

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
DEPARTAMENTO ACADÊMICO DE INFORMÁTICA
CURSO SUPERIOR DE BACHARELADO EM SISTEMAS DE
INFORMAÇÃO

JOÃO PAULO DE OLIVEIRA COSTA
LUCAS DISSENHA ORTOLAN

**CLASSIFICAÇÃO DE IMAGENS DE SENSORIAMENTO REMOTO
UTILIZANDO REDES NEURAS ARTIFICIAIS**

TRABALHO DE CONCLUSÃO DE CURSO

CURITIBA

2014

JOÃO PAULO DE OLIVEIRA COSTA
LUCAS DISSENHA ORTOLAN

**CLASSIFICAÇÃO DE IMAGENS DE SENSORIAMENTO REMOTO
UTILIZANDO REDES NEURAS ARTIFICIAIS**

Trabalho de Conclusão de Curso apresentado ao Departamento Acadêmico de Informática como requisito parcial para obtenção do grau de Bacharel no Curso Superior de Bacharelado em Sistemas de Informação da Universidade Tecnológica Federal do Paraná.

Orientadora: Prof. Dra. Leyza Baldo Dorini

CURITIBA

2014

AGRADECIMENTOS

À Deus, que nos deu força e coragem durante toda esta longa caminhada. Às nossas famílias e amigos, pelo incentivo e pelo apoio constantes, e à professora Leyza, pela paciência na orientação e incentivo que tornaram possível a conclusão desta monografia.

RESUMO

COSTA, João Paulo de Oliveira e ORTOLAN, Lucas Dissenha. Classificação de Imagens de Sensoriamento Remoto Utilizando Redes Neurais Artificiais. 78 f. Trabalho de Conclusão de Curso – Curso Superior de Bacharelado em Sistemas de Informação, Universidade Tecnológica Federal do Paraná. Curitiba, 2014.

As imagens produzidas a partir do sensoriamento remoto geralmente são analisadas por especialistas para extração de informações usadas para análise de dados ou tomada de decisões. Este processo pode ser auxiliado por meio de um procedimento automático de classificação, de tal forma que uma imagem temática seja produzida, enfatizando características e/ou regiões de interesse. O presente trabalho tem como objetivo desenvolver uma metodologia baseada em Redes Neurais Artificiais (RNAs) para reconhecimento de padrões em imagens de sensoriamento remoto em dois cenários distintos. O primeiro refere-se à imagens de satélite da região de Três Pontas, localizada ao Sul de Minas Gerais, onde a cultura cafeeira encontra-se presente. Neste caso, o objetivo é identificar automaticamente zonas produtoras de café, diferenciando-a de regiões de mata e de outros usos. O segundo cenário é composto por imagens da região da Baía de Paranaguá referentes à duas datas de aquisição distintas, 1986 e 1999. Este trabalho tem como objetivo delimitar as regiões correspondentes à zonas urbanas. Dessa forma, é possível determinar diferentes itens, incluindo invasão de zonas de preservação e crescimento urbano. A precisão da classificação foi avaliada com base no índice Kappa, que fornece uma ideia da acurácia da classificação. O melhor índice obtido no primeiro cenário foi de 0.81 e no segundo de 0.80, ambos considerados bons. Alguns dos erros da abordagem proposta podem ser minimizados ao considerar diferentes descritores e operações de pré-processamento, o que pode incentivar o desenvolvimento de trabalhos futuros.

