01.	63
B.12	Matriz Confusão da Cenário 03 - Teste 02.	63
B.13	Tabela de resultado dos parâmetros da Cenário 03 - Testes 01 e 02.. . . .	63
B.14	Matriz Confusão 2a. Fase - Cenário 01 - Classe G01.	64
B.15	Tabela de resultado dos parâmetros da 2a. Fase - Cenário 01 - Classe G01.	64
B.16	Matriz Confusão 2a. Fase - Cenário 01 - Classe G02.	64
B.17	Tabela de resultado dos parâmetros do 2a. Fase - Cenário 01 - Classe G02.	64
B.18	Matriz Confusão 2a. Fase - Cenário 01 - Classe G03.	65
B.19	Tabela de resultado dos parâmetros do 2a. Fase - Cenário 01 - Classe G03.	65
B.20	Matriz Confusão 2a. Fase - Cenário 01 - Classe G04.	65
B.21	Tabela de resultado dos parâmetros do 2a. Fase - Cenário 01 - Classe G04.	65
B.22	Matriz Confusão do Cenário 02 - Testes 01 e 02.	66
B.23	Tabela de resultado dos parâmetros do Cenário 02 - Testes 01 e 02.	66
B.24	Matriz Confusão da Simulação 03 - Teste 01.	67
B.25	Matriz Confusão da Simulação 03 - Teste 02.	67
B.26	Tabela de resultado dos parâmetros do Cenário 03 - Testes 01 e 02.. . . .	67

Lista de Figuras

1.1	Etapas básicas de um Processamento de Imagens. FONTE: (GONZALEZ RAFAEL C.; WOODS, 2002)	3
2.1	Modelo de Neurônio Simples. FONTE: (HAYKIN, 1998)	8
2.2	Tipos de função ativação. FONTE: (RAUBER, 1997)	9
2.3	Topologias de Redes de Propagação para Frente: (1) camada única, (2) com camada oculta. FONTE: (HAYKIN, 1998)	10
2.4	Topologias de Redes Recorrentes: (1) camada única, (2) com camada oculta. FONTE: (HAYKIN, 1998)	11
2.5	Forma de leitura e representação de uma imagem digital em aspecto matemático. FONTE: Adaptado de (CARVALHO, 2003) e (GONZALEZ RAFAEL C.; WOODS, 2002)	15
2.6	Propriedade de Vizinhança. (a) D_{4n} , pixels conectados pela borda, (b) D_{4d} , pixels conectados pela diagonal, e (c) D_8 , pixels conectados pelas bordas e pela diagonal. FONTE: Adaptado de (PAVIM X A.; ROLOFF, 2005)	16
2.7	Diferença da distância segundo as três abordagens de conectividade, para efeitos de exemplo utilizou-se a contagem de pixels como medida de distância. (a) utilizando D_{4n} , a distância seria igual a 8px, (b) D_{4d} e (c) D_8 , a distância para ambos seria de 4px. FONTE: Adaptado de (PAVIM X A.; ROLOFF, 2005).	16
2.8	Etapas do Processamento Digital de Imagens. FONTE: Adaptado de (GONZALEZ RAFAEL C.; WOODS, 2002)	16
2.9	Esquema do processo de formação da imagem. FONTE: (GONZALEZ RAFAEL C.; WOODS, 2002)	17
2.10	Exemplo de fractal auto-similar e independente de escala. FONTE: (ASSIS, 2008)	20
3.1	Componentes do parafuso, (a) Cabeça, (b) Corpo, (c) Extremidade. FONTE: (DESTEC, 2011)	21
3.2	Diferentes tipos de cabeça de parafuso. FONTE: (DESTEC, 2011)	22
3.3	Diferentes tipos de corpo de parafuso, (a) Ponta Agulha Rosqueado, (b) Ponta Broca Rosqueado, (c) Ponta Agulha Parcialmente Rosqueado e, (d) Ponta Broca Parcialmente Rosqueado. FONTE: (DESTEC, 2011)	22
3.4	Objetos de estudo.	23
3.5	Diagrama do modelo proposto.	24
3.6	Exemplificação das etapas do processamento de imagens. FONTE: Adaptado de (PAVIM X A.; ROLOFF, 2005)	25
3.7	Exemplo da malha do método Box-Counting. FONTE: (FERNANDES, 2007)	26
3.8	Modelo da RNA para o trabalho.	26
4.1	Filtros lineares Passa-Baixa 3x3:	29
4.2	Filtro linear Passa-Alta 3x3:	29
4.3	Imagem após as 3 primeiras etapas.	30
4.4	Algoritmo de dilatação por vizinhança D_8	30
4.5	Algoritmo de subtração de imagens.	31

4.6	Imagem resultante do processo de extração da borda.	31
4.7	Imagem do arquivo texto gerado contendo os valores dos pixels normalizados utilizados como dados de entrada da rede neural.	33
4.8	Interface do aplicativo desenvolvido.	33
4.9	Componentes da interface do aplicativo relacionadas à escolha do Cenário.	34
4.10	Componentes da interface responsáveis pela aquisição e informação de dados para a rede neural, e os componentes de Treinamento e Execução da RNA.	34
4.11	Componentes da interface que mostram os resultados obtidos.	35
4.12	Aplicativo com Cenário 01 selecionado e seus respectivos itens habilitados.	35
4.13	Cenário 02 escolhido e itens habilitados	36
4.14	Interface do aplicativo com o terceiro cenário escolhido e os itens desabilitados.	36
4.15	Imagem do aplicativo em execução.	37
5.1	Imagem de um objeto normal (a) e uma figura manipulada para ter defeito (b).	40
5.2	Diagrama dos experimentos realizados.	43
5.3	Gráfico dos resultados obtidos nos testes do Cenário 01 - Grupo 01 da primeira fase.	46
5.4	Gráfico dos resultados obtidos nos testes do Cenário 01 - Grupo 02 da primeira fase.	47
5.5	Gráfico dos resultados obtidos nos testes do Cenário 01 - Grupo 03 da primeira fase.	47
5.6	Gráfico dos resultados obtidos nos testes do Cenário 01 - Grupo 04 da primeira fase.	48
5.7	Gráfico dos resultados obtidos nos testes do Cenário 02 - Teste 01 da primeira fase.	48
5.8	Gráfico dos resultados obtidos nos testes do Cenário 02 - Teste 02 da primeira fase.	49
5.9	Gráfico dos resultados obtidos nos testes do Cenário 03 - Teste 01 da primeira fase.	49
5.10	Gráfico dos resultados obtidos nos testes do Cenário 03 - Teste 02 da primeira fase.	50
5.11	Gráfico dos resultados obtidos nos testes do Cenário 01 - Grupo 01 da segunda fase.	50
5.12	Gráfico dos resultados obtidos nos testes do Cenário 01 - Grupo 02 da segunda fase.	51
5.13	Gráfico dos resultados obtidos nos testes do Cenário 01 - Grupo 03 da segunda fase.	51
5.14	Gráfico dos resultados obtidos nos testes do Cenário 01 - Grupo 04 da segunda fase.	52
5.15	Gráfico dos resultados obtidos nos testes do Cenário 02 - Teste 01 da segunda fase.	52
5.16	Gráfico dos resultados obtidos nos testes do Cenário 02 - Teste 02 da segunda fase.	53
5.17	Gráfico dos resultados obtidos nos testes do Cenário 03 - Teste 01 da segunda fase.	53
5.18	Gráfico dos resultados obtidos nos testes do Cenário 03 - Teste 02 da segunda fase.	53

5.19	Gráfico comparativo das Taxas de Índice Kappa das duas fases.	54
5.20	Gráfico comparativo da diferença entre a taxa de acerto total e o índice kappa das duas fases.	54

Lista de Siglas

PPGMCTI ..	Programa de Pós-graduação em Modelagem Computacional e Tecnologia Industrial
PDI	Processamento Digital de Imagens
RNA	Redes Neurais Artificiais
MLP	Multilayer Perceptron
px	Pixels
RGB	Red Green Blue
PDI	Processamento Digital de Imagens
PCA	Análise de Componentes Principais

Introdução

Uma célebre frase de um autor desconhecido já dizia: “Uma imagem vale mais que mil palavras”, é assim que (GONZALEZ RAFAEL C.; WOODS, 2002) inicia seu trabalho sobre o Processamento de Imagens Digitais. Nele, os autores afirmam haver dois grande motivos para o interesse nesta recente área de pesquisa: (1) melhoria de informações para interpretação humana e, (2) no processamento de dados de imagem para armazenamento, transmissão e representação para percepção de máquinas autônomas. O rápido desenvolvimento das tecnologias permitiu que o uso de imagens expandisse para todos os lados, e atualmente, no que se trata de pesquisas científicas, tem um grande foco em Visão Computacional para dispositivos mecânicos autônomos. Contudo, há algum tempo atrás, atividades que envolviam imagens não eram simples de serem executadas.

Tendo basicamente a atividade humana como combustível para sua divulgação, as pesquisas que se baseavam em imagens não tinham como avançar muito, mas com o tempo isso foi mudando. Desde a Revolução Industrial, onde as máquinas começaram a substituir parte das atividades dos homens em algumas tarefas, até os dias atuais onde elas efetivamente os substituíram, a busca pela automatização de atividades foi crescendo. Através desta constante busca é que surgiu a Robótica. Ao contrário do que a maioria pensa, a robótica não se trata somente de máquinas com aspecto físico semelhante ao homem ou animais, vide andróides, ciborgues e etc. Mas trata-se de uma área de pesquisas tecnológicas que visa automatizar e otimizar processos (MACHADO KÁSSIO L.; RIBEIRO, 2009). Sua expansão é percebida em diversos aspectos, tais como a Indústria, o lar, o entretenimento, as pesquisas, entre outros.

Desde sua invenção, a Robótica possibilitou um grande crescimento nas atividades industriais. Pode-se afirmar que a maioria das Indústrias fazem uso de equipamentos robóticos em suas etapas de fabricação, sejam elas automobilísticas, aeronáuticas, alimentícias, etc. Dentro do mundo da robótica, há uma área que visa dar autonomia às máquinas, chamada de Robótica Autônoma. Seu objetivo principal é permitir aos dispositivos mecânicos tomarem decisões, tornando-os capazes de executar tarefas em diferentes meios sem a intervenção humana (BAYER, 2004).

Nas últimas décadas, os progressos no campo da robótica permitiram o desenvolvimento de tecnologias de ponta, possibilitando o uso de metodologias mais seguras, melhores e eficientes. Com isso, a robótica autônoma tornou-se de grande importância para os dias atuais, tanto para as indústrias quanto para as residências, visto que através dela é possível aumentar o lucro e a qualidade do produto, bem como reduzir os custos, e propor-

cionar um maior conforto e qualidade nos serviços oferecidos às pessoas (TORRES RUBIAO G.; MACHADO, 2005). Para alcançar esse nível de autonomia, as pesquisas foram intensificadas e novos métodos continuam sendo desenvolvidos para que tais equipamentos possam atuar sozinhos. Para isso, a utilização de sensores e atuadores torna-se de fundamental importância para a obtenção da autonomia robótica. Dentre muitas partes que auxiliam essas máquinas, os dispositivos de visão artificial, têm demonstrado grande eficiência no suporte aos equipamentos (ROSARIO, 2005) (FORESTI RENAN L; LORINI, 2005).

A área de estudos que investiga o uso da visão artificial é chamada de Visão Computacional. Os estudos envolvendo essa área, especificamente o reconhecimento de objetos, concentram-se basicamente numa tentativa de assemelhar-se à capacidade que o cérebro humano possui de reconhecer objetos em três dimensões (3D) baseando-se somente em uma imagem bidimensional (2D) (HOGENDOORN, 2006). Inspirado na visão humana, essa área visa estudar e desenvolver conjuntos de métodos e técnicas que permitam sistemas computacionais tornarem-se capazes de interpretar imagens. Entretanto, alcançar os mesmos níveis de reconhecimento visual humano é uma tarefa extremamente difícil (RODRIGUES P S.; ARAUJO, 2002).

Por meio da visão artificial é que se obtêm a imagem, objeto este, que é a matéria prima do trabalho desenvolvido. Por conter uma grande quantidade de informações que não são perceptíveis aos olhos humanos, a imagem tornou-se fonte de dados para as pesquisas nas áreas que envolvem a Visão Computacional (CARVALHO, 2003). Há alguns anos atrás, era grande a dificuldade em processar dados de imagens, mas com os avanços da computação, hoje a Visão Computacional está presente nos mais diversos campos de atuação, manipulando dados simples ou complexos (BOGGIONE, 2004).

Em pouco tempo, a visão computacional alcançou um rápido desenvolvimento nas áreas de detecção e reconhecimento. Detectar e classificar objetos e/ou grupos de objetos em imagens constituem atualmente um dos mais interessantes, úteis, e difíceis desafios para a visão de máquinas. Muito progresso têm sido alcançado durante a última década: na formulação de modelos que capturam a imagem e características geométricas de objetos naturais, na criação de algoritmos que rapidamente correlacionam esses modelos às imagens, e no desenvolvimento de técnicas de aprendizado que podem estimar esses modelos a partir de um treinamento com imagens e supervisão limitada. O sistema de visão artificial se comparado ao humano consegue operar em praticamente todo o espectro de radiações eletromagnéticas e com altíssima velocidade de processamento, mas não possui capacidade de trabalhar sob condições variadas nem de reconhecimento de padrões simultâneos diversos numa mesma imagem. Contudo, os melhores algoritmos estão longe de alcançar as habilidades humanas, pois, como (GRILL-SPECTOR K.; KANWISHER, 2005) afirmaram em sua pesquisa: *“para humanos classificar algo é tão rápido quanto detectar a presença do objeto - logo que você sabe que está lá, você já sabe o que é”*. Os sistemas de visão

computacional diferem em diversos aspectos do sistema biológico humano, tais como: número de categorias a serem aprendidas e reconhecidas, as taxas de erro de classificação, a velocidade, e a facilidade com que se aprende.

A partir do reconhecimento de padrões, a visão computacional encontrou várias formas de aplicações, tanto na indústria, que vão desde a inspeção de peças até a montagem robotizada quanto na medicina ou no entretenimento. Mas, para que se possa utilizar todas as informações úteis contidas nas imagens, às vezes é necessário passar por um processo de melhoria e seleção de dados (BITTENCOURT J R; OSORIO, 2002).

O Processamento de Imagens Digitais, ou PDI, é um conjunto de técnicas bastante comum em diversas áreas da Computação, é um processo pelo qual as imagens passam para a obter algum tipo de melhoria. É realizada através da utilização de funções matemáticas que transformam a imagem original em uma imagem tratada (BITTENCOURT J R; OSORIO, 2002).

Segundo (GONZALEZ RAFAEL C.; WOODS, 2002) é um processo composto basicamente de 6 etapas, conforme a Figura 1.1, e que não implica a passagem por todas as etapas.

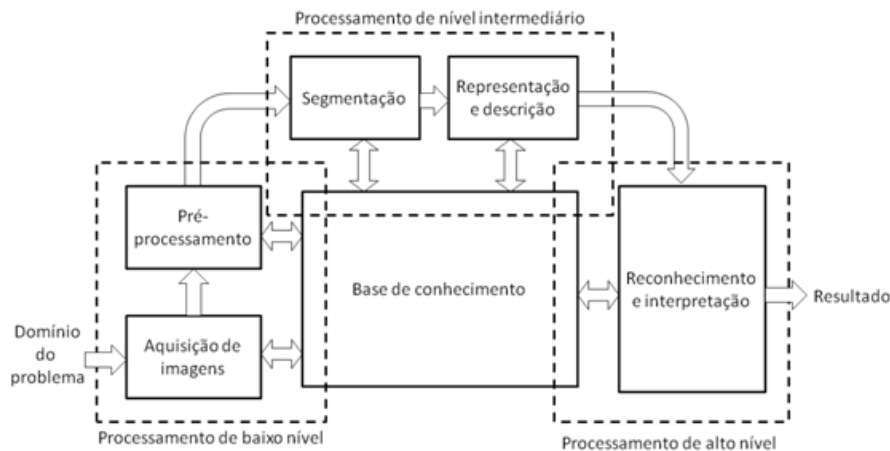


Figura 1.1: Etapas básicas de um Processamento de Imagens. FONTE: (GONZALEZ RAFAEL C.; WOODS, 2002)

Basicamente, a primeira etapa é a aquisição de imagens, que como o próprio nome diz, é a etapa onde a imagem é adquirida. A segunda etapa é o pré-processamento, que é responsável por aplicar técnicas de transformações lineares e não lineares às imagens com o objetivo de reduzir problemas e melhorar características. Posteriormente, na etapa de segmentação, a imagem é particionada em regiões disjuntas desde que possuam alguma característica importante para a aplicação. A representação consiste nas diversas formas de armazenar as regiões obtidas após a segmentação. Esta nova representação possui informações sobre a forma e topologia dos objetos. Para complementar a representação, a descrição serve para extrair características estruturais. Em seguida, no reconhecimento,

um rótulo é associado a cada objeto segmentado, enquanto a interpretação associa um significado a cada conjunto de objetos. Pode-se recorrer à base de conhecimento quando se dispõe de conhecimento prévio do resultado esperado. A base de conhecimento, além de controlar a interação do processo, é reponsável por guiar a operação de cada etapa no processamento (GONZALEZ RAFAEL C.; WOODS, 2002).

O processamento de imagens é constantemente utilizado por diversas áreas em inúmeras tarefas, das quais podemos citar: a detecção de doenças na medicina; na geografia, em geoprocessamento e análises de vegetação, clima, entre outros; na computação e robótica, no reconhecimento de padrões e objetos, aquisição e transmissão de imagem digital (TV Digital) (BITTENCOURT J R; OSORIO, 2002).

Para que um computador possa entender uma imagem, é necessário transformá-la em uma matriz de números (BRITO S. F.; CARVALHO, 1998). Dessa forma, o processamento oferece bastante flexibilidade na manipulação dos dados. Entretanto, entender e analisar tal matriz é uma atividade complexa e demanda um custo computacional alto devido ao grande volume de operações matemáticas (CARVALHO, 2003).

Atualmente há uma grande quantidade de pesquisas que utilizam imagens processadas para obtenção de resultados mais satisfatórios dentro de algum processo. Comumente associada ao processamento de imagens, a Rede Neural Artificial (RNA) é uma técnica constantemente utilizada no Reconhecimento de Padrões e Objetos.