Palavras-chave: Sensoriamento Remoto, Redes Neurais Artificiais, Classificação

LISTA DE FIGURAS

FIGURA 1 – PROCESSO DE OBTENÇÃO DAS IMAGENS DE SENSORIAMENTO REMOTO UTILIZANDO SATÉLITES ARTIFICIAIS.	16
FIGURA 2 – CURVA ESPECTRAL.	16
FIGURA 3 – COMPORTAMENTO DA REFLECTÂNCIA DOS RAIOS CONDICIONADO ÀS ELEVAÇÕES VERTICAIS DA SUPERFÍCIE DO OBJETO: (A) SUPERFÍCIE LISA E (B) SUPERFÍCIE DIFUSORA.	17
FIGURA 4 – ELEMENTOS QUE CONSTITUEM UMA IMAGEM DIGITAL.	18
FIGURA 5 – REPRESENTAÇÃO DE IMAGEM BINÁRIA.	19
FIGURA 6 – REPRESENTAÇÃO DE IMAGEM DE NÍVEIS DE CINZA.	19
FIGURA 7 – REPRESENTAÇÃO DE IMAGEM COLORIDA.	20
FIGURA 8 – MODELO PARA RECONHECIMENTO DE PADRÕES.	22
FIGURA 9 – MODELO DE NEURÔNIO ARTIFICIAL.	24
FIGURA 10 – IMAGENS TM/LANDSAT 5, BANDAS 3, 4 E 5 DO CENÁRIO01 - REGIÃO DE TRÊS PONTAS.	31
FIGURA 11 – IMAGENS TM/LANDSAT 5, BANDAS 3, 4 E 5 DO CENÁRIO01 - REGIÃO DE TRÊS PONTAS - COM MÁSCARA DE DRENAGEM.	32
FIGURA 12 – IMAGENS TM/LANDSAT 7, BANDAS 1, 2, 3, 4 E 5 DO CENÁRIO02 - REGIÃO DA BAÍA DE PARANAGUÁ - AQUISIÇÃO EM 14/09/1986.	33
FIGURA 13 – IMAGENS TM/LANDSAT 7, BANDAS 1, 2, 3, 4 E 5 DO CENÁRIO02 - REGIÃO DA BAÍA DE PARANAGUÁ - AQUISIÇÃO EM 26/09/1999.	34
FIGURA 14 – IMAGEM DE REFERÊNCIA DO CENÁRIO01 - REGIÃO DE TRÊS PONTAS.	35
FIGURA 15 – SUB-IMAGENS UTILIZADAS PARA A ESCOLHA DA MELHOR CONFIGURAÇÃO DE RNA NO CENÁRIO01: (A) BANDA 3, (B) BANDA 4, (C) BANDA 5 E (D) MÁSCARA DE REFERÊNCIA.	36
FIGURA 16 – IMAGEM DE REFERÊNCIA DO CENÁRIO02 - BAÍA DE PARANAGUÁ, PARANÁ.	36
FIGURA 17 – SUB-IMAGENS UTILIZADAS PARA A DETERMINAÇÃO DA MELHOR CONFIGURAÇÃO DE RNA NO CENÁRIO02 - PASSAGEM DE 1986: (A) BANDA 1, (B) BANDA 2, (C) BANDA 3, (D) BANDA 4 E (E) BANDA 5.	37
FIGURA 18 – SUB-IMAGENS UTILIZADAS PARA A DETERMINAÇÃO DA MELHOR CONFIGURAÇÃO DE RNA NO CENÁRIO02 - PASSAGEM DE 1999: (A) BANDA 1, (B) BANDA 2, (C) BANDA 3, (D) BANDA 4 E (E) BANDA 5.	38

FIGURA 19 – MÁSCARAS UTILIZADAS NO CENÁRIO02 PARA EXTRAÇÃO DE DESCRITORES DE (A) REGIÕES URBANAS E (B) REGIÕES NÃO-URBANAS. FONTE: AUTORIA PRÓPRIA.	38
FIGURA 20 – DELIMITAÇÃO DAS REGIÕES DE TREINAMENTO E TESTE (EXEMPLO PARA A BANDA 3 DO CENÁRIO01).	41
FIGURA 21 – VALIDAÇÃO DOS TESTES PARA ESCOLHA DA CONFIGURAÇÃO DE RNA DO CENÁRIO02 (SUB-IMAGENS 720× 720): (A) IMAGEM ORIGINAL E (B) IMAGEM REFERÊNCIA (B) REPRESENTA REGIÕES URBANAS).	42
FIGURA 22 – RESULTADO DE CLASSIFICAÇÃO PARA A REGIÃO DE TESTE COMPLETA DO CENÁRIO01 UTILIZANDO COMO DESCRITORES OS NÍVEIS DE CINZA E A CONFIGURAÇÃO DE RNA 12: (A) IMAGEM CLASSIFICADA PELA RNA (BRANCO REPRESENTA A CLASSE CAFÉ) E (B) REGIÕES ONDE OCORRERAM OS ERROS DE CLASSIFICAÇÃO.	46
FIGURA 23 – RESULTADO DE CLASSIFICAÇÃO PARA A REGIÃO DE TESTE COMPLETA DO CENÁRIO01 UTILIZANDO COMO DESCRITOR A MÉDIA DOS NÍVEIS DE CINZA E A CONFIGURAÇÃO DE RNA 13: (A) IMAGEM CLASSIFICADA PELA RNA (BRANCO REPRESENTA A CLASSE CAFÉ) E (B) REGIÕES ONDE OCORRERAM OS ERROS DE CLASSIFICAÇÃO.	48
FIGURA 24 – RESULTADO DE CLASSIFICAÇÃO PARA A REGIÃO DE TESTE COMPLETA DO CENÁRIO01 UTILIZANDO COMO DESCRITORES A MÉDIA E O DESVIO PADRÃO DOS NÍVEIS DE CINZA E A CONFIGURAÇÃO DE RNA 12: (A) IMAGEM CLASSIFICADA PELA RNA (BRANCO REPRESENTA A CLASSE CAFÉ) E (B) REGIÕES ONDE OCORRERAM OS ERROS DE CLASSIFICAÇÃO.	50
FIGURA 25 – RESULTADO DE CLASSIFICAÇÃO PARA A REGIÃO DE TESTE COMPLETA DO CENÁRIO01 UTILIZANDO COMO DESCRITOR O VALOR DE REFLECTÂNCIA E A CONFIGURAÇÃO DE RNA 14: (A) IMAGEM CLASSIFICADA PELA RNA (BRANCO REPRESENTA A CLASSE CAFÉ) E (B) REGIÕES ONDE OCORRERAM OS ERROS DE CLASSIFICAÇÃO.	52
FIGURA 26 – RESULTADO DE CLASSIFICAÇÃO PARA A REGIÃO DE TESTE COMPLETA DO CENÁRIO01 UTILIZANDO COMO DESCRITOR A MÉDIA DO VALOR DE REFLECTÂNCIA E A CONFIGURAÇÃO DE RNA 15: (A) IMAGEM CLASSIFICADA PELA RNA (BRANCO REPRESENTA A	