As RNAs, são técnicas computacionais que apresentam um modelo inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento a partir de experiência prévia (HAYKIN, 1998). A premissa básica das Redes Neurais Artificiais é imitar o funcionamento do cérebro humano e desenvolver sistemas computacionais capazes de aprender, generalizar e descobrir (NEVES, 2006). Compostas por sistemas paralelos distribuídos que possuem unidades de processamento simples, comumente chamados de neurônios, que computam determinadas funções matemáticas. Tais unidades são dispostas em uma ou mais camadas, e interligadas por um grande número de conexões. Essas ligações estão associadas a pesos, que armazenam o conhecimento representado no modelo e serve para ponderar a entrada recebida por cada neurônio (BILOBROVEC M; MARCAL, 2004).

A principal característica das redes neurais é o paralelismo, que cria a possibilidade de um desempenho superior se comparado a métodos convencionais (HAYKIN, 1998). Para a resolução de problemas com redes neurais, o procedimento normal passa por uma fase de aprendizagem, onde um conjunto de exemplos é apresentado à rede, que extrai automaticamente as características necessárias para representar a informação recebida. Essas características são utilizadas posteriormente para gerar respostas para o problema (CHAGAS C. S.; VIEIRA, 2009). As redes neurais possuem essa capacidade de aprender a partir de

exemplos e de generalizar a informação aprendida (NYGREN, 2004). A generalização está associada a capacidade da rede em aprender através de um conjunto reduzido de exemplos, e posteriormente, dar respostas coerentes a dados não apresentados à rede. (HAYKIN, 1998)

Os modelos de RNAs têm sido constantemente explorados em processamento de imagens e reconhecimento de padrões, pois, uma vez treinada, a ativação de uma rede neural é extremamente rápida, o que a torna atraente para problemas que requerem processamento em tempo real (MORAES, 2010).

A natureza se manifesta de diversas maneiras, tais como sons, formas, imagens, cheiros e sabores, que são facilmente percebidos e reconhecidos por pessoas e animais. Na computação, o reconhecimento de padrões é a área do processamento em que se utilizam técnicas computacionais para aproximar a performance das máquinas à do ser humano de modo a reconhecer padrões (NOGUEIRA A.; AZEVEDO, 2006). Existem dois grandes motivos para os estudos nesta área: (1) a necessidade de comunicação entre máquinas e humanos através de linguagens naturais; (2) e na construção de robôs autônomos. Sendo uma ciência não exata, o padrão de natureza não estruturado torna o problema de reconhecimento mais difícil de ser tratado por métodos tradicionais. Desta forma, o uso de redes neurais artificiais surgiu como modo alternativo de solução, pois, ao invés de criar procedimentos lógicos, a construção destas redes envolve o entendimento informal do comportamento desejado para atender o problema (CASTRO, 2009).

1.1 Definição do problema

O problema clássico da visão computacional e do processamento de imagens é determinar se uma imagem contém ou não um dado objeto, característica ou atividade. É uma tarefa facilmente resolvida pelos humanos, mas que ainda não foi satisfatoriamente resolvida para equipamentos autônomos, onde objetos, situações, iluminação e pose são arbitrárias. O principal problema do processo computacional está relacionado a quantificação das informações visuais presentes nas imagens, ou seja, para um reconhecimento de um dado objeto é necessário encontrar de alguma maneira características na imagem que o distingam dos outros dentro do seu universo de trabalho (MACHADO, 2008).

O problema concentra-se no desenvolvimento de um modelo de Redes Neurais para reconhecimento de objetos e classificação dele em grupos de objetos. Tal modelo necessita extrair características relevantes do objeto em questão, para que possam ser utilizadas no reconhecimento. A proposta do problema pode ser exemplificada com a seguinte situação: Uma empresa hipotética fabrica parafusos para venda, que são utilizados em diversas situações, mas cada tipo de parafuso possui uma utilização específica. Tendo

em vista o crescimento das vendas, a empresa precisa agilizar a fabricação dos materiais mantendo a qualidade do produto. Pensando nisso, ela resolveu modernizar os processos, e para que a qualidade não diminua, foi idealizado o desenvolvimento de um equipamento robótico que possui um sistema de visão computacional acoplado e que avalia peça por peça separando-as conforme a necessidade, no intuito de agilizar a fabricação e entrega do produto final sem perder a qualidade.

1.2 Objetivo

A partir do entendimento dos princípios e conceitos que fundamentam os assuntos apresentados, o presente trabalho concentra-se particularmente no sistema de visão artificial. Tem como objetivo principal a modelagem e implementação de um sistema de visão robótica em C++ para reconhecimento e classificação de objetos em imagens baseado em Redes Neurais e Geometria Fractal.

1.3 Importância e Motivação da Pesquisa

Muitas pesquisas são realizadas no âmbito do reconhecimento de padrões, conseqüentemente, há diversas técnicas para o problema proposto. Na busca por uma melhor solução, as chances de encontrar vantagens específicas em cada um dos métodos existentes são grandes, e uma simples união dessas vantagens poderia ser de grande interesse, porém, acarretando também o aumento da dimensionalidade dos dados. Essas dificuldades reforçam a necessidade de maior investigação e busca de soluções. Por se tratar da união de grandes áreas de pesquisa, nota-se de fato, que é um campo fértil e que o trabalho será de utilidade para o laboratório no qual foi desenvolvido.

1.4 Organização da Dissertação de Mestrado

O presente documento apresenta seis capítulos e está estruturado da seguinte forma:

- **Capítulo 1 - Introdução:** Contextualiza o âmbito, no qual a pesquisa proposta está inserida. Apresenta a definição do problema, objetivos e justificativas da pesquisa e como esta dissertação de mestrado está estruturada;
- **Capítulo 2 - Fundamentação Teórica e Estado da Arte no uso de Reconhecimento de Padrões e Objetos, Redes Neurais e Geometria Fractal:** é

discutido o Estado da Arte no que tange o Reconhecimento de Padrões e Objetos utilizando Redes Neurais para a classificação dos dados;

- **Capítulo 3 - Modelo Computacional Proposto:** apresenta as estratégias para o reconhecimento de objetos. Nele é descrito o modelo proposto, as etapas necessárias e a metodologia empregada;
- **Capítulo 4 - Trabalho Experimental:** descreve o desenvolvimento do modelo, os experimentos realizados, bem como suas funcionalidades e algoritmos desenvolvidos;
- **Capítulo 5 - Resultados Obtidos:** são apresentados os resultados obtidos, considerações sobre os experimentos realizados e uma análise do desempenho das abordagens propostas;
- **Capítulo 6 - Considerações Finais:** Apresenta as principais conclusões, contribuições e algumas sugestões de atividades de pesquisa a serem desenvolvidas no futuro.

Fundamentação Teórica e Estado da Arte no uso de Reconhecimento de Padrões e Objetos, Redes Neurais e Geometria Fractal

Neste capítulo serão mostrados os avanços dos trabalhos que utilizam Redes Neurais, Processamento de Imagens e Reconhecimento de Padrões, e Geometria Fractal como base para as pesquisas. Poder-se-á verificar que as diversidades de trabalhos desenvolvidos nos últimos anos em que esses temas atuam só tendem a crescer e se espalhar por outras grandes áreas de pesquisa.

2.1 As Redes Neurais Artificiais

Os estudos envolvendo o cérebro são datados de muitos anos atrás. Porém, por meio da criação da eletrônica, foi que os homens começaram a tentar simular o cérebro e seus processos (HAYKIN, 1998). Em 1943, McCulloch & Pitts publicaram o primeiro modelo de neurônio artificial, Figura 2.1, que interpretava o funcionamento como sendo um circuito binário simples que combina várias entradas e gera uma saída (NEVES, 2006).




Figura 2.1: Modelo de Neurônio Simples. FONTE: (HAYKIN, 1998)

Em termos matemáticos, um neurônio pode ser descrito através das equações 2.1 e 2.2 (HAYKIN, 1998):

$$u_k = \sum_{j=1}^m w_{kj} * x_j \quad (2.1)$$

$$y_k = \varphi(u_k + b_k) \quad (2.2)$$

Desta forma os autores mostraram que era possível criar uma rede neural utilizando somente a matemática e algoritmos. O neurônio é composto basicamente de três elementos básicos (HAYKIN, 1998):

1. Um conjunto de Pesos: especificamente, um sinal x_j na entrada, conectada ao neurônio k é multiplicado pelo peso w_{kj} ;
2. Um somador: que faz a soma dos sinais de entrada já ponderados;
3. Uma função de ativação: que restringe a amplitude da saída de um neurônio. A depender do problema, pode-se escolher diferentes tipos de funções, a figura 2.2, mostra três diferentes tipos de função:




Figura 2.2: Tipos de função ativação. FONTE: (RAUBER, 1997)

Posteriormente, as pesquisas tiveram altos e baixos, mas em 1958, Frank Rosenblatt criou o perceptron, a unidade funcional das redes, o que alimentou os ânimos, e desde então, as pesquisas envolvendo este tema cresceram bastante (MASSON, 1990). Atualmente as aplicações envolvendo Redes Neurais em seu desenvolvimento abrangem uma diversidade de áreas, indo de pesquisas educacionais/científicas à aplicações comerciais e industriais (BILOBROVEC M; MARCAL, 2004).

2.1.1 Topologias de Redes

A eficiência das Redes Neurais se dá pela utilização de conjuntos de neurônios interligados entre si formando uma complexa estrutura de rede (CERA, 2005), onde os sinais de

entrada recebidos pelos neurônios são transformados e repassados adiante, até chegarem a saída, onde obtêm-se a resposta desejada (MEDEIROS, 2003), é neste processo onde a “inteligência” é formada. A topologia de uma rede é a forma pela qual ela se apresenta fisicamente, ou seja, como ela está organizada. A escolha de uma topologia implica diretamente no resultado da Rede, isto porque a organização dos neurônios numa RNA está diretamente relacionado ao tipo de problema a ser resolvido e é um fator decisivo na escolha do algoritmo de aprendizado (NEVES, 2006). As principais topologias de rede são (HAYKIN, 1998):

- Propagação para frente (*Feedforward*): As redes *feedforward*, figura 2.3, são unidirecionais, agrupadas em camadas, podendo haver camadas ocultas, ou seja, não estão conectadas nem com as entradas nem com as saídas. São mais populares por possuírem métodos de aprendizagem mais difundidos e fáceis de utilizar.




Figura 2.3: Topologias de Redes de Propagação para Frente: (1) camada única, (2) com camada oculta. FONTE: (HAYKIN, 1998)

- Recorrentes (*Recurrent*): Distingue-se de uma rede de propagação para frente por ter pelo menos um laço de realimentação e o uso de mais um elemento na rede, figura 2.4, o que implica em um impacto na capacidade de aprendizagem e desempenho da rede.

Para o desenvolvimento da pesquisa, foi escolhido a topologia de Propagação para Frente, por apresentar melhores resultados quando utilizados no reconhecimento de objetos.

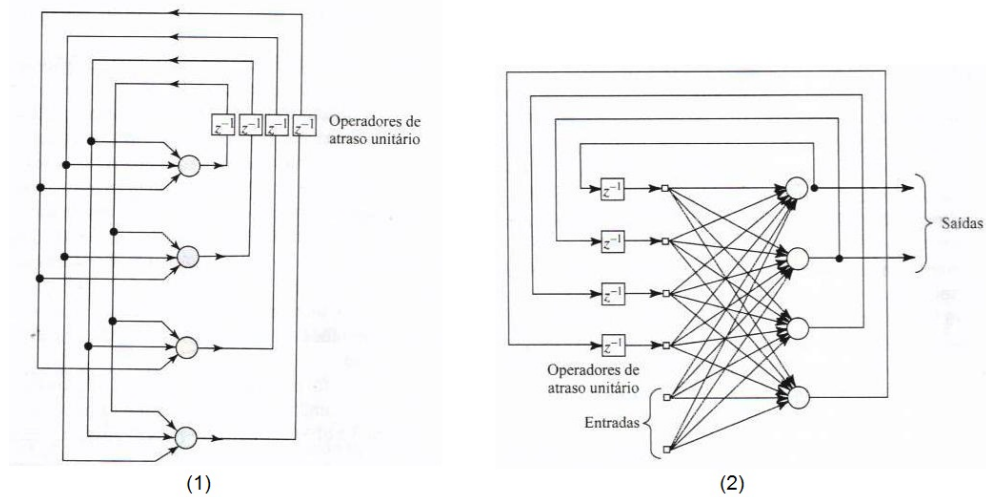


Figura 2.4: Topologias de Redes Recorrentes: (1) camada única, (2) com camada oculta. FONTE: (HAYKIN, 1998)

2.1.2 Paradigmas de Aprendizagem

O principal processo de uma rede neural é a aprendizagem. É o ato de produzir um comportamento diferente por um estímulo recebido, isto ocorre devido às reações obtidas anteriormente. As redes neurais possuem a capacidade de aprender por exemplos. O aprendizado pode ser classificado em (NEVES, 2006):

- **Supervisionado:** Neste caso, a rede é treinada pela presença de dados de entrada e saída desejada, e a cada iteração do treinamento da rede, a entrada produz uma saída que ao ser comparada com a saída desejada, gera uma diferença e faz com que a rede se reajuste (adaptando os pesos) até que essa diferença seja mínima ou nula.
- **Não-Supervisionado:** Ao contrário do supervisionado, este tipo de treinamento não possui um dado de saída desejada para guiar o treinamento. Neste tipo, a aprendizagem é realizada pelas descobertas de semelhanças nos dados de entrada, procurando agrupamentos dos exemplos de treinos. Basicamente, usa a seguinte idéia, para exemplos de coisas semelhantes, a rede responde de forma semelhante.

O foco deste trabalho é na rede de aprendizado supervisionado. Para que ocorra o aprendizado é necessária a utilização de regras matemáticas, chamadas de regras de aprendizado. Existem diversas regras para o aprendizado neste tipo de rede. Pode-se citar a Lei de Hebb, representada na equação 2.3 (HEBB, 1949).

$$\Delta_H w_{ij} = \eta * Y_i * y_j \quad (2.3)$$

Onde η é a taxa de aprendizado, que é um valor de escala positiva que determina a velocidade da aprendizagem. Y_i é a saída calculada e y_j a saída desejada. Esse modelo foi adaptado por Widrow-Hoff (WIDROW B.; HOFF, 1960), e passou a ser chamada de Regra Delta. Esta regra tem como objetivo minimizar o erro entre os valores de saída calculados pela rede e os desejados pelos exemplos fornecidos, e está representada na equação 2.4:

$$\Delta_D w_{ij} = \eta * (Y_i - y_i) * y_j \quad (2.4)$$

Onde $Y_i - y_i$, é a diferença entre o valor da saída calculada e da desejada. Porém, o bom funcionamento dessas regras é exclusivo das redes com duas camadas, entrada e saída. Em 1986, Rumelhart, Hinton e Williams desenvolveram o algoritmo de retropropagação de erro, ou *Backpropagation*, que é uma generalização da Regra Delta, podendo ser utilizado com eficiência em redes com três ou mais camadas (RUMELHART D. E.; HINTON, 1986). Esta é uma das regras mais utilizadas em pesquisas, e não se limita a resolver problemas linearmente separáveis.

2.1.3 Avanços na utilização das Redes Neurais

Toda essa evolução das redes neurais até os dias atuais somado a era da tecnologia permitiu aos pesquisadores avanços ainda mais significativos no desenvolvimento de uma rede neural artificial. Por terem sido criadas com base na rede neural biológica, as RNA possuem algumas de suas características mais importantes, como o aprendizado pela experiência, a generalização e abstração de características. Atributos esses que geram grande interesse para as pesquisas atuais. (WASSERMAN, 1989)

Atualmente as Redes Neurais estão sendo utilizadas em pesquisas nas mais diversas áreas, por meio de sua utilização é possível reconhecer objetos, classificar objetos em grupos, reconhecer e associar padrões, além de “predizer o futuro”. A grande maioria das pesquisas foca na classificação de objetos e padrões (NYGREN, 2004). Em 2000, (ZHANG, 2000) afirma em seu trabalho que as Redes Neurais surgiram como uma importante ferramenta para classificação, e que as pesquisas mostraram ser uma promissora alternativa aos métodos de classificação existentes. Hoje, percebe-se a extensão da sua utilização, da economia à medicina.

Em seu artigo, (LIMA FABIANO G; PERERA, 2009) mostrou a aplicação das redes neurais na análise e concessão de crédito ao consumidor, apresentando resultados positivos na classificação, em torno de 75% de acertos, ou nas previsões de séries financeiras (MACIEL L S.; BALLINI, 2008)(ABELEM, 1994), que são particularmente ruidosas e sem periodi-

cidade aparente, mostrando que o método das Redes Neurais Artificiais é superior aos outros testados, pelos autores, dentro do âmbito da economia. Já em (TORRES RUBIAO G.; MACHADO, 2005), é apresentada a utilização no ambiente industrial, na previsão de falhas de equipamentos do sistema industrial antes da manutenção programada. Esses modelos foram desenvolvidos para que possam ser previstas futuras falhas de determinadas peças do maquinário para que se possa fazer a manutenção prévia, no intuito de terem as máquinas funcionando de forma prolongada e eficiente, sem serem pegos de surpresa. Em outra situação, utilizada em atividades da agropecuária, as Redes Neurais continuam afirmando a sua eficácia nas atividades propostas. Em (BITTENCOURT, 2009), foi proposto um método para classificação automática do acabamento de gorduras em carcaças bovinas utilizando redes neurais, a mesma alcançou uma taxa de acerto em torno de 86% na classificação.

Nos últimos tempos, está sendo constantemente utilizada no Geoprocessamento e Sensoriamento Remoto, ambos ligados a Geografia. Em sua tese (GALO, 2000), a autora realizou um estudo comparativo da caracterização ambiental de uma localidade utilizando Redes Neurais e Sensoriamento Remoto, somente utilizando as características espaciais, espectrais, radiométricas e temporais das imagens obtidas por meio de satélites e os dados reais obtidos pelo órgão responsável. Os resultados mostraram que a classificação das Redes Neurais obtiveram valores próximos aos reais, o que comprova mais uma vez a eficiência das RNA e que é totalmente viável sua utilização neste tipo de pesquisa. Em (CHAGAS C. S.; VIEIRA, 2009), as Redes Neurais são utilizadas como um método alternativo para a classificação dos níveis de degradação de pastagens, obtendo excelentes resultados nas comparações com a realidade.

Na medicina, as Redes Neurais Artificiais são utilizadas em diversas aplicações, como nas decisões médicas (diagnóstico, prognóstico e terapia), no reconhecimento de sinais biológicos (ECG, EEG, etc) e em imagens médicas (raio-x, cintilografia, ressonâncias, tomografias, etc). Uma pesquisa realizada no Colorado desenvolveu um sistema para diagnosticar o câncer de próstata bem como prever a possível recorrência do mesmo depois do tratamento. No trabalho de (ROCHA EDROALDO L. DA; NICOLEIT, 2007), é apresentado um sistema com Redes Neurais e Processamento de Imagens para o diagnóstico automatizado de doenças do cólon do útero, que segundo o INCA, é o terceiro tipo de doença mais comum entre mulheres no Brasil.

2.2 *Processamento Digital de Imagens para o Reconhecimento de Padrões*

O Processamento Digital de Imagens, ou PDI, teve um notável crescimento nas últimas décadas, graças ao desenvolvimento tecnológico e computacional, tornando-se um grande e atual tema de pesquisa (CASTRO, 2009) (HAYKIN, 1998). Trata-se da representação e análise de dados em forma visual, i.e., o PDI é um processo de manipulação de dados numéricos contidos em uma imagem digital que utiliza funções matemáticas para efetuar mudanças com a proposta de melhorar sua aparência visual (HOGENDOORN, 2006). A partir deste processo, é possível melhorar imagens antigas, clarear imagens médicas, entre outros, além de possuir a habilidade de extrair informações imperceptíveis aos olhos humanos.

Atualmente o PDI está sendo utilizado em aplicações de diversos seguimentos, como a indústria, medicina, robótica, exploração espacial, marítima e terrestre, pesquisas educacionais, entre outras. Na medicina, é comumente utilizado na análise morfológica dos cortes em tecidos (pele, músculos, etc), no clareamento de imagens para diagnóstico, comparação de DNA; na biotecnologia faz parte do sequenciamento automático de DNA, entre outros (PEREIRA RAFAEL M.; WU, 2004). Um bom exemplo da importância do uso do PDI se dá na meteorologia, que utilizando uma sequência de imagens de satélite da formação de um furacão, e combinando esses dados a outros dados meteorológicos armazenados, na análise das imagens processadas obtidas é possível traçar rotas, prever a força, o tempo e a localização por onde irá passar, podendo ajudar em um possível sinal de alerta. O PDI também é utilizado na descoberta de focos de queimadas, detecção de doenças nos olhos, na restauração e conservação de obras de arte, etc (BOGGIONE, 2004).

A utilização do PDI se mostra presente principalmente nas aplicações que necessitam de compressão e/ou análise em grandes volumes de dados, na velocidade de manipulação e demanda de informação atualizada. O processamento digital de imagens é um processo totalmente matemático. Uma imagem digital é uma matriz de medidas, que pode conter dados de iluminação, temperatura, altitude, etc, transformadas em intervalos regulares e mostradas em forma de pixels (GONZALEZ RAFAEL C.; WOODS, 2002).

2.2.1 *Imagem Digital e o Pixel*

Para que uma imagem possa ser processada computacionalmente é necessário que a mesma seja adquirida digitalmente (BRITO S. F.; CARVALHO, 1998). Sendo ela o objeto principal do modelo, uma imagem digital, nada mais é que uma matriz $M \times N$ de níveis de cinza, no caso de uma imagem digital monocromática. Segundo (BANON, 2000), uma imagem

em escala de cinzas é composta por dois conjuntos: (1) Conjunto X, composto por um quadrado dispostos em linhas e colunas e, (2) um conjunto Y, contendo níveis de cinza, variando de 0 a 255. Para ele, um pixel é um elemento do produto cartesiano de uma posição do conjunto X e um elemento do conjunto Y.

Uma imagem digital monocromática segundo (MASCARENHAS N. A.; VELASCO, 1989) é uma função de intensidade de luz bidimensional $f(x,y)$, chamada de pixel, onde x e y são coordenadas espaciais. Cada pixel possui propriedades associadas a ele, valores estes representados por níveis de cinza, cor, textura, etc. Em uma imagem monocromática, o valor de f no ponto (x,y) é proporcional ao brilho da imagem neste ponto. Caso a imagem seja colorida, a cor ou o valor de f passa a ser definida por três grandezas: (1) muminância, associada ao brilho da luz, (2) matiz, associada com o comprimento de onda dominante, e (3) saturação, que está associada com o grau de pureza da matiz. Independente de ser vista como uma matriz, a leitura matemática de uma imagem digital é diferente e se dá conforme a Figura 2.5, nela as coordenadas x e y se invertem, e x é lida de cima para baixo. Para este trabalho, utilizou-se a imagem em escala de cinzas como base.




Figura 2.5: Forma de leitura e representação de uma imagem digital em aspecto matemático. FONTE: Adaptado de (CARVALHO, 2003) e (GONZALEZ RAFAEL C.; WOODS, 2002)

2.2.1.1 Propriedade dos Pixels

Uma das propriedades importantes dos pixels é a conectividade. Vizinhança, ou conectividade, pode ser classificada em dois tipos (Figura 2.6) (CARVALHO, 2003):

- Conectividade $D4_n$, na qual se têm por base os pixels adjacentes a borda, desconsiderando os vizinhos na diagonal;
- Conectividade $D4_d$, utiliza os pixels da diagonal;
- Conectividade $D8$, onde se utilizam todas as oito direções.




Figura 2.6: Propriedade de Vizinhança. (a) D4n, pixels conectados pela borda, (b) D4d, pixels conectados pela diagonal, e (c) D8, pixels conectados pelas bordas e pela diagonal. FONTE: Adaptado de (PAVIM X A.; ROLOFF, 2005)

O pixel é um elemento anisotrópico em relação a distância, i.e., o valor da distância terá diferentes resultados que irão depender da direção considerada, que no caso é o tipo de conectividade. A escolha de um deles afeta diretamente na propriedade da distância dos pixels, Figura 2.7, que é utilizada constantemente em métodos de processamento digital como as operações morfológicas (PAVIM X A.; ROLOFF, 2005).




Figura 2.7: Diferença da distância segundo as três abordagens de conectividade, para efeitos de exemplo utilizou-se a contagem de pixels como medida de distância. (a) utilizando D4n, a distância seria igual a 8px, (b) D4d e (c) D8, a distância para ambos seria de 4px. FONTE: Adaptado de (PAVIM X A.; ROLOFF, 2005).

2.2.2 Etapas do Processo

Adaptando o modelo de (GONZALEZ RAFAEL C.; WOODS, 2002), as etapas do processamento digital de imagens do trabalho é composto por quatro etapas básicas: (1) Aquisição da Imagem, (2) Pré-Processamento da Imagem e Segmentação, (3) Representação e Descrição, e (4) Reconhecimento e Interpretação, conforme Figura 2.8.



Figura 2.8: Etapas do Processamento Digital de Imagens. FONTE: Adaptado de (GONZALEZ RAFAEL C.; WOODS, 2002)

2.2.2.1 Aquisição da Imagem

Para o processo de formação da imagem e sua possível aquisição em uma imagem digital, Figura 2.9, são necessários três elementos: (1) luz natural ou artificial, (2) dispositivo físico sensível a luz, que seja capaz de captar os espectros de energia eletromagnética refletidos pela imagem/dado original e, (3) um digitalizador, que converte o sinal analógico/elétrico em formato digital. Sistemas de imageamento, como também são chamados o conjunto de elementos, são facilmente encontrados atualmente, por exemplo, as câmeras fotográficas digitais (CARVALHO, 2003).

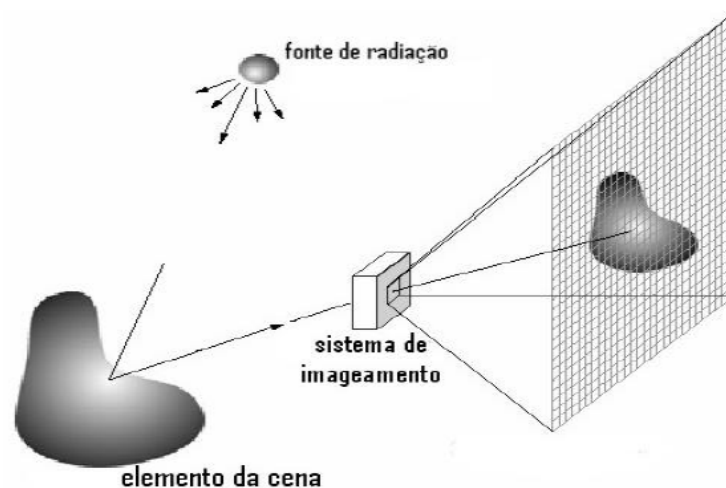


Figura 2.9: Esquema do processo de formação da imagem. FONTE: (GONZALEZ RAFAEL C.; WOODS, 2002)

Segundo Kulkarni, no momento da aquisição existe a possibilidade da imagem vir com algum tipo de degradação, seja pelo ambiente ou pelo equipamento utilizado (CASTRO, 2009). Quando se trata de uma pesquisa científica, existem bancos de dados de imagens na internet, i.e., pacotes de imagens de um mesmo objeto, geralmente fornecidas por instituições de ensino e/ou pesquisa. Esta é uma etapa fundamental do processo, pois além de ser o momento da aquisição, é nela onde serão discutidos aspectos externos ao processo, como ambiente, iluminação, resolução, entre outros (FIGUEREDO, 2007).

2.2.2.2 *Pré-Processamento e Segmentação*

O pré-processamento consiste na maior parte de transformações lineares e não lineares aplicadas à imagem visando o aprimoramento da mesma, através de remoção de ruídos, mudança de contraste, iluminação, distorções, nitidez, dentre outros. A segmentação é a extração ou identificação de regiões contidas na imagem, onde a região é toda a característica com conteúdo relevante para a aplicação (MASCARENHAS N. A.; VELASCO, 1989). Geralmente particiona a imagem em duas regiões, uma representa o fundo da imagem, constituída de dados “desnecessários” à aplicação, e a outra, denominada de região de interesse, que contém os dados necessários para as próximas etapas. É uma fase em que o processo autônomo torna-se difícil pois necessita de informações específicas, e que são melhores fornecidos por um observador humano a um observador mecânico. Entretanto, muitos algoritmos computacionais são utilizados e seus resultados são bastante satisfatórios. Constantemente utilizado nesta etapa, o histograma é um dos métodos de segmentação que é eficaz e simples de ser implementado. Pode ser criado por diferentes formas, mas, sua idéia principal é quantizar a frequência da ocorrência de pixels dentro de um mesmo espaço.

2.2.2.3 *Representação e Descrição*

Esta etapa serve para extrair dados numéricos da região de interesse obtida na segmentação, armazenando essas informações num vetor de características. A representação consiste das várias formas de armazenar a fronteira e o interior de objetos segmentados, contendo informações sobre a forma e a topologia dos objetos. (GONZALEZ RAFAEL C.; WOODS, 2002) define esta etapa como:

Geralmente, uma representação externa é escolhida quando a atenção primária estiver voltada para características de forma. Por outro lado, uma representação interna é selecionada quando a atenção estiver voltada para propriedades como cor ou textura. (GONZALEZ RAFAEL C.; WOODS, 2002)

A descrição, ou escolha de características, é a extração de atributos que resultam em uma relação quantitativa da representação.

2.2.2.4 *Interpretação e Reconhecimento*

Com base na descrição, o reconhecimento associa um rótulo a cada objeto segmentado, e a interpretação associa um significado ao conjunto de objetos segmentados.

2.2.3 *A necessidade do Reconhecimento de Padrões*

Está intrínseca à natureza dos seres humanos, a habilidade de reconhecer padrões, ou seja, no momento em que observa um dado objeto/sensação, são coletadas informações e comparadas com as informações de propriedades e comportamentos que possuímos armazenadas na mente (CERA, 2005) (NOGUEIRA A.; AZEVEDO, 2006).

O termo “reconhecimento de padrões” foi primeiramente introduzido na década de 60 e significava detecção de formas simples, hoje, sabe-se que o termo vai muito além do que só reconhecer formas simples (REIS CAIMI F; ALBUQUERQUE, 2001). Existem muitas definições sobre reconhecimento de padrões, segundo Pao(1989), todas as coisas que acontecem na vida humana tomam forma de padrões, daí a importância nos estudos do reconhecimento de padrões. Já Bezdek e Pal (1992) dizem que é a busca por estruturas em dados. Duda, Hart e Stork (2000) definem como sendo: “um campo que consiste no reconhecimento de regularidades significativas em meios ruidosos e complexos” (MORAES, 2010).

Nos seres humanos a habilidade de reconhecer padrões é bastante rápida e trivial, porém, para a computação, não existe hardware nem software capaz de se igualar a capacidade humana. Para a computação, o reconhecimento de padrões é uma ciência inexata, por isso admite diversas abordagens para solucionar um determinado problema, como redes neurais, redes neuro-*fuzzy*, *k*-means, rede Bayes com algoritmos genéticos, dentre outros (SOUZA, 1999). Um grande desafio dessa área é o reconhecimento de objetos/padrões em imagens. Reconhecer um objeto é um processo de tomada de decisão objetivando classificá-los em números de categorias ou classes (MACHADO, 2008). A maioria das aplicações que utiliza o reconhecimento de padrões, utilizam o processamento digital de imagens como primeiro passo.

Por serem padrões complexos, as imagens possuem uma alta dimensão de características e por natureza são difíceis de processar (SOUZA, 1999). Segundo (JAIN A. K.; DUIN, 2000), nos últimos anos, avanços significativos foram alcançados por meio das pesquisas. Atualmente, a quantidade de aplicações que requerem técnicas de reconhecimento de padrões mais eficientes aumentou, pode-se citar como exemplo a Bioinformática, diagnósticos médicos, mineração de dados, automação industrial, dentre outros.

2.3 O uso da Dimensão Fractal em Pesquisas

A geometria fractal é o ramo da matemática que estuda as propriedades e comportamentos dos fractais. Descreve situações que não podem ser explicadas pela geometria clássica. O termo fractal foi criado pelo matemático Benoît Mandelbrot em 1975, que estudava os problemas da geometria clássica. Um fractal é um dado objeto geométrico que pode ser dividido em partes, cada uma delas semelhante ao objeto original, são auto-similares e independem de escala, como mostra a Figura 2.10 (ASSIS, 2008).




Figura 2.10: Exemplo de fractal auto-similar e independente de escala. FONTE: (ASSIS, 2008)

Segundo (BACKES, 2006), por meio dos fractais, é possível calcular um número denominado de dimensão fractal, que para o processamento de imagens, atua como uma medida da complexidade da organização dos pixels que constituem a imagem, sendo que este nível de complexidade é diretamente relacionado ao seu aspecto visual.

2.3.1 Os Avanços

A Geometria Fractal tem sido constantemente utilizada em diversas áreas científicas. Na Geografia por exemplo, é constantemente utilizada nos estudos cartográficos, topográficos e ecológicos (AZEVEDO T. S.; MARQUES, 2004). Por meio das pesquisas, nota-se uma ampla utilização da dimensão fractal na Medicina. Ela é utilizada como método de diagnóstico quantitativo e objetivo de várias patologias. Um dos campos mais desenvolvidos é o diagnóstico de câncer (ASSIS, 2008). Os experimentos mostram que a rede capilar dos tumores cancerígenos possuem dimensão fractal maior que o dos tecidos normais. Partindo dessa informação, os pesquisadores continuaram as pesquisas, e conseguiram descrever o processo patológico da doença, sendo também utilizado como parâmetro relacionado ao grau de agressividade da doença (GUANDALINI, 2006). Segundo (DINIZ, 2006), é possível identificar alguns tipos de câncer na boca, e que pelo valor da dimensão, é possível afirmar em que grau de infiltração a doença está. Dessa forma, o estudo realizado, que pode ser considerado um prognóstico, ou seja, uma antecipação do desenvolvimento da doença, é de grande importância já que a partir da análise desses dados é possível iniciar um tratamento

e conseqüentemente aumentar consideravelmente as chances de recuperação do paciente. Em sua pesquisa, (OLIVEIRA, 2006) constatou que a dimensão fractal é um parâmetro que pode ser utilizado para diferenciar pessoas normais das que possuem problemas na retina dos olhos. Segundo o autor (BARRETO, 2001), outra área de utilização dos fractais é na biologia. Um estudo realizado pela Universidade Federal do Rio de Janeiro mostra que a irregularidade do habitat de algumas espécies influencia diretamente na escolha dos locais, por oferecer melhor abrigo e proteção contra predadores e variações climáticas.

Modelo Computacional

Este capítulo apresenta o modelo desenvolvido como solução para o problema proposto.

3.1 Apresentação do Modelo

Conforme visto anteriormente, o problema clássico da visão computacional e do processamento de imagens é determinar se em uma dada imagem há ou não um objeto específico, uma característica ou uma atividade. Ao contrário dos seres humanos, que realizam tais tarefas com tamanha facilidade, a computação ainda não consegue executá-las satisfatoriamente, onde objetos, situações, iluminação e pose são arbitrárias. Para um sistema computacional exercer essas atividades, é necessário que ele extraia características da imagem que distingam o dado objeto dos outros dentro do mesmo universo.

Sabe-se que a computação é uma ferramenta de apoio a qualquer área do conhecimento, e tendo em vista, a eterna melhoria na qualidade de serviços e equipamentos, a necessidade de ter um sistema confiável que execute as atividades desejadas com eficiência é deveras alta. Para isto, os esforços realizados na pesquisa e desenvolvimento desses sistemas crescem muito, não tendo em vista somente o âmbito científico, mas também no entretenimento e conforto pessoal.

3.1.1 Objeto de Pesquisa

Para a avaliação do sistema, foi escolhido o parafuso, como objeto de análise. Foi escolhido por ser um item que possui diversos tamanhos, formas, e é utilizado em larga escala por diversos seguimentos da indústria, a Figura 3.1 mostra as partes que compõem o parafuso.




Figura 3.1: Componentes do parafuso, (a) Cabeça, (b) Corpo, (c) Extremidade. FONTE: (DESTEC, 2011)

O parafuso serve para fixar um objeto a outro, e a depender dos materiais que serão acoplados, a forma do parafuso é determinante (SENAI, 2008). Os parafusos diferem tanto na cabeça quanto no corpo, a Figura 3.2 e a Figura 3.3 mostram algumas das diferenças entre eles.