	CLASSE CAFÉ) E (B) REGIÕES ONDE OCORRERAM OS ERROS DE CLASSIFICAÇÃO.	54
FIGURA 27	– RESULTADO DE CLASSIFICAÇÃO PARA A REGIÃO DE TESTE COMPLETA DO CENÁRIO01 UTILIZANDO COMO DESCRITORES A MÉDIA E O DESVIO PADRÃO DO VALOR DE REFLECTÂNCIA E A CONFIGURAÇÃO DE RNA 8: (A) IMAGEM CLASSIFICADA PELA RNA (BRANCO REPRESENTA A CLASSE CAFÉ) E (B) REGIÕES ONDE OCORRERAM OS ERROS DE CLASSIFICAÇÃO.	56
FIGURA 28	– RESULTADOS DE CLASSIFICAÇÃO PARA AS DIFERENTES COMBINAÇÕES DE BANDA - 1986.	61
FIGURA 29	– ERROS DE CLASSIFICAÇÃO PARA AS DIFERENTES COMBINAÇÕES DE BANDA - 1986.	62
FIGURA 30	– RESULTADOS DE CLASSIFICAÇÃO PARA AS DIFERENTES COMBINAÇÕES DE BANDA - 1999.	63
FIGURA 31	– ERROS DE CLASSIFICAÇÃO PARA AS DIFERENTES COMBINAÇÕES DE BANDA - 1999.	64
FIGURA 32	– CLASSIFICAÇÃO DA IMAGEM COMPLETA CONSIDERANDO A CONFIGURAÇÃO COM MELHOR DESEMPENHO (A) 1986 E (B) 1999. .	73