Figura 3.2: Diferentes tipos de cabeça de parafuso. FONTE: (DESTEC, 2011)




Figura 3.3: Diferentes tipos de corpo de parafuso, (a) Ponta Agulha Rosqueado, (b) Ponta Broca Rosqueado, (c) Ponta Agulha Parcialmente Rosqueado e, (d) Ponta Broca Parcialmente Rosqueado. FONTE: (DESTEC, 2011)

Como exemplo da diferença na utilização do item, na Figura 3.2, tanto (a) quanto (b) servem para fixar perfis metálicos entre si, já o (c) serve para a fixação de chapas de gesso sobre perfis metálicos. Enquanto na Figura 3.3, os tipos (a) e (c) servem para perfurar chapas metálicas com espessura máxima de 0,7mm e a (b) e (d) para chapas de 0,7 a 2mm, isso sem levar em consideração o fato de estarem totalmente ou parcialmente rosqueados (DESTEC, 2011).

Mediante tais diferenças, e sabendo que qualquer defeito, o menor que fosse, pode prejudicar a sua utilização. Com isso, o modelo possui como idéia principal, o reconhecimento de quatro tipos distintos de parafusos conforme mostra a Figura 3.4.

Conforme visto na Figura 3.4, os tipos de objetos são chamados de: (a) Parafuso Ponta Broca, (b) Parafuso Cabeça Chata Rosca Total, (c) Parafuso Sextavado Rosca Parcial e, (d) Parafuso Cabeça Trombeta Ponta Agulha (DESTEC, 2011)(SENAI, 2008). Distinguem-se principalmente no formato da cabeça, somente o (c) que possui o corpo parcialmente rosqueado, (c) e (b) possuem semelhança no tipo de extremidade, diferentemente de (a)



Figura 3.4: Objetos de estudo.

e (d) que são bem distintas entre si.

Baseando-se nos dados apresentados, e sabendo da necessidade de agilidade na fabricação, bem como na estabilidade ou melhora da qualidade dos produtos, idealiza-se o desenvolvimento de um dispositivo robótico capaz de vistoriar as peças, separando as boas das defeituosas e/ou separá-las conforme sua especificação. Para isso, o sistema de visão precisa ser rápido e eficiente. Baseando-se nesta necessidade, e sabendo das vantagens que as redes neurais possuem, este modelo implementa um sistema de reconhecimento de objetos que utiliza como parâmetro a imagem de um dado objeto e a dimensão fractal do mesmo.

3.1.2 Diferencial da Pesquisa

O fator diferencial deste modelo está na utilização da geometria fractal como uma das características imposta a rede neural como parâmetro de aprendizado e classificação. A dimensão fractal atua como uma medida da complexidade da organização dos pixels que constituem a imagem, sendo esse nível de complexidade da imagem diretamente relacionado ao seu aspecto visual, tornando possível a sua comparação com outras imagens.

3.2 Composição do Modelo

Para o problema proposto, foi desenvolvido um modelo de reconhecimento de objetos através de Redes Neurais Artificiais e Geometria Fractal. O modelo é basicamente composto de três áreas do conhecimento: (1) Imagem e Processamento de Imagens, (2) Geometria Fractal, e (3) Redes Neurais Artificiais. O modelo desenvolvido é composto

resumidamente de 5 etapas, como mostra a Figura 3.5.

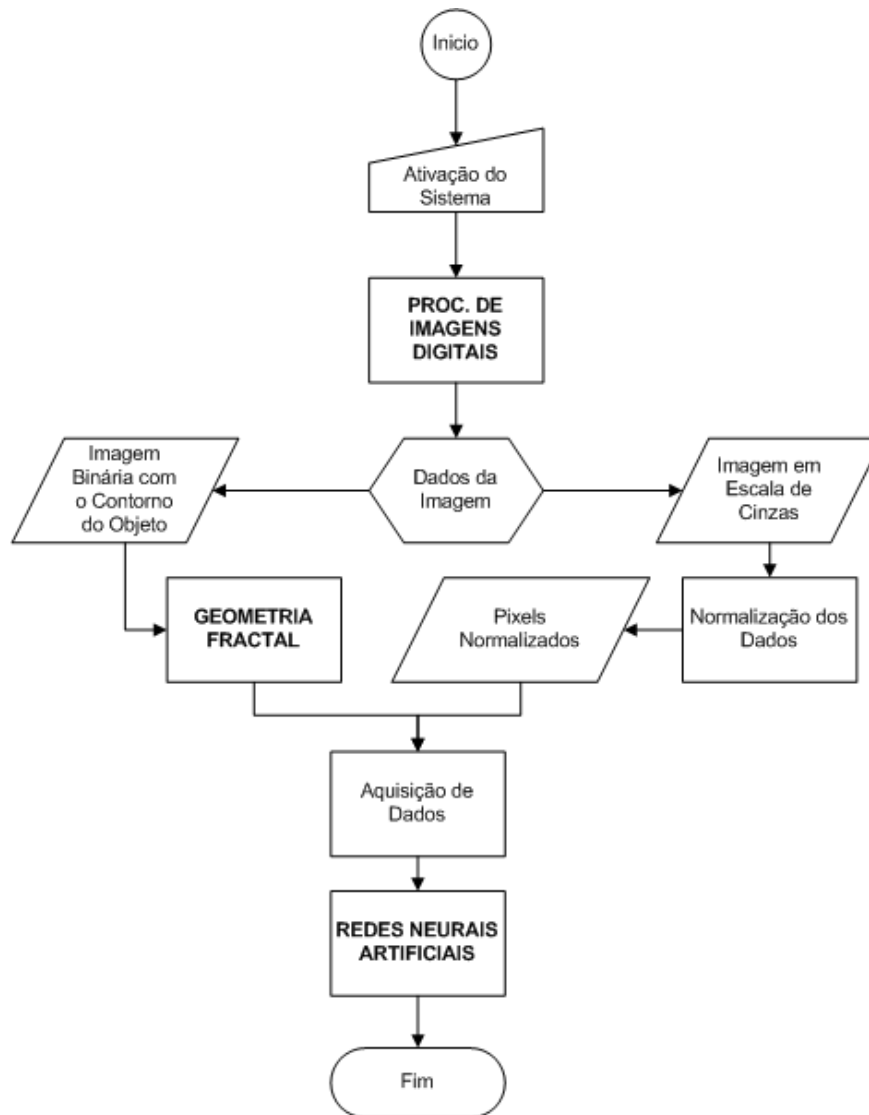


Figura 3.5: Diagrama do modelo proposto.

Primeiramente, há a apresentação do problema, o qual determina a área de atuação da atividade, onde o objeto será avaliado. Posteriormente, as atividades relativas à área de Imagem e Processamento, onde serão realizados processos na imagem de forma que a mesma sofra alterações para tornar-se mais adequada aos procedimentos seguintes. Na etapa da Geometria Fractal, a imagem passa por uma avaliação e é gerado um valor referente à dimensão fractal da mesma. A Rede Neural é responsável por organizar os dados recebidos pelas duas etapas anteriores e realizar o treinamento e classificação dos dados. E, por último, a etapa dos resultados, na qual serão evidenciados os dados obtidos após a classificação e reconhecimento dos dados.

3.3 Etapas do Modelo

3.3.1 Processamento de Imagens

Como sendo o primeiro passo do modelo, a etapa de PDI é responsável por modificar a imagem adquirida, e transformá-la a ponto de estar em seu melhor estado para que possa ser utilizada nos processos seguintes. O objetivo da etapa de processamento de imagens é separar o objeto do restante, ou seja, ter somente informações referentes ao objeto, excluindo o fundo da imagem. A Figura 3.6 exemplifica a sequência de informações geradas no processamento de imagens.




Figura 3.6: Exemplificação das etapas do processamento de imagens. FONTE: Adaptado de (PAVIM X A.; ROLOFF, 2005)

3.3.2 Geometria Fractal e sua Dimensão

Para o cálculo da dimensão fractal existem diversos métodos, dentre eles existe o Box-Counting, comumente utilizado e considerado um dos métodos mais simples de implementar e estimar a dimensão fractal de um dado objeto em uma imagem.

O método Box-Counting consiste basicamente em sobrepor uma malha de quadrados de tamanho M e contar quantos são os números de quadrados que contém alguma parte da imagem, como mostra a Figura 3.7.

Este processo resulta em um certo número N , que depende de M , i.e., $N(M)$. Em seguida, diminui-se o tamanho de M , por serem inversamente proporcionais, o valor de $N(M)$ aumentará, e assim por diante, cada vez com M menor e contando o número de quadrados. Posteriormente, para cada iteração n , contrói-se o gráfico no plano $\log(N(M)) \times \log(1/M)$ marcando seus respectivos pontos. Depois, encaixa-se uma reta nos pontos do diagrama,




Figura 3.7: Exemplo da malha do método Box-Counting. FONTE: (FERNANDES, 2007)

e a medida da inclinação da reta corresponde a dimensão Box-Counting da imagem, representada pela Equação 3.1:

$$Df = \lim_{n \rightarrow \infty} \frac{\log(N_{n+1}(M)) - \log(N_n(M))}{\log\left(\frac{1}{M_{n+1}}\right) - \log\left(\frac{1}{M_n}\right)} \quad (3.1)$$

3.3.3 Redes Neurais Artificiais

Baseando-se nas análises de outros trabalhos, verificou-se que a arquitetura de Redes Neurais Multilayer Perceptron utilizando o algoritmo de Retropropagação de Erro para o aprendizado são as que geram melhores resultados em se tratando de Reconhecimento de Padrões através de imagens, por isso, optou-se pela utilização das mesmas. Nesse método, os dados de entrada são apresentados repetidamente para a rede neural, e ao final de cada iteração, a saída da rede neural é comparada com a saída desejada e um valor de erro é calculado. Esse erro é propagado de volta a rede e usado para ajustar os pesos buscando reduzir o erro a cada etapa, até que o resultado torne-se o mais próximo da saída desejada. A Figura 3.8 mostra o esquema da Rede Neural criada para o modelo.




Figura 3.8: Modelo da RNA para o trabalho.

Trabalho Experimental e Desenvolvimento do Sistema

Neste capítulo serão mostradas as etapas do desenvolvimento do sistema, bem como as simulações propostas.

4.1 *Desenvolvimento do Sistema*

Esta pesquisa foi realizada por meio de revisão de literatura, e apresenta um enfoque quantitativo experimental. Para o desenvolvimento do sistema, foi utilizado a IDE QT Creator 2.0, de programação em C++, de propriedade da Nokia Corporation. Baseado no modelo computacional, o sistema foi desenvolvido em 5 etapas distintas: (1) A primeira etapa é referente ao Processamento de Imagem, (2) Funções da Geometria Fractal, (3) Desenvolvimento de uma RNA MLP utilizando o algoritmo de Retropropagação de Erro, (4) Adaptação da entrada da Rede Neural para os dados, e (5) Treinamento, Testes e Validação.

4.1.1 *Implementação do Processamento de Imagens*

O processamento de imagens utiliza, como o próprio nome diz, a imagem como matéria prima. Para tanto, foi necessário transformar a imagem original de forma que se adapte a maneira com a qual vai ser processada.

A aquisição de imagens foi realizada de duas formas diferentes. A primeira foi feita através de busca na internet, seja por meio de banco de dados de imagens ou de forma aleatória. A segunda foi adquirida por uma máquina fotográfica digital, posicionada a uma distância de 30 centímetros e fixada a um ângulo de 90 graus em relação a superfície, luminosidade proveniente da própria câmera e de lâmpadas fluorescentes presentes no ambiente. Todas as imagens adquiridas possuem o parafuso na posição horizontal. No total, obteve-se 184 imagens, posteriormente divididas em grupos para a realização dos testes. Sabe-se que a qualidade da imagem é diretamente ligada ao tamanho das imagens, logo não houve a necessidade de utilizar uma máquina acima de 3 megapixels, já que todas as imagens tiveram que ser reduzidas. Após a aquisição, foi necessário manipular as imagens manualmente para que as mesmas tivessem um tamanho padrão, foram testados quatro tamanhos diferentes, (1) 176x144px, (2) 156x124px, (3) 154x62px e por último, (4) 152x56px, tamanho

este que apresentou melhores resultados na manipulação dos pixels além de apresentar uma quantidade menor de dados para a rede sem prejudicar a performance do sistema. Para isso, foi utilizado um software livre para manipulação de imagens, chamado GIMP, na versão 2.6.11.

Sabendo que qualquer meio utilizado para a obtenção de imagens pode interferir na mesma, pode ser necessário manipulá-las para que se obtenha a melhor imagem possível. Na teoria, os esforços para adquirir uma imagem perfeita deveriam ser feitos no momento da aquisição, mas como na prática isto implica em gastos financeiros e computacionais altos, a opção utilizada pela maioria é a utilização de softwares de manipulação de imagens para tratá-las e torná-las o mais próximo da “perfeição”.

4.1.1.1 Métodos de Processamento

Para a realização do processo, foi necessário utilizar três tipos de manipulação: (1) Filtragem Linear no Domínio Espacial, (2) Transformações Radiométricas e, (3) Detecção de Contorno.

1. Filtragem Linear no Domínio Espacial

A utilização de filtros lineares tem como objetivo modificar o valor de um pixel tendo como base seu valor de original e dos pixels da vizinhança. Essas mudanças podem ser no intuito de corrigir, suavizar ou realçar determinadas características de uma imagem dentro de uma aplicação específica. Atua no domínio espacial por operar diretamente sobre os pixels da imagem em sua forma original. Esse processo de filtragem é feito utilizando matrizes, chamadas de máscaras, que são aplicadas sobre a imagem original, e percorrem todas as linhas e colunas. As máscaras podem ser geradas em dimensões $M \times N$, sendo que o pixel resultante obedece a seguinte Equação 4.1:

$$r(i, j) = \sum_{m=1}^M \sum_{n=1}^N p(m, n) * h(m, n) \quad (4.1)$$

onde $r(i, j)$ é o valor novo do pixel e i e j são suas coordenadas, $p(m, n)$ é o pixel original e $h(m, n)$ é a máscara escolhida. No sistema foram utilizados dois filtros: (1) filtro passa-baixa e, (2) filtro passa-alta.

- (a) Filtro Passa-Baixa: São filtros que atenuam ou eliminam as altas frequências que estão associadas as informações de detalhes da imagem. Seu efeito visual é o de suavizar a imagem, que conseqüentemente minimiza o efeito dos ruídos. Em contrapartida, diminui a nitidez e definição da imagem. A Figura 4.1 mostra as

máscaras que foram testadas nas imagens, sendo que a utilizada foi a (b) por apresentar um melhor resultado.

$$\begin{array}{cc}
 \frac{1}{10} * \begin{array}{|c|c|c|} \hline 1 & 1 & 1 \\ \hline 1 & 2 & 1 \\ \hline 1 & 1 & 1 \\ \hline \end{array} & \frac{1}{16} * \begin{array}{|c|c|c|} \hline 1 & 2 & 1 \\ \hline 2 & 4 & 2 \\ \hline 1 & 2 & 1 \\ \hline \end{array} \\
 (a) & (b)
 \end{array}$$

Figura 4.1: Filtros lineares Passa-Baixa 3x3:

- (b) Filtro Passa-Alta: Ao contrário do passa-baixa, este filtro atenua ou elimina as baixas frequências, realçando os detalhes, ou seja, torna mais nítida as transições entre regiões diferentes, realçando o contraste. Seu efeito colateral é o de intensificar o ruído existente na imagem. A figura 4.2 mostra a máscara usada como passa-alta.

$$\mathbf{1} * \begin{array}{|c|c|c|} \hline -1 & -1 & -1 \\ \hline -1 & 8 & -1 \\ \hline -1 & -1 & -1 \\ \hline \end{array}$$

Figura 4.2: Filtro linear Passa-Alta 3x3:

No intuito de obter uma imagem sem ruído, ou com o mínimo possível, utilizou-se o filtro passa-baixa, porém, como a mesma implica na perda de nitidez, foi necessário utilizar posteriormente o filtro passa-alta para aumentar a nitidez.

2. Transformações Radiométricas

São transformações que independem da localização dos pixels na imagem (FALCAO ALEXANDRE X; LEITE, 2003). Foram feitas três transformações radiométricas: (1) Escala de Cinzas, (2) Histograma e, (3) Binarização.

- (a) Escala de Cinzas: Inicialmente foi feita a transformação da imagem colorida em escala de cinzas. Para isso, é mister saber que o pixel é formado pela combinação das três cores primitivas da escala RGB: (1) vermelho, (2) verde e, (3) azul. Mas para a transformação em escala de cinzas, foi necessário separar essas cores. Depois da separação, as cores vermelho, verde e azul precisam ser acrescentadas em 30%, 11% e 59% de seu valor, respectivamente, e a sua soma equivale ao valor em tom de cinza (GONZALEZ RAFAEL C.; WOODS, 2002). Por

exemplo, um pixel $p=$ é decomposto em $R_p=x$, $G_p=y$ e $B_p=z$, posteriormente, $P=(R_p+R_p*30\%) + (G_p+G_p*11\%) + (B_p+B_p*59\%)$.

- (b) Histograma e Binarização: O histograma é um gráfico que indica a quantidade de vezes em que uma determinada cor se repete, e para a criação do histograma é necessário contar a frequência de ocorrência dos níveis de cinza da imagem (FALCAO ALEXANDRE X; LEITE, 2003). É por meio do histograma que é possível obter um valor de *threshold*, ou limiar, para poder binarizar a imagem, i.e., transformá-la em uma imagem somente com pixels brancos e pretos. Por observação, chegou-se a um valor médio de *threshold* igual a 178. A partir dessa definição, todos os pixels da imagem que são menores que 178 tornam-se brancos, e os que são maiores ou igual tornam-se pretos. Desta forma a imagem que antes estava em escala de cinzas, tornou-se binária, fazendo com que o objeto do reconhecimento seja evidenciado, como mostra a Figura 4.3.




Figura 4.3: Imagem após as 3 primeiras etapas.

3. Detecção de Contorno

Para a realização do cálculo da dimensão fractal foi necessário obter o contorno do objeto da imagem. Tal procedimento foi feito por meio de uma operação elementar da morfologia matemática, a dilatação. Compreende na mudança do valor do pixel da vizinhança pelo valor do pixel central. No caso do sistema foi feito o seguinte algoritmo:

Sendo p =pixel, $p(x,y)$ =valor do pixel, 0 para branco e 1 para preto.

Se $p(x,y)=1$

$p(x-1,y-1), p(x-1,y), p(x-1,y+1), p(x,y-1), p(x,y), p(x,y+1), p(x+1,y-1), p(x+1,y), p(x+1,y+1) = 1$

Figura 4.4: Algoritmo de dilatação por vizinhança D8.

Desta forma, o objeto na imagem aumenta de tamanho. E a partir dela, foi feita uma subtração dos elementos da imagem original pela imagem dilatada, onde o resultado

Tabela 4.1: Tabela da quantidade de quadrados para o método Box-Counting

M	Quantidade
2	2.128
4	532
8	$\cong 133$
16	$\cong 27$

foi posto em uma terceira imagem que contém somente a borda, conforme mostra o algoritmo e a Figura 4.6 resultante.

Sendo p_n =pixel da imagem n , $p_n(x,y)$ =valor do pixel da imagem n , $n=\{1,2,3\}$, 0 para branco e 1 para preto.

Se $p_1(x,y) \neq p_2(x,y)$
 $p_3(x,y)=1$

Senão
 $p_3(x,y)=0$

Figura 4.5: Algoritmo de subtração de imagens.




Figura 4.6: Imagem resultante do processo de extração da borda.

4.1.2 Implementação da Dimensão Fractal

Para calcular a dimensão fractal de um dado objeto foi utilizado o método do Box-Counting, explicado em 3.2.3. Baseando-se na Equação 1, para o sistema, foram feitos cálculos com $M=2, 4, 8, 16$, obtendo os valores da Tabela 4.1.

4.1.3 Rede Neural

A rede neural do modelo é composta por uma camada de entrada, uma camada oculta e uma camada de saída. A camada de entrada possui tantas entradas quanto a quantidade de pixels da imagem mais uma, ou seja, 8.512 unidades. Visto que uma das necessidades da pesquisa é a identificação de defeitos em objetos, a análise de cada ponto da imagem é de grande importância. Como consequência da grande quantidade de entradas, o custo computacional do processo é alta. A camada oculta possui 4.256 neurônios e a camada de saída possui 1, 4 e 8 neurônios, pois foram feitas três topologias para a pesquisa.

4.2 O Sistema

O sistema foi desenvolvido em algumas etapas. Primeiramente, foi feito um módulo de aquisição da imagem e processamento da imagem, nele é feita a aquisição da imagem, pré-processada e obtido o contorno. Posteriormente foi criado um módulo de aquisição dos dados de entrada, este procedimento é responsável por extrair os valores de pixels das imagens contidas nos grupos e colocá-las em um arquivo texto para que a fase de treinamento torne-se mais ágil. Posteriormente, os módulos referentes ao cálculo da dimensão fractal e da rede neural. Por último foi desenvolvido a interface do aplicativo.

4.2.1 Dados de Entrada

Para uma maior agilidade na fase do treinamento e uma redução no custo computacional dos cálculos, preferiu-se tratar os dados anteriormente a fazer esse processo em tempo real. Devido ao número de testes e as diferentes quantidades de dados de entrada, foram criados arquivos separados contendo tais informações. Esses arquivos foram separados em Treinamento, Teste e Validação, respeitando a quantidade de imagens definidas para cada etapa em cada cenário e seus valores de pixels devidamente normalizados. Um exemplo do resultado desse processo pode ser conferido na Figura 4.7.

Em geral, os arquivos tiveram a seguinte forma de nomenclatura: tipo-do-cenario_tipo-da-etapa+numero-de-teste_grupo+tipo-grupo. Os arquivos do Cenário 01 foram nomeados com a seguinte terminação: cen01_YW_g0ZX, onde $Y=\{\text{tr, te, va}\}$, $W=\{1, 2, 3\}$, $Z=\{1, 2, 3, 4\}$ e $X=\{\text{n, d}\}$. Os elementos do conjunto Y são referentes a treinamento (tr), teste (te) e validação (va), e os elementos de X são normais (n) e defeituosos (d). Já os arquivos dos Cenários 02 e 03 tiveram a nomenclatura baseada em: cen0X_YW, onde $X=\{2, 3\}$, $Y=\{\text{tr, va}\}$, $W=\{1, 2\}$, devido ao fato de não possuírem a etapa de teste nem o terceiro teste.




Figura 4.7: Imagem do arquivo texto gerado contendo os valores dos pixels normalizados utilizados como dados de entrada da rede neural.

4.2.2 Componentes do Aplicativo

A interface do aplicativo foi desenvolvida para ser bastante amigável ao usuário e está ilustrada na Figura 4.8. Na interface, todos os módulos foram representados, porém somente dois módulos seriam realmente necessários: (1) Aquisição de Dados e, (2) Redes Neurais. Os módulos de pré-processamento e da dimensão fractal possuem somente a visualização do resultado para apreciação do usuário pois não enviam informações necessárias para que o aplicativo deixe de funcionar.

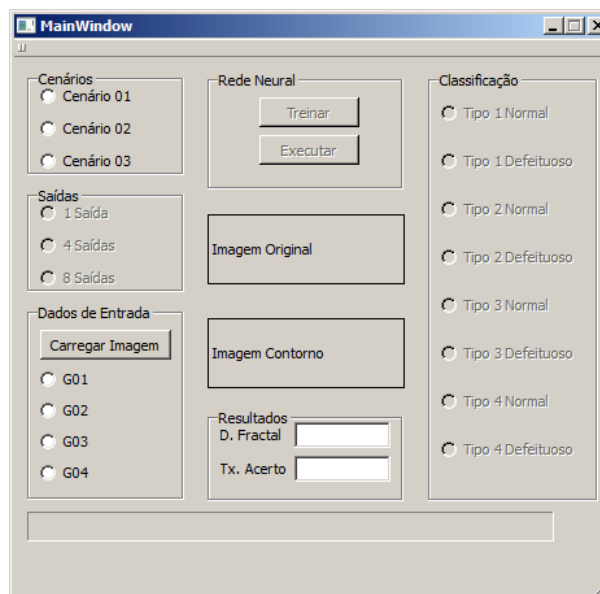


Figura 4.8: Interface do aplicativo desenvolvido.

A Figura 4.9 mostra dois componentes da interface: (1) Cenários e, (2) Saídas. Para dar início ao funcionamento do aplicativo, é necessário escolher qual o cenário que será utilizado. Por *default*, o componente Saídas vem desabilitado, e serve só para informar ao usuário da quantidade de saídas que a rede neural terá. No momento da escolha do

cenário, a saída é automaticamente selecionada.



Figura 4.9: Componentes da interface do aplicativo relacionadas à escolha do Cenário.

A Figura 4.10 mostra os componentes: (1) Dados de Entrada e, (2) Rede Neural. No primeiro componente, o botão “Carregar Imagem” é responsável por enviar a imagem que será avaliada. Nesse componente também há a escolha do Grupo de Treinamento, estes itens somente estarão habilitados quando o cenário escolhido for o Cenário 01, por ser o único no qual se escolhe o grupo que será treinado e testado. O segundo componente, Rede Neural, possui os botões de treinamento e execução da rede, que somente estarão habilitados se todos os itens necessários estiverem selecionados.



Figura 4.10: Componentes da interface responsáveis pela aquisição e informação de dados para a rede neural, e os componentes de Treinamento e Execução da RNA.

A Figura 4.11 mostra três componentes de resultados: (1) Resultados, (2) Classificação e, (3) Imagem Contorno. O componente de Resultados mostra os valores da dimensão fractal da imagem a ser avaliada, e a porcentagem da provável taxa de acerto da rede para a imagem fornecida. O componente Classificação mostra objetivamente o resultado da execução da rede. Inicialmente vem totalmente desabilitado, e dependendo do cenário escolhido, os possíveis resultados serão habilitados. E somente para efeito de visualização, o terceiro componente mostra o contorno do objeto escolhido para ser testado.

As Figuras 4.12, 4.13 e 4.14 mostram os itens habilitados conforme as escolhas realizadas. A Figura 4.15 mostra a tela do aplicativo sendo utilizada.



Figura 4.11: Componentes da interface que mostram os resultados obtidos.

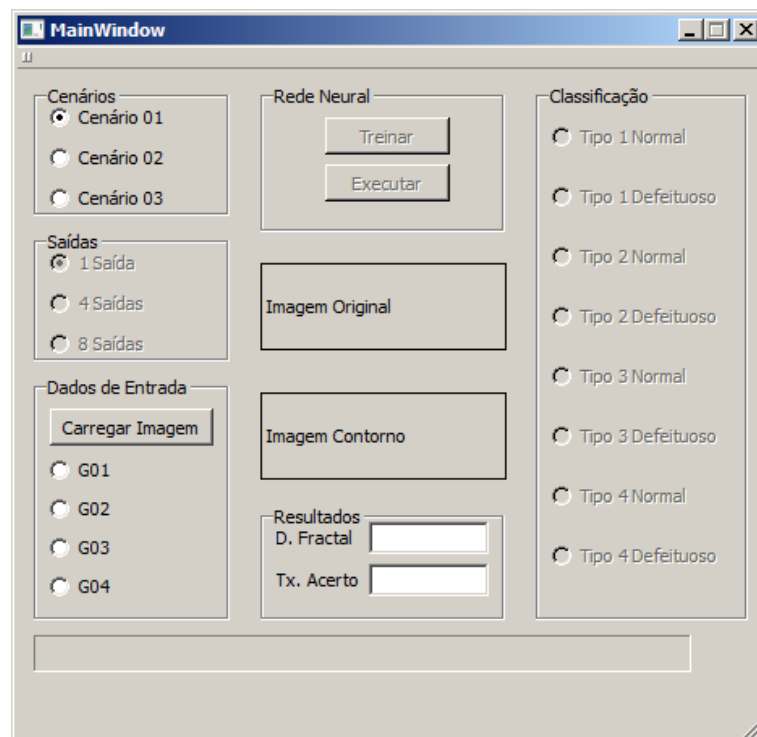


Figura 4.12: Aplicativo com Cenário 01 selecionado e seus respectivos itens habilitados.

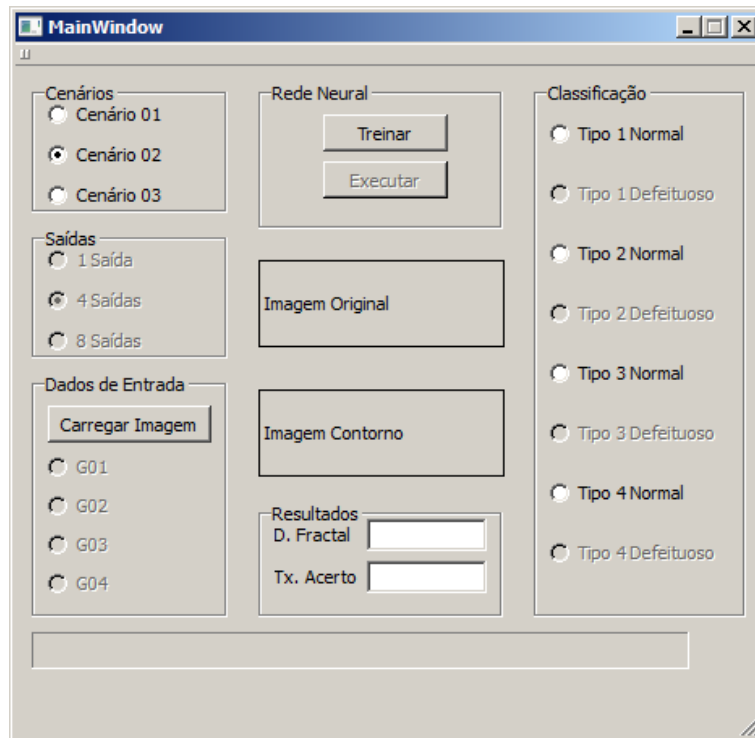


Figura 4.13: Cenário 02 escolhido e itens habilitados .

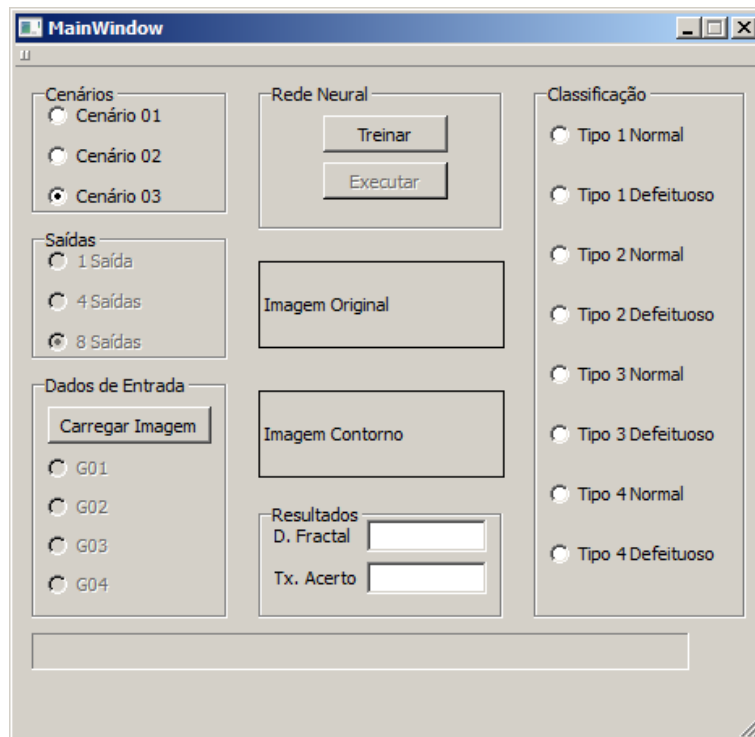


Figura 4.14: Interface do aplicativo com o terceiro cenário escolhido e os itens desabilitados.

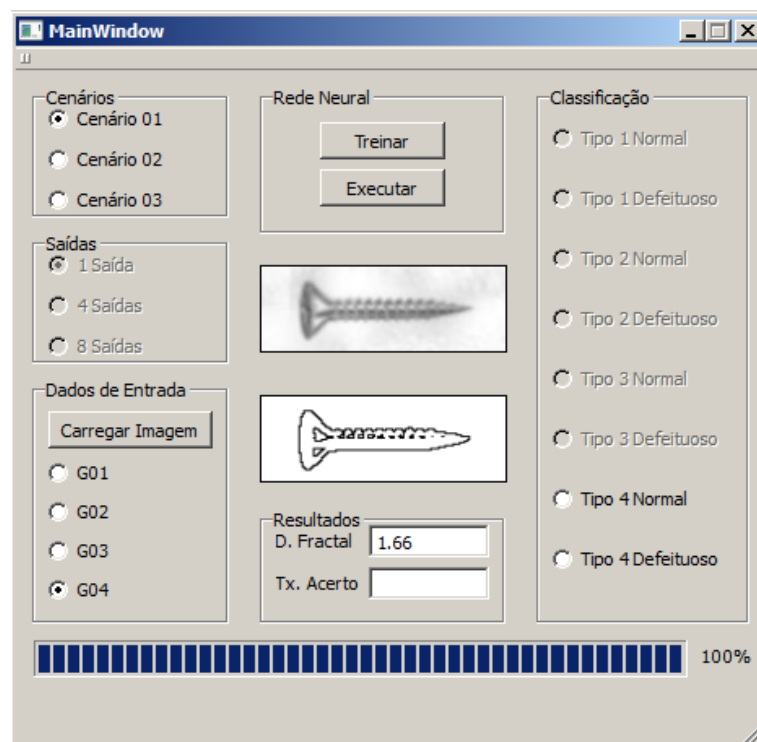


Figura 4.15: Imagem do aplicativo em execução.

Experimentos e Resultados

Neste capítulo serão feitas considerações acerca do treinamento de cada uma dessas redes e serão apresentados os resultados do sistema proposto, bem como os resultados obtidos pela referida metodologia, com a aplicação do conjunto de testes e validação. Os experimentos foram divididos em dois grupos principais: (1) experimentos que utilizam a dimensão fractal como um dos parâmetros da Rede Neural, e (2) experimentos que não usam a dimensão fractal.

5.1 Base de Imagens

As imagens de objetos utilizadas foram coletadas conforme o procedimento descrito em 4.1.1 através de duas formas diferentes: (1) por meio da internet e, (2) por meio de câmera fotográfica. Foram coletadas um total de 184 amostras, divididas em quatro classes, aqui denominadas G01, G02, G03 e G04, totalizando assim 46 exemplares/amostras por classe. Tais imagens foram gravadas com o padrão de compressão JPEG e com a resolução de 152x56 pixels. Como dito anteriormente, o processo de aquisição não é perfeito, o que pode acarretar na presença de ruídos na imagem final, de forma que o pré-processamento não seja capaz de eliminar. É importante considerar o fato de que a aquisição de um objeto 3D para uma imagem (2D) implica no aparecimento de sombras e/ou sobreposições, o que também pode prejudicar o resultado final da imagem.

5.2 Preparação dos Dados e Configuração da Rede

De um total de 184 amostras, separadas em quatro grupos, variando de 43% a 60% das amostras de cada classe foram submetidas como entrada da rede na etapa de treinamento, essa quantidade varia de acordo com as simulações realizadas. Antes de serem inseridas na rede, é importante que todos os dados de entrada, no caso os pixels, sejam tratados. Esse processo é chamado de normalização, que é um ajuste na escala dos valores. A análise de similaridade dos componentes dos dados possuem escalas de medidas diferentes, podendo haver uma variância menor ou maior. Sendo ela menor, quer dizer que uma pequena variação nesse componente pode ser mais relevante que em um componente com maior variância, i.e., com os valores em uma faixa definida a classificação de um padrão torna-se mais fácil. Os dados normalizados não perdem o significado da informação, são apenas convertidos numa nova escala. Os valores dos pixels originais estavam em uma faixa de 0

a 255, e foram normalizados pela Equação 5.1 para uma faixa entre 0 e 1.

$$P = \frac{(p - p_{min})}{(p_{max} - p_{min})} \quad (5.1)$$

Onde P é o valor do pixel normalizado, p é o valor do pixel original, e p_{min} e p_{max} , são respectivamente o menor e o maior valor do intervalo do conjunto original.

5.2.1 Arquitetura da Rede Neural

A Rede Neural desenvolvida para o sistema é composta por uma camada de entrada, uma camada oculta e uma camada de saída. Porém, para a realização dos testes foram utilizadas três variações da arquitetura, conforme Tabela 5.1:

Tabela 5.1: Tabela de topologias de rede submetidas ao sistema.