LISTA DE TABELAS

TABELA 1	– BANDAS ESPECTRAIS DO SENSOR TM.	15
TABELA 2	– CONFIGURAÇÕES DAS RNAS UTILIZADAS PARA A REALIZAÇÃO DOS TESTES NAS IMAGENS.	41
TABELA 3	– MATRIZ DE CONFUSÃO.	43
TABELA 4	– QUALIFICAÇÃO DO ÍNDICE KAPPA A PARTIR DE SEU VALOR.	43
TABELA 5	– CONFIGURAÇÕES PADRÃO DE TODAS AS ARQUITETURAS DE RNA TESTADAS NO CENÁRIO01.	44
TABELA 6	– RESULTADOS PARA CADA RNA - TESTES REALIZADOS COM AS SUB-IMAGENS 200×200 DO CENÁRIO01 UTILIZANDO OS NÍVEIS DE CINZA COMO DESCRITORES.	45
TABELA 7	– RESULTADOS PARA CADA RNA - TESTES REALIZADOS COM AS SUB-IMAGENS 200×200 DO CENÁRIO01 UTILIZANDO A MÉDIA DOS NÍVEIS DE CINZA COMO DESCRITOR.	47
TABELA 8	– RESULTADOS PARA CADA RNA - TESTES REALIZADOS COM AS SUB-IMAGENS 200×200 DO CENÁRIO01 UTILIZANDO A MÉDIA E O DESVIO-PADRÃO DOS NÍVEIS DE CINZA COMO DESCRITOR.	49
TABELA 9	– RESULTADOS PARA CADA RNA - TESTES REALIZADOS COM AS SUB-IMAGENS 200×200 DO CENÁRIO01 UTILIZANDO OS VALORES DE REFLECTÂNCIA COMO DESCRITOR.	51
TABELA 10	– RESULTADOS PARA CADA RNA - TESTES REALIZADOS COM AS SUB-IMAGENS 200×200 DO CENÁRIO01 UTILIZANDO A MÉDIA DOS NÍVEIS DE REFLECTÂNCIA COMO DESCRITOR.	53
TABELA 11	– RESULTADOS PARA CADA RNA - TESTES REALIZADOS COM AS SUB-IMAGENS 200×200 DO CENÁRIO01 UTILIZANDO A MÉDIA E O DESVIO-PADRÃO DOS NÍVEIS DE REFLECTÂNCIA COMO DESCRITOR.	55
TABELA 12	– MELHORES DESEMPENHOS DAS RNAS NO PROCESSO DE CLASSIFICAÇÃO PARA O CENÁRIO01 EM CADA UMA DAS ABORDAGENS PARA AS IMAGENS 200×200.	57
TABELA 13	– MELHORES DESEMPENHOS DAS RNAS NO PROCESSO DE CLASSIFICAÇÃO PARA O CENÁRIO01 EM CADA UMA DAS ABORDAGENS PARA AS IMAGENS ORIGINAIS (COMPLETAS).	57
TABELA 14	– CONFIGURAÇÕES PADRÃO DE TODAS AS ARQUITETURAS DE	

RNA TESTADAS NO CENÁRIO 1.	59
TABELA 15 – DESEMPENHO DA CLASSIFICAÇÃO DA RNA UTILIZANDO DIFERENTES BANDAS DO REGISTRO DE 1986.	60
TABELA 16 – DESEMPENHO DA CLASSIFICAÇÃO DA RNA UTILIZANDO DIFERENTES BANDAS DO REGISTRO DE 1999.	60
TABELA 17 – RESULTADOS PARA CADA RNA - TESTES REALIZADOS COM AS IMAGENS 720×720 DAS ZONAS URBANAS UTILIZANDO OS NÍVEIS DE CINZA COMO DESCRITORES.	65
TABELA 18 – RESULTADOS PARA CADA RNA - TESTES REALIZADOS COM AS IMAGENS 720×720 DAS ZONAS URBANAS UTILIZANDO A MÉDIA DOS NÍVEIS DE CINZA COMO DESCRITORES.	66
TABELA 19 – RESULTADOS PARA CADA RNA - TESTES REALIZADOS COM AS IMAGENS 720×720 DAS ZONAS URBANAS UTILIZANDO A MÉDIA E O DESVIO PADRÃO DOS NÍVEIS DE CINZA COMO DESCRITORES.	67
TABELA 20 – RESULTADOS PARA CADA RNA - TESTES REALIZADOS COM AS IMAGENS 720×720 DAS ZONAS URBANAS UTILIZANDO OS VALORES DE REFLECTÂNCIA COMO DESCRITORES.	68
TABELA 21 – RESULTADOS PARA CADA RNA - TESTES REALIZADOS COM AS IMAGENS 720×720 DAS ZONAS URBANAS UTILIZANDO A MÉDIA DOS VALORES DE REFLECTÂNCIA COMO DESCRITORES. .	69
TABELA 22 – RESULTADOS PARA CADA RNA - TESTES REALIZADOS COM AS IMAGENS 720×720 DAS ZONAS URBANAS UTILIZANDO A MÉDIA E O DESVIO PADRÃO DOS VALORES DE REFLECTÂNCIA COMO DESCRITORES.	70
TABELA 23 – MELHORES DESEMPENHOS DAS RNAS NO PROCESSO DE CLASSIFICAÇÃO DAS CENAS URBANAS EM CADA UMA DAS ABORDAGENS PARA AS IMAGENS 720×720 DE 1986.	71
TABELA 24 – MELHORES DESEMPENHOS DAS RNAS