Camada	Modelo 01	Modelo 02	Modelo 03
Entrada	8.512+1 neurônios	8.512+1 neurônios	8.512+1 neurônios
Oculta	4.256 neurônios	4.256 neurônios	4.256 neurônios
Saída	1 neurônio	4 neurônios	8 neurônios

Como visto em 4.1.3, a camada de entrada possui 8.209 entradas, cada uma referente a um pixel da imagem, e mais um referente a dimensão fractal. A camada oculta inicialmente foi criada com a mesma quantidade da camada de entrada, porém, devido ao custo computacional e resultados com pouca diferença, optou-se por utilizar metade da quantidade. A camada de saída possui três variações, cada uma para um tipo de simulação realizada. Posteriormente, definiu-se a função de transferência sigmóide visto que a mesma limita a saída dos neurônios a uma pequena faixa. A rede foi treinada seguindo os parâmetros apresentados na Tabela 5.2.

Tabela 5.2: Parâmetros de treinamento da rede neural

Parâmetro	Valor
Épocas	5.000
Erro Médio	0.01
Taxa de Aprendizado	0.3
Peso	[-0.2,0.2]

5.2.2 Classes de Objetos

As imagens obtidas foram separadas em quatro classes, cada uma contendo 46 amostras do objeto. Para cada classe, foram manipulados cerca de 30% das imagens, o equivalente a 14 unidades, para que apresentassem algum tipo de defeito que o pré-processamento não fosse capaz de alterar. A Figura 5.1 mostra um objeto que foi manipulado para apresentar defeito.




Figura 5.1: Imagem de um objeto normal (a) e uma figura manipulada para ter defeito (b).

Percebe-se que na imagem (b) foram modificados quatro pontos do objeto. Em dois deles, foram retirados filetes da parte rosqueada, na parte não rosqueada do parafuso foi feita uma extração da imagem, defeito tal que pode ser gerado no momento da aquisição, e por último, a ponta do parafuso que foi desgastada.

5.2.3 Métricas de Avaliação

Para fazer uma análise dos resultados, foram adotadas algumas técnicas de avaliação de classificadores. Segundo (CONGALTON, 1991), a partir de uma amostra de referência já é possível fazer uma avaliação. Neste projeto utilizou-se a Matriz de Confusão, ou Matriz de Erros, e o Índice Kappa.

5.2.3.1 Matriz de Confusão

A matriz de confusão é considerada uma base padrão para se calcular medidas de avaliação de hipóteses em problemas de classificação. O objetivo principal desta métrica é mostrar os números de previsões corretas em relação às esperadas para cada regra (CRUZ ELEAN-DRO S.; CARVALHO, 2008). Também chamada de matriz de erros, é uma matriz quadrada de dimensão igual ao número de classes avaliadas. Nessa matriz, os resultados da classificação são colocados nas colunas, estando na diagonal principal os números de observações

que tiveram a classificação de acordo com sua referência. No restante da coluna, está o número de observações omitidas e classificadas como outras classes, denominadas de erro de omissão (CONGALTON, 1991). A Tabela 5.3 mostra a nomenclatura utilizada numa matriz de duas classes utilizada na pesquisa, onde suas classes são “Normal” e “Defeituosa”, respectivamente representados na matriz por “Norm” e “Def”.

Tabela 5.3: Matriz de Confusão com duas classes. FONTE: (CONGALTON, 1991)

R/P	Norm	Def
Norm	Verdadeiro Positivo (VP)	Falso Negativo (FN)
Def	Falso Positivo (FP)	Verdadeiro Negativo (VN)

5.2.3.2 Índice Kappa

Desenvolvido por Cohen em 1960, o Índice Kappa (K) é uma medida estatística usada para medir o grau de concordância interobservador. A taxa de acerto total utiliza somente os dados que foram ditos verdadeiros, i.e., os resultados VP e VN, enquanto o Índice Kappa utiliza todos os dados obtidos (VP, VN, FP e FN), por este motivo é mais utilizado que a taxa de acerto total (CRUZ ELEANDRO S.; CARVALHO, 2008). Este índice é encontrado por meio da Equação 5.2:

$$K = \frac{A_t - \theta}{1 - \theta} \quad (5.2)$$

em que, K é o coeficiente Kappa, A_t é o Acerto Total (Equação 5.5) e, θ é a quantidade esperada de acerto por acaso, calculada pela Equação 5.3.

$$\theta = \frac{\sum_{i=1}^c x_{i\oplus} * x_{\oplus i}}{n^2} \quad (5.3)$$

Segundo Hudson e Ramm (1987), o coeficiente Kappa pode ser estimado a partir dos totais marginais da matriz confusão, pela seguinte Equação 5.4 (CRUZ ELEANDRO S.; CARVALHO, 2008):

$$K = \frac{n * \sum_{i=1}^c x_{ii} - \sum_{i=1}^c x_{i\oplus} * x_{\oplus i}}{n^2 - \sum_{i=1}^c x_{i\oplus} * x_{\oplus i}} \quad (5.4)$$

onde,

- X_{ii} = valor na linha i e coluna i da matriz confusão;
- $X_{i\oplus}$ = total da linha i ;
- $X_{\oplus i}$ = total da coluna i ;
- n = total de amostras;
- c = número total de classes.

Para avaliar se a concordância é razoável, Landis Jr. e Koch GG sugerem as seguintes medidas conforme a Tabela 5.4 (CRUZ ELEANDRO S.; CARVALHO, 2008):

Tabela 5.4: Tabela de medidas avaliatórias do Índice Kappa. FONTE: (CRUZ ELEANDRO S.; CARVALHO, 2008)

Valor do Índice	Interpretação (Concordância)
<0	Sem
0 - 0,19	Mínima
0,20 - 0,39	Baixa
0,40 - 0,59	Moderada
0,60 - 0,79	Substancial
0,80 - 1,00	Alta

5.2.3.3 Parâmetros de Avaliação dos Resultados

Os resultados obtidos neste projeto serão apresentados e avaliados através dos parâmetros abaixo (CRUZ ELEANDRO S.; CARVALHO, 2008):

- Erros de Omissão (E.Om.): são descritos como a falha de classificação de uma determinada classe;
- Erros de Comissão (E.Co.): são descritos como atribuição de uma imagem a uma classe a qual não pertence;
- Taxa de Acerto Total (A_t): representa o nível da classificação, é obtida a partir da Equação 5.5:

$$A_t = \frac{\sum_{i=1}^c x_{ii}}{n} \quad (5.5)$$

O Acerto Total é calculado pela divisão da soma da diagonal principal pelo número total de amostras, onde, n representa o número total de amostras; x_{ii} representa os números da diagonal principal e c , o número de classes presentes.

- Sensitividade (S): é a habilidade de classificar corretamente os objetos pertencentes à dada categoria, representada pela Equação 5.6:

$$S = \frac{VP}{VP + FN} \quad (5.6)$$

- Especificidade (E): refere-se a classificação correta dos objetos não pertencentes à categoria, calculado pela da Equação 5.7:

$$E = \frac{VN}{VN + FP} \quad (5.7)$$

5.3 Descrição dos Experimentos Realizados

Os experimentos foram realizados em duas fases como mostra a Figura 5.2, na primeira, utilizou-se a dimensão fractal como parâmetro de treinamento na rede, já na segunda, esse parâmetro foi retirado, para que possa ser feita uma análise do uso da geometria fractal neste tipo de pesquisa. Ambos possuem os mesmos testes e as mesmas imagens para que a comparação seja realizada de forma correta.

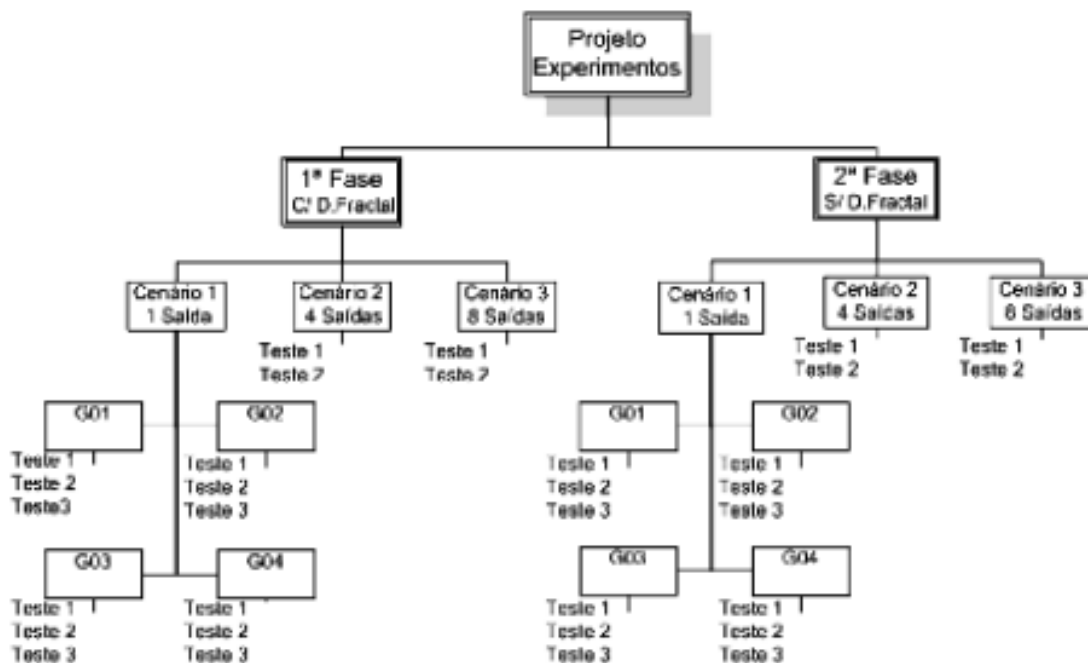


Figura 5.2: Diagrama dos experimentos realizados.

5.3.1 Descrição dos Cenários

Para o desenvolvimento da pesquisa, foram realizados três cenários diferentes. O objetivo da Cenário 01 é provar que o sistema sabe classificar se o objeto é defeituoso ou não, utilizando o modelo 01 da topologia. Foi realizado em tantas fases quanto a quantidade de classes constituintes, i.e. formado por 4 fases, cada uma referente a um tipo de objeto. O Cenário 02 utiliza o modelo 02 da topologia e realiza a tarefa de classificar um objeto específico numa rede treinada pelas quatro classes sem a inclusão das amostras defeituosas. Esses cenários foram criados de forma a comprovar a funcionalidade do modelo, mas, é no Cenário 03 que o estudo se concentra. O mesmo é composto pela união dos dois objetivos anteriores, ou seja, serve para classificar o objeto e identificar se é defeituoso ou não, utilizando o modelo 03 de topologia.

5.3.1.1 Cenário 01

O primeiro cenário tem como objetivo a separação de objetos com e sem defeito. Foi realizado em quatro etapas, referentes as classes utilizadas na pesquisa. A saída da rede neural deste cenário é binária e denominada de Alvo_Cen01, como mostra a Tabela 5.5, e utiliza o total de imagens adquiridas.

Tabela 5.5: Especificação do Cenário 01.

Classes	Amostras Normais	Amostras Defeituosas	Total de Amostras
G01	32	14	46
G02	32	14	46
G03	32	14	46
G04	32	14	46
Total	128	56	184
Alvo_Cen01	0	1	

Cada etapa foi composta por três testes, variando-se as quantidades de dados nas fases de treinamento, teste e validação da rede neural. A Tabela 5.6 descreve a quantidade de imagens utilizadas e como foram distribuídas nos diferentes experimentos.

Tabela 5.6: Distribuição da quantidade de dados nas fases da rede neural no primeiro cenário.

Etapas	Teste 01		Teste 02		Teste 03	
	Normal	Def.	Normal	Def.	Normal	Def.
Treinamento	24	4	18	6	12	8
Teste	2	3	3	2	0	0
Validação	6	7	11	6	20	6

5.3.1.2 Cenário 02

Neste cenário foram utilizadas todas as imagens que não apresentavam defeitos. Utilizando o modelo 2 da topologia, essa rede busca classificar os dados em suas respectivas classes. A Tabela 5.7 mostra o conjunto saída da rede, agora composto por quatro unidades.

Tabela 5.7: Especificação do Cenário 02.

Conjunto	G01	G02	G03	G04	Total de Amostras
Quantidade de Imagens	32	32	32	32	128
Alvo_Cen02	1	2	3	4	

Este cenário foi composto por dois testes, conforme mostra a tabela 5.8:

Tabela 5.8: Distribuição da quantidade de dados nas fases da rede neural no segundo cenário.

Etapas	Teste 01		Teste 02	
	G01/G02/G03/G04		G01/G02/G03/G04	
Treinamento	10un/classe		20un/classe	
Teste	10un/classe		0	
Validação	12un/classe		12un/classe	

5.3.1.3 Cenário 03

Como sendo o experimento objetivo do projeto, o Cenário 03 utiliza todas as imagens adquiridas, isso inclui as imagens normais e as defeituosas. Utilizando o modelo 3 da topologia, busca classificar as imagens em suas respectivas classes bem como separá-las entre normais e defeituosas. Foi utilizado um conjunto saída com 8 neurônios, conforme mostra a Tabela 5.9.

Tabela 5.9: Especificação do Cenário 03.

Conjunto	G01		G02		G03		G04		Total de Amostras
	N	D	N	D	N	D	N	D	
Quantidade de Imagens	32	14	32	14	32	14	32	14	184
Alvo_Cen03	1	2	3	4	5	6	7	8	

No parâmetro Alvo_Cen03, os alvos ímpares referem-se as imagens normais das classes, e as pares às imagens com defeito. Este cenário foi composto por dois testes, com a distribuição de imagens conforme Tabela 5.10.

Tabela 5.10: Distribuição da quantidade de dados nas fases da rede neural no terceiro cenário.

Etapas	Teste 01		Teste 02	
	G01/G02/G03/G04 (un/classe)		G01/G02/G03/G04 (un/classe)	
	N	D	N	D
Treinamento	10	5	16	7
Teste	0	0	0	0
Validação	22	9	16	7

5.4 Análise e Discussão dos Resultados

A seguir são apresentados os gráficos dos resultados obtidos nos experimentos realizados, divididos em duas fases. No Apêndice B, encontram-se tabelas com todas as informações dos resultados obtidos.

5.4.1 Primeira Fase

A primeira fase contém as experiências que utilizaram a dimensão fractal como parâmetro da rede.

5.4.1.1 Cenário 01

Como dito anteriormente, o objetivo do Cenário 01 é identificar em cada classe quem era defeituoso e quem não era.

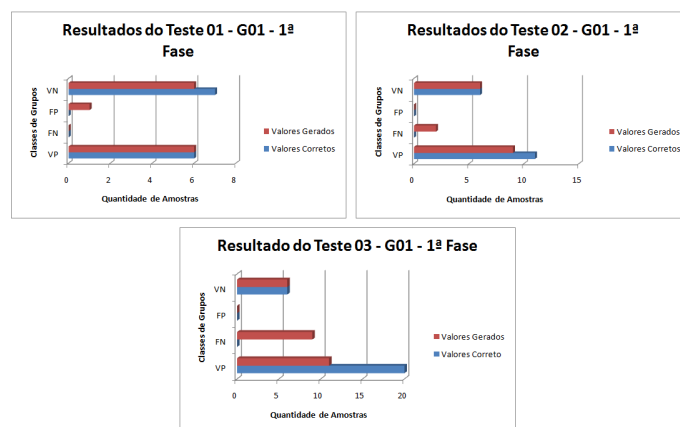


Figura 5.3: Gráfico dos resultados obtidos nos testes do Cenário 01 - Grupo 01 da primeira fase.

O Cenário 01 em geral obteve uma média de acerto satisfatória, onde o G01 (Figura 5.3),




Figura 5.4: Gráfico dos resultados obtidos nos testes do Cenário 01 - Grupo 02 da primeira fase.

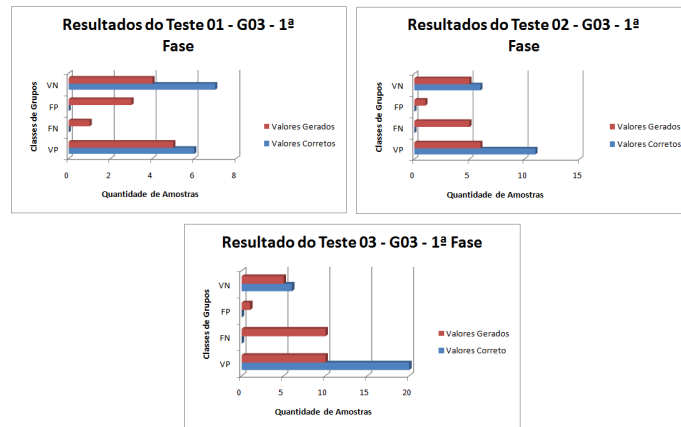


Figura 5.5: Gráfico dos resultados obtidos nos testes do Cenário 01 - Grupo 03 da primeira fase.

G02 (Figura 5.4), G03 (Figura 5.5) e G04 (Figura 5.6), obtiveram respectivamente uma média de acerto, baseado no índice Kappa, igual a 81,7%, 77,7%, 62,% e 82,3%. Observa-se que em todos os grupos, a taxa de acerto decresce a medida que os testes avançam, isto foi provocado pela diminuição das amostras na fase de treinamento e conseqüentemente no aumento da fase de validação. Os grupos G04 e G01 obtiveram os melhores resultados, enquanto o G03 obteve o pior dentre eles.

5.4.1.2 Cenário 02

Utilizando 32 imagens de cada classe e distribuídas de diferentes formas nos dois testes realizados, a simulação do Cenário 02 da primeira fase apresentou os seguintes resultados conforme mostra as Figuras 5.7 e 5.8:

Com o intuito de classificar os objetos em suas respectivas classes, o modelo apresentou bons resultados. Pela análise do Índice Kappa, 0,79 e 0,87 respectivamente para o primeiro




Figura 5.6: Gráfico dos resultados obtidos nos testes do Cenário 01 - Grupo 04 da primeira fase.




Figura 5.7: Gráfico dos resultados obtidos nos testes do Cenário 02 - Teste 01 da primeira fase.

e segundo teste, o resultado é avaliado como substancial e alta.

5.4.1.3 Cenário 03

Com toda a quantidade de amostras obtidas, i.e., as 184 imagens, as Figuras 5.9 e 5.10 apresentam os resultados obtidos do Cenário 03:

Por ser a simulação objetivo do trabalho, os resultados dos testes 1 e 2 do Cenário 3 obtiveram uma classificação alta.




Figura 5.8: Gráfico dos resultados obtidos nos testes do Cenário 02 - Teste 02 da primeira fase.




Figura 5.9: Gráfico dos resultados obtidos nos testes do Cenário 03 - Teste 01 da primeira fase.

5.4.2 Segunda Fase

A segunda fase foi realizada sem a utilização da dimensão fractal como parâmetro e constituída dos mesmos cenários e testes que a primeira fase.

5.4.2.1 Cenário 01

Treinada com as mesmas imagens da primeira fase, as redes neurais das classes G01 (Figura 5.11), G02 (Figura 5.12), G03 (Figura 5.13) e G04 (Figura 5.14) apresentaram os seguintes resultados:

As simulações do Cenário 01 na segunda fase, obtiveram índices inferiores ao apresentado




Figura 5.10: Gráfico dos resultados obtidos nos testes do Cenário 03 - Teste 02 da primeira fase.




Figura 5.11: Gráfico dos resultados obtidos nos testes do Cenário 01 - Grupo 01 da segunda fase.

na primeira fase, contudo obteve um desempenho satisfatório. Igualmente ao primeiro teste, o grupo G03 apresentou um menor desempenho, e índices pouco satisfatórios.

5.4.2.2 Cenário 02

Os resultados do Cenário 02 estão nas Figuras 5.15 e 5.16:

Felizmente ao contrário dos resultados do cenário anterior, este apresentou melhores índices, sendo classificado como de concordância substancial, obteve valores bons, porém se comparados à primeira fase, foram inferiores.




Figura 5.12: Gráfico dos resultados obtidos nos testes do Cenário 01 - Grupo 02 da segunda fase.




Figura 5.13: Gráfico dos resultados obtidos nos testes do Cenário 01 - Grupo 03 da segunda fase.

5.4.2.3 Cenário 03

Os resultados obtidos da simulação do Cenário 03 são apresentadas nas Figuras 5.17 e 5.18:

O Cenário 03 apresentou bons índices no geral, com uma média de 0,78 e 0,79 para os dois testes, igualmente aos outros testes, mostrou-se inferior à primeira fase das simulações.

5.4.3 Comparação dos Resultados

Pela análise dos resultados, foi possível avaliar a rede neural de reconhecimento de objetos como um bom classificador, além de comprovar que a utilização da dimensão fractal é bastante relevante a este tipo de pesquisa, a Figura 5.19 mostra uma comparação dos




Figura 5.14: Gráfico dos resultados obtidos nos testes do Cenário 01 - Grupo 04 da segunda fase.




Figura 5.15: Gráfico dos resultados obtidos nos testes do Cenário 02 - Teste 01 da segunda fase.

valores do índice kappa obtido por todas os testes de ambas as fases.

Por meio da Figura 5.19, é fácil ver a diferença nas taxas de acerto da rede, mostrando que o uso da fractalidade do objeto foi um parâmetro importante no treinamento e validação da rede. Anteriormente foi dito a razão pela qual o uso do Índice Kappa é maior que a Taxa de Acerto Total, partindo dessa ideia, foi realizada uma outra análise dos resultados. Sendo o Índice Kappa superior em sua forma de avaliação, entende-se que quanto mais próximos os valores da Taxa de Acerto Total estão do Índice Kappa, pode-se afirmar que seus resultados são mais confiáveis daqueles que possuem uma maior diferença. Nesta avaliação verificou-se que essa diferença foi maior nos testes da segunda fase que na primeira, como mostra o gráfico da Figura 5.20.

Com isso, pode-se afirmar que o uso da dimensão fractal como parâmetro foi o diferencial nos resultados dos testes.




Figura 5.16: Gráfico dos resultados obtidos nos testes do Cenário 02 - Teste 02 da segunda fase.




Figura 5.17: Gráfico dos resultados obtidos nos testes do Cenário 03 - Teste 01 da segunda fase.




Figura 5.18: Gráfico dos resultados obtidos nos testes do Cenário 03 - Teste 02 da segunda fase.




Figura 5.19: Gráfico comparativo das Taxas de Índice Kappa das duas fases.




Figura 5.20: Gráfico comparativo da diferença entre a taxa de acerto total e o índice kappa das duas fases.

Considerações Finais

6.1 Conclusão

A partir da análise dos dados obtidos, pode-se concluir que a utilização da dimensão fractal no reconhecimento/classificação alcançou melhores resultados frente aos testes realizados sem a mesma, com uma média de acerto estimada em 79% contra 67%. O sistema provou que este tipo de pesquisa pode ser utilizado em ambientes diversos e que a dimensão fractal pareceu ser responsável por um significativo melhoramento. Há grandes possibilidades dos resultados serem ainda melhores se forem feitas reduções nos dados de entrada, bem como uma melhoria nos equipamentos de aquisição. Além disso, a pesquisa mostrou que o uso da geometria fractal é um fator que pode contribuir para uma melhor solução nas pesquisas, e que por meio de suas características específicas ajudou o sistema criado a obter uma convergência mais satisfatória dos resultados.

Como já foi dito anteriormente, o reconhecimento de objetos por meio de equipamentos robóticos autônomos é uma importante e difícil tarefa a ser desenvolvida, principalmente no que tange o conhecimento dos mesmos. Desde o momento de aquisição e pré-processamento de dados, é grande a exigência computacional dos equipamentos, porém, é no momento de reconhecimento e classificação em que tudo é posto em prova. Reconhecer e classificar objetos para humanos é uma tarefa trivial, mas para equipamentos robóticos, não. A primeira grande, e talvez principal, dificuldade é dar conhecimento a tais máquinas, tarefa esta, que ainda não foi satisfatoriamente resolvida. Porém, as pesquisas avançam a cada dia, e métodos são desenvolvidos para que máquinas façam tarefas específicas, utilizando seu “próprio” conhecimento.

O presente trabalho consistiu na elaboração de um modelo computacional para reconhecimento e classificação de objetos através de Redes Neurais Artificiais utilizando o conceito matemático de dimensão fractal. Para tal foi desenvolvido um aplicativo onde um grupo de imagens do objeto em estudo passam por um processamento antes de serem utilizadas no treinamento da rede, e posteriormente analisada para a classificação. Durante todo o processo, essas imagens passam por alterações em suas características sem perder sua identidade, em seguida, definindo-se a figura em escala de cinzas e o contorno da figura como entradas da rede. A dimensão fractal é obtida a partir do método box-counting, contando-se essencialmente o número de pixels ocupados pela borda e a quantidade total de pixels da imagem. A implementação do trabalho foi realizada através do software de programação em C++ Qt Creator, e para a manipulação das imagens utilizou-se o GIMP, ambos são softwares de licença livre.

6.2 *Atividades Futuras de Pesquisa*

Com o desenvolvimento do sistema, notou-se que as limitações da pesquisa giram em torno da dimensionalidade dos dados apresentados à rede. Objetivando uma redução nesses dados, e dando continuidade a pesquisa, pode-se utilizar os métodos PCA (Análise de Componentes Principais) para reduzir o número de entrada de dados e Algoritmos Genéticos para fazer a seleção dos melhores dados de entrada para a rede. Visto que a dimensão fractal proveu melhores resultados ao sistema, pretende-se continuar seu uso. Porém, realizando o cálculo da dimensão fractal através da imagem em escala de cinzas e utilizando a Dimensão Fractal Multi-escala, que ao contrário da realizada neste trabalho, apresenta mais de um parâmetro para análise. Para justificar o uso dos métodos apresentados, sugere-se a utilização de imagens 3D do objeto para a análise.

Algoritmo de Retropropagação de Erro

O Perceptron Multi-Camadas foi desenvolvido por causa da deficiência que as Redes Neurais de duas camadas possuíam. Este problema baseava-se na seguinte idéia: padrões de entrada similares resultavam em padrões de saídas similares. Esta restrição implica que a rede era incapaz de, mediante entradas com estruturas similares, gerar uma saída com estruturas diferentes, um exemplo clássico é o caso da função ou-exclusivo(XOR). Devido a esse impasse, (RUMELHART D. E.; HINTON, 1986) desenvolveram o modelo de Redes Neurais Multi-Camadas treinadas sob o algoritmo de Retropropagação de Erro (BackPropogation).

A.1 O Algoritmo

O algoritmo de retropropagação de erro é realizado em uma sequência de dois passos (CARVALHO, 2005):

1. Feed-Forward: Nesta etapa, o padrão é apresentado à camada de entrada, e os cálculos de pesos e saídas são realizados normalmente, até que a saída final seja produzida.
2. Feed-Backward: No segundo passo, a saída obtida é comparada com a saída desejada, estando diferente, o erro entre elas é calculado e propagado da camada de saída até a camada de entrada.

Esse algoritmo utiliza uma variação da Regra Delta apropriada para as Redes Neurais Multi-Camadas.

A.2 Os Passos do Algoritmo

Um esquema resumido do algoritmo de retropropagação de erro é apresentado a seguir (WINANDY, 2007):

1. Inicialização da Rede: Os pesos sinápticos e os “bias” são escolhidos aleatoriamente, no intervalo de $[0;1]$.

2. Dados de Entrada: Os exemplos de padrões de entrada são apresentados à rede.
3. Feed-Forward: Depois de apresentado o exemplo do conjunto de treinamento, o valor da ativação é calculado pela função A.1, neste caso função sigmóide:

$$f(v) = \frac{1}{1 + \exp(-\alpha v)} \quad (\text{A.1})$$

Onde,

$$v_j = \sum_{i=1}^m w_{ij}x_i + b \quad (\text{A.2})$$

Utilizando a saída dos neurônios de uma camada como os valores de entrada da camada seguinte. Este processo é repetidamente utilizando até que se alcance a última camada da rede, onde a saída final é calculada.

4. Cálculo do Sinal de Erro: Neste passo, é calculada a diferença entre a saída obtida da saída desejada, Equação A.3.

$$er_n = d_j(n) - O_j(n) \quad (\text{A.3})$$

Onde $d_j(n)$ é a saída desejada e $O_j(n)$ é a saída obtida. Caso a resposta obtida esteja fora dos parâmetros de parada da rede, este sinal de erro calculado será utilizado para computar os valores de erros das camadas anteriores, e fazer as correções necessárias nos pesos sinápticos.

5. Feed-Backward: Neste passo os erros locais são calculados baseados no sinal de erro obtido anteriormente. A camada de saída é a primeira a fazer a correção, e a partir dela o erro é repassado até a camada de entrada. Para a camada de saída é utilizada a Equação A.4 e para as demais camadas utiliza-se a Equação A.5:

$$\delta_j(n) = \exp(n) O_j(n) (1 - O_j(n)) \quad (\text{A.4})$$

$$\delta_j(n) = O_j(n) (1 - O_j(n)) \sum \delta_k w_{jk} \quad (\text{A.5})$$

Onde, O_j é a função de ativação; δ_k é o erro das unidades da camada anterior; w_{jk} são os pesos das conexões com a camada anterior.

Após o cálculo dos erros de cada unidade, calcula-se o ajuste dos pesos sinápticos de cada conexão conforme Equação A.6 e depois atualiza-se os pesos, Equação A.7:

$$\Delta w_{kj}(n+1) = \alpha w_{kj}(n) + \eta \delta_j y_j \quad (\text{A.6})$$

$$w_{n+1} = w_n + \Delta w_{kj}(n) \quad (\text{A.7})$$

Onde, α é a constante de momentum, que quando for igual a zero, a regra passa a funcionar como regra delta comum; η é a taxa de aprendizado; δ_j é o erro da unidade; y_j é a saída produzida pela unidade j .

6. Parâmetro de Parada: As condições de paradas do treinamento podem ser diversas, dentre as mais comuns podem-se citar: (1) a quantidade de épocas e (2) a baixa convergência da saída da rede. Enquanto essas condições não forem alcançadas, os passos 3, 4 e 5 continuam sendo realizados.

Resultados Totais

Os resultados serão apresentados em formas de tabelas, contendo todas as informações obtidas durante os testes.

B.1 Primeira Fase

Esta fase contém os resultados dos testes que utilizaram a dimensão fractal como parâmetro da rede.

B.1.1 Cenário 01

O objetivo deste Cenário era a classificação da imagem fornecida em normal ou defeituoso.

B.1.1.1 Cenário 01 - G01

Tabela B.1: Matriz Confusão G01 - Cenário 01.

Classes	Teste 01			Teste 02			Teste 03		
	Norm.	Def.	E.Co.	Norm.	Def.	E.Co.	Norm.	Def.	E.Co.
Normais	06	01	14,3%	09	00	0,0%	11	00	0,0%
Defeituosas	00	06	0,0%	02	06	25,0%	09	06	60,0%
E.Om.	0,0%	14,3%	-	18,2%	0,0%	-	45,0%	0,0%	-

Tabela B.2: Tabela de resultado dos parâmetros do G01 - Cenário 01.

Parâmetros	Teste 01	Teste 02	Teste 03
	Valor	Valor	Valor
Taxa de Acerto Total	92,3%	88,2%	65,38%
Sensitividade	87,5%	100,0%	100,0%
Especificidade	100,0%	75,0%	40,0%
Índice Kappa	0,92	0,88	0,65

B.1.1.2 Cenário 01 - G02

Tabela B.3: Matriz Confusão G02 - Cenário 01.

Classes	Teste 01			Teste 02			Teste 03		
	Norm.	Def.	E.Co.	Norm.	Def.	E.Co.	Norm.	Def.	E.Co.
Normais	05	00	0,0%	08	01	11,0%	12	01	8,0%
Defeituosas	01	07	13,0%	03	05	38,0%	08	05	62,0%
E.Om.	17,0%	0,0%	-	27,0%	17,0%	-	40,0%	17,0%	-

Tabela B.4: Tabela de resultado dos parâmetros do G02 - Cenário 01.

Parâmetros	Teste 01	Teste 02	Teste 03
	Valor	Valor	Valor
Taxa de Acerto Total	92,3%	76,5%	65,4%
Sensitividade	100,0%	88,4%	92,3%
Especificidade	87,5%	62,5%	38,5%
Índice Kappa	0,92	0,76	0,65

B.1.1.3 Cenário 01 - G03

Tabela B.5: Matriz Confusão G03 - Cenário 01.

Classes	Teste 01			Teste 02			Teste 03		
	Norm.	Def.	E.Co.	Norm.	Def.	E.Co.	Norm.	Def.	E.Co.
Normais	05	03	37,5%	06	01	14,3%	10	01	9,1%
Defeituosas	01	04	20,0%	05	05	50,0%	10	05	66,7%
E.Om.	16,7%	42,9%	-	45,5%	16,7%	-	50,0%	16,7%	-

Tabela B.6: Tabela de resultado dos parâmetros do G03 - Cenário 01.

Parâmetros	Teste 01	Teste 02	Teste 03
	Valor	Valor	Valor
Taxa de Acerto Total	69,2%	64,7%	57,7%
Sensitividade	62,5%	85,7%	90,9%
Especificidade	80,0%	50,0%	33,3%
Índice Kappa	0,68	0,63	0,56

B.1.1.4 Cenário 01 - G04

Tabela B.7: Matriz Confusão G04 - Cenário 01.

Classes	Teste 01			Teste 02			Teste 03		
	Norm.	Def.	E.Co.	Norm.	Def.	E.Co.	Norm.	Def.	E.Co.
Normais	06	02	25,0%	09	01	10,0%	15	00	0,0%
Defeituosas	00	05	0,0%	02	05	28,6%	05	06	45,6%
E.Om.	0,0%	28,6%	-	18,2%	16,7%	-	25,0%	0,0%	-

Tabela B.8: Tabela de resultado dos parâmetros do G04 - Cenário 01.

Parâmetros	Teste 01	Teste 02	Teste 03
	Valor	Valor	Valor
Taxa de Acerto Total	84,4%	82,4%	80,8%
Sensitividade	75,0%	90,0%	100,0%
Especificidade	100,0%	71,4%	54,5%
Índice Kappa	0,84	0,82	0,81

B.1.2 Cenário 02

O objetivo deste Cenário foi fazer com que o sistema indicasse a qual grupo a imagem pertencia.

Tabela B.9: Matriz Confusão do Cenário 02 - Testes 01 e 02.

Classes	Teste 01					Teste 02				
	G01	G02	G03	G04	E.Co.	G01	G02	G03	G04	E.Co.
G01	11	00	00	00	0,0%	12	01	00	00	7,7%
G02	01	10	02	02	33,3%	00	10	02	00	16,7%
G03	00	00	08	01	11,1%	00	01	09	01	18,2%
G04	00	02	02	09	30,8%	00	00	01	11	8,3%
E.Om.	8,3%	16,7%	33,3%	25,0%	-	0,0%	16,7%	25,0%	8,3%	-

Tabela B.10: Tabela de resultado dos parâmetros do Cenário 02 - Testes 01 e 02.

Parâmetros	Teste 01	Teste 02
	Valor	Valor
Taxa de Acerto Total	79,2%	87,5%
Sensitividade	81,0%	87,0%
Especificidade	92,2%	95,7%
Índice Kappa	0,79	0,87

B.1.3 Cenário 03

O objetivo deste Cenário mescla os dois anteriores, i.e., classificar a qual grupo pertence e dizer se o objeto é defeituoso ou não.

Tabela B.11: Matriz Confusão do Cenário 03 - Teste 01.

Classes	G01-N	G01-D	G02-N	G02-D	G03-N	G03-D	G04-N	G04-D	E.Co.
G01-N	19	00	00	02	00	00	00	00	9,5%
G01-D	00	08	00	00	00	01	00	00	11,1%
G02-N	03	00	20	00	02	00	02	00	25,9%
G02-D	00	01	00	07	00	02	00	00	30,0%
G03-N	00	00	02	00	16	00	01	00	15,8%
G03-D	00	00	00	00	00	06	00	01	14,3%
G04-N	00	00	00	00	04	00	19	00	17,4%
G04-D	00	00	00	00	00	00	00	08	0,0%
E.Om.	13,6%	11,1%	9,1%	22,2%	27,3%	33,3%	13,6%	11,1%	

Tabela B.12: Matriz Confusão da Cenário 03 - Teste 02.

Classes	G01-N	G01-D	G02-N	G02-D	G03-N	G03-D	G04-N	G04-D	E.Co.
G01-N	16	00	00	00	00	00	00	00	0,0%
G01-D	00	07	00	00	00	00	00	00	0,0%
G02-N	00	00	15	00	01	00	00	00	6,3%
G02-D	00	00	00	06	00	02	00	00	25,0%
G03-N	00	00	01	00	13	01	01	00	18,8%
G03-D	00	00	00	00	00	04	00	02	33,3%
G04-N	00	00	00	00	02	00	15	00	11,8%
G04-D	00	00	00	01	00	00	00	05	16,7%
E.Om.	0,0%	0,0%	6,3%	14,3%	18,8%	42,9%	6,3%	28,6%	

Tabela B.13: Tabela de resultado dos parâmetros da Cenário 03 - Testes 01 e 02..

Parâmetros	Teste 01	Teste 02
	Valor	Valor
Taxa de Acerto Total	83,1%	88,0%
Sensitividade	84,0%	86,0%
Especificidade	97,1%	98,1%
Índice Kappa	0,83	0,88

B.2 Segunda Fase

A segunda fase foi realizada sem a utilização da dimensão fractal como parâmetro, mas foi constituída dos mesmos cenários que a primeira fase, bem como os mesmos grupos de

imagens como entrada.

B.2.1 Cenário 01

B.2.1.1 Grupo G01

Tabela B.14: Matriz Confusão 2a. Fase - Cenário 01 - Classe G01.

Classes	Teste 01			Teste 02			Teste 03		
	Norm.	Def.	E.Co.	Norm.	Def.	E.Co.	Norm.	Def.	E.Co.
Normais	06	02	25,0%	07	00	0,0%	12	03	20,0%
Defeituosas	00	05	0,0%	04	06	40,0%	08	03	72,7%
E.Om.	0,0%	28,6%	-	36,4%	0,0%	-	40,0%	50,0%	-

Tabela B.15: Tabela de resultado dos parâmetros da 2a. Fase - Cenário 01 - Classe G01.

Parâmetros	Teste 01	Teste 02	Teste 03
	Valor	Valor	Valor
Taxa de Acerto Total	84,6%	76,5%	57,7%
Sensitividade	75,0%	100,0%	80,0%
Especificidade	100,0%	60,0%	27,3%
Índice Kappa	0,85	0,76	0,54

B.2.1.2 Grupo G02

Tabela B.16: Matriz Confusão 2a. Fase - Cenário 01 - Classe G02.

Classes	Teste 01			Teste 02			Teste 03		
	Norm.	Def.	E.Co.	Norm.	Def.	E.Co.	Norm.	Def.	E.Co.
Normais	05	02	28,6%	06	02	25,0%	12	04	25,0%
Defeituosas	01	05	16,7%	05	04	55,6 %	08	02	80,0%
E.Om.	16,7%	28,6%	-	45,5%	33,3%	-	40,0%	66,7%	-

Tabela B.17: Tabela de resultado dos parâmetros do 2a. Fase - Cenário 01 - Classe G02.

Parâmetros	Teste 01	Teste 02	Teste 03
	Valor	Valor	Valor
Taxa de Acerto Total	76,9%	58,8%	53,8%
Sensitividade	71,4%	75,0%	75,0%
Especificidade	83,3%	44,4%	20,0%
Índice Kappa	0,76	0,56	0,49

B.2.1.3 Grupo G03

Tabela B.18: Matriz Confusão 2a. Fase - Cenário 01 - Classe G03.

Classes	Teste 01			Teste 02			Teste 03		
	Norm.	Def.	E.Co.	Norm.	Def.	E.Co.	Norm.	Def.	E.Co.
Normais	03	03	50,0%	05	02	28,6%	09	02	18,2%
Defeituosas	03	04	42,9%	06	04	60,0%	11	04	73,3%
E.Om.	50,0%	42,9%	-	54,5%	33,3%	-	55,0%	33,3%	-

Tabela B.19: Tabela de resultado dos parâmetros do 2a. Fase - Cenário 01 - Classe G03.

Parâmetros	Teste 01	Teste 02	Teste 03
	Valor	Valor	Valor
Taxa de Acerto Total	53,8%	52,9%	50,0%
Sensitividade	57,1%	71,4%	81,8%
Especificidade	50,0%	40,0%	26,7%
Índice Kappa	0,48	0,49	0,47

B.2.1.4 Grupo G04

Tabela B.20: Matriz Confusão 2a. Fase - Cenário 01 - Classe G04.

Classes	Teste 01			Teste 02			Teste 03		
	Norm.	Def.	E.Co.	Norm.	Def.	E.Co.	Norm.	Def.	E.Co.
Normais	05	02	28,6%	07	00	0,0%	14	03	17,6%
Defeituosas	01	05	16,7%	04	06	40,0%	06	03	66,7%
E.Om.	16,7%	28,6%	-	36,4%	0,0%	-	30,0%	50,0%	-

Tabela B.21: Tabela de resultado dos parâmetros do 2a. Fase - Cenário 01 - Classe G04.

Parâmetros	Teste 01	Teste 02	Teste 03
	Valor	Valor	Valor
Taxa de Acerto Total	76,9%	76,5%	65,4%
Sensitividade	71,4%	100,0%	82,4%
Especificidade	83,3%	60,0%	33,3%
Índice Kappa	0,76	0,76	0,63

B.2.2 Cenário 02

Tabela B.22: Matriz Confusão do Cenário 02 - Testes 01 e 02.

Classes	Teste 01					Teste 02				
	G01	G02	G03	G04	E.Co.	G01	G02	G03	G04	E.Co.
G01	09	01	03	00	30,8%	11	02	00	00	15,4%
G02	02	10	01	00	23,1%	01	09	01	00	18,2%
G03	00	00	07	03	30,0%	00	00	07	03	30,0%
G04	01	01	01	09	25,0%	00	01	04	09	35,7%
E.Om.	25,0%	16,7%	41,7%	25,0%	-	8,3%	25,0%	41,7%	25,0%	-

Tabela B.23: Tabela de resultado dos parâmetros do Cenário 02 - Testes 01 e 02.

Parâmetros	Teste 01	Teste 02
	Valor	Valor
Taxa de Acerto Total	72,9%	75,0%
Sensitividade	73,0%	75,0%
Especificidade	89,2%	90,4%
Índice Kappa	0,72	0,75

B.2.3 Cenário 03

Tabela B.24: Matriz Confusão da Simulação 03 - Teste 01.

Classes	G01-N	G01-D	G02-N	G02-D	G03-N	G03-D	G04-N	G04-D	E.Co.
G01-N	19	01	00	02	00	00	00	00	13,6%
G01-D	01	07	00	00	00	00	00	00	12,5%
G02-N	00	01	19	00	01	02	00	00	17,4%
G02-D	00	00	00	06	02	02	00	00	40,0%
G03-N	01	00	03	00	16	00	02	02	33,3%
G03-D	00	00	00	00	00	05	00	02	28,6%
G04-N	01	00	00	00	03	00	20	00	16,7%
G04-D	00	00	00	01	00	00	00	05	16,7%
E.Om.	13,6%	22,2%	13,6%	33,3%	27,3%	44,4%	9,1%	44,4%	

Tabela B.25: Matriz Confusão da Simulação 03 - Teste 02.

Classes	G01-N	G01-D	G02-N	G02-D	G03-N	G03-D	G04-N	G04-D	E.Co.
G01-N	14	01	00	00	00	00	00	00	6,7%
G01-D	01	06	00	00	02	00	00	00	33,3%
G02-N	01	00	15	02	00	00	00	00	16,7%
G02-D	00	00	00	05	00	00	00	00	0,0%
G03-N	00	00	00	00	12	02	02	00	25,0%
G03-D	00	00	00	00	00	03	00	01	25,0%
G04-N	00	00	01	00	02	00	13	01	23,5%
G04-D	00	00	00	00	00	02	01	05	37,5%
E.Om.	12,5%	14,3%	6,3%	28,6%	25,0%	57,1%	18,8%	28,6%	

Tabela B.26: Tabela de resultado dos parâmetros do Cenário 03 - Testes 01 e 02..

Parâmetros	Teste 01	Teste 02
	Valor	Valor
Taxa de Acerto Total	78,2%	79,3%
Sensitividade	78,0%	79,0%
Especificidade	96,2%	96,4%
Índice Kappa	0,78	0,79

Referências Bibliográficas

- ABELEM, A. J. G. *Redes Neurais Artificiais na Previsão de Séries Temporais*. Dissertação (Mestrado) — Pontifícia Universidade Católica do Rio de Janeiro, 1994.
- ASSIS, T. A. d. Geometria fractal: propriedades e características de fractais ideais. *Revista Brasileira de Ensino de Física*, v. 30, p. 1–10, 2008.
- AZEVEDO T. S.; MARQUES, M. L. As propriedades fractais da representação cartográfica de linhas: Um estudo de caso para o litoral do estado de são paulo - brasil. *GEOUSP - Espaço e Tempo*, v. 15, p. 51–61, 2004.
- BACKES, A. R. *Implementação e Comparação de métodos de estimativa da Dimensão Fractal e sua aplicação à análise e Processamento de Imagens*. Dissertação (Mestrado) — Instituto de Ciências Matemáticas e de Computação, USP, 2006.
- BANON, G. J. F. *Formal Introduction to digital image processing*. [S.l.], 2000.
- BARRETO, C. C. *Fractais: Pra que serve?* [S.l.], 2001.
- BAYER, F. M. *Desenvolvimento e Implementação de uma Interface de Comunicação para Controlador Robótico Industrial*. Dissertação (Mestrado) — Programa de Pós-Graduação em Engenharia Mecânica, Universidade Federal do Rio Grande do Sul, 2004.
- BILOBROVEC M; MARCAL, R. F. M. P. L. A. Aplicações de redes neurais artificiais em simulações. *XI Simbep*, v. 1, p. 60–67, 2004.
- BITTENCOURT, C. D. R. *Classificação Automática do Acabamento de Gordura em Imagens Digitais de Carcaças Bovinas*. Dissertação (Mestrado) — Instituto de Ciências Exatas, Universidade de Brasília, 2009.
- BITTENCOURT J R; OSORIO, F. S. *O Uso de Redes Neurais Artificiais no Processamento de Imagens Inteligente*. [S.l.], 2002.
- BOGGIONE, G. d. A. *Restauração de Imagens do Satélite LandSat-7*. Dissertação (Mestrado) — Ministério da Ciência e Tecnologia, Instituto Nacional de Pesquisas Espaciais, 2004.
- BRITO S. F.; CARVALHO, J. M. *Sistemas de Processamento Digital de Imagens para fins Didáticos/Científicos: Estudo, seleção e implementação de algoritmos de segmentação*. Agosto 1998.
- CARVALHO, A. A. d. C. *Fundamentação Teórica para Processamento Digital de Imagens*. [S.l.], 2003.

- CARVALHO, A. P. d. L. F. *Artificial Neural Networks*. [S.l.], 2005.
- CASTRO, A. P. A. d. *Restauração de Imagens por Operadores Modelados por Redes Neurais Artificiais*. Tese (Doutorado) — Ministério da Ciência e Tecnologia, Instituto Nacional de Pesquisas Espaciais, 2009.
- CERA, M. C. *Uso de Redes Neurais para o Reconhecimento de Padrões*. [S.l.], 2005.
- CHAGAS C. S.; VIEIRA, C. A. O. F. E. I. F. J. W. d. C. Utilização de redes neurais artificiais na classificação de níveis de degradação em pastagens. *Revista Brasileira de Engenharia Agrícola e Ambiental*, v. 13, p. 319–327, 2009.
- CONGALTON, R. A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, v. 37, p. 35–46, 1991.
- CRUZ ELEANDRO S.; CARVALHO, D. F. V. C. A. A. S. L. D. B. S. W. J. P. F. A. C. Comparação de classificadores de imagens digitais na determinação da cobertura do solo. *Engenharia Agrícola*, v. 28, p. 237–244, 2008.
- DESTEC. *Desenho Técnico Instrumental*. [S.l.], 2011.
- DINIZ, G. A matemática do cancer. *Ciência Hoje*, v. 232, p. 80, 2006.
- FALCAO ALEXANDRE X; LEITE, N. J. *Tópicos em Processamento de Imagens*. August 2003.
- FERNANDES, J. A. *Fractais: Uma nova visão da matemática*. [S.l.], 2007. v. 1, 32 p.
- FIGUEREDO, R. d. C. *Um estudo de algoritmos de Processamento de Imagem e Reconhecimento de Padrão em Imagem Digital capturada em ambiente aberto*. Dissertação (Mestrado) — Universidade Federal da Bahia, 2007.
- FORESTI RENAN L; LORINI, F. J. *Sistema de Visão Robótica para Reconhecimento de Contornos de Componentes na Aplicação de Processos Industriais*. [S.l.], 2005.
- GALO, M. d. L. B. T. *Aplicação de Redes Neurais Artificiais e Sensoriamento Remoto na Caracterização Ambiental do Parque Estadual Morro do Diabo*. Tese (Doutorado) — Escola de Engenharia de São Carlos - USP, 2000.
- GONZALEZ RAFAEL C.; WOODS, R. E. *Digital Image Processing*. [S.l.]: Tom Robbins, 2002.
- GRILL-SPECTOR K.; KANWISHER, N. Visual recognition: as soon as you know it is there, you know what it is. *Psychological Science*, v. 16, p. 152–160, 2005.
- GUANDALINI, G. S. *Morfometria e Geometria Fractal: Imageamento Fractal como descritor de agressividade nas displasias epiteliais orais*. [S.l.], 2006.
- HAYKIN, S. *Neural Networks: A Comprehensive Foundation*. [S.l.]: Prentice Hall, 1998.

- HEBB, D. *Organization of Behavior*. [S.l.], 1949.
- HOGENDOORN, H. *The State of the Art in Visual Object Recognition*. 2006.
- JAIN A. K.; DUIN, R. Statistical pattern recognition: A review. *IEEE Transactions On Pattern Analysis and Machine intelligence*, v. 22, p. 4–37, 2000.
- LIMA FABIANO G; PERERA, L. C. J. K. H. F. A. C. S. Aplicação de redes neurais na análise e na concessão de crédito ao consumidor. *R.Adm*, v. 44, p. 34–45, 2009.
- MACHADO, D. S. *Reconhecimento de Objetos de Formas Variadas*. [S.l.], 2008.
- MACHADO Kássio L.; RIBEIRO, D. R. P. L. A. C. O. A. S. M. K. A. J. F. *Rede Neural Artificial embarcada em Robótica Móvel*. [S.l.], 2009.
- MACIEL L S.; BALLINI, R. Redes neurais para previsão de séries financeiras. *Anais do XVI Congresso Interno da Unicamp*, v. 1, p. 231, 2008.
- MASCARENHAS N. A.; VELASCO, F. R. D. *Processamento Digital de Imagens*. [S.l.], 1989.
- MASSON, E. W. Y. *Introduction to Computation and Learning in Artificial Neural Networks*. [S.l.], 1990.
- MEDEIROS, L. F. *Redes Neurais em Delphi*. [S.l.]: Visual Book Editora, 2003.
- MORAES, E. C. *Reconhecimento de Padrões e Redes Neuras Artificiais em predição de estruturas secundárias de proteínas*. Tese (Doutorado) — COPPE/UFRJ, 2010.
- NEVES, M. V. *Uma (Breve) Introdução às Redes Neurais Artificiais*. [S.l.], 2006.
- NOGUEIRA A.; AZEVEDO, J. B. V. S. S. *Um Overview sobre Reconhecimento de Padrões*. [S.l.], 2006.
- NYGREN, K. *Stock Prediction - A Neural Network Approach*. March 2004.
- OLIVEIRA, A. J. *Análise estatística de Índices Morfométricos e Dimensão Fractal da Vascularização da Retina Humana*. Dissertação (Mestrado) — UFRPE, 2006.
- PAVIM X A.; ROLOFF, M. L. *Curso de Processamento e Análise de Imagens*. [S.l.], 2005.
- PEREIRA RAFAEL M.; WU, F. C. M. R. B. L. H. D. D. S. F. J. J. G. J. R. N. Um subsistema de processamento de imagens digitais para a extração de atributos em gráficos de experimentos médicos. *Anais do I WorkComp-SUL*, v. 1, p. 33–43, 2004.
- RAUBER, T. W. *Redes Neurais Artificiais*. [S.l.], 1997.
- REIS CAIMI F; ALBUQUERQUE, M. P. C. S. B. *Introdução ao Reconhecimento de Padrões utilizando Redes Neurais*. [S.l.], 2001.

- ROCHA EDROALDO L. DA; NICOLEIT, E. R. M. M. C. d. S. P. W. T. d. A. M. S. A. *Diagnóstico Automatizado de doenças no Colo do Útero baseado em Redes Neurais Artificiais e Processamento de Imagens Digitais*. [S.l.], 2007.
- RODRIGUES P S.; ARAUJO, A. d. A. Um algoritmo para reconhecimento de objetos baseado em regiões. *Anais do III Workshop em Tratamento de Imagens - UFMG*, v. 1, p. 72–80, 2002.
- ROSARIO, J. M. *Princípios de Mecatrônica*. [S.l.]: Pearson Brasil, 2005.
- RUMELHART D. E.; HINTON, G. E. W. R. J. *Parallel Distributed Processing: Explorations in the Microstructure of Cognition I*. [S.l.]: MIT Press, 1986. Chapter: Learning internal representations by error propagation, pp. 318-362.
- SENAI. *Telecurso 2000 - Elementos de Fixação*. [S.l.], 2008.
- SOUZA, J. A. d. *Reconhecimento de Padrões usando Indexação Recursiva*. Tese (Doutorado) — Departamento de Engenharia de Produção e Sistemas, Universidade Federal de Santa Catarina, 1999.
- TORRES RUBIAO G.; MACHADO, M. A. S. S. R. C. Previsão de séries temporais de falhas em manutenção industrial usando redes neurais. *Engevista*, v. 7, p. 4–18, 2005.
- WASSERMAN, P. D. *Neural Computing: Theory and Practice*. [S.l.]: Van Nostrand Reinhold, 1989.
- WIDROW B.; HOFF, M. E. *Adaptive switching circuits*. [S.l.], 1960.
- WINANDY, C.-E. *Algoritmos para Aprendizagem Supervisionada*. [S.l.], 2007.
- ZHANG, G. P. Neural networks for classification: A survey. *IEEE Transactions on Systems, Man, and Cybernetics - Part C: Applications and Reviews*, v. 30, p. 451–462, 2000.

Reconhecimento de Objetos utilizando Redes Neurais Artificiais e Geometria Fractal

Cândido Regis de Brito Bisneto

Salvador, Maio de 2011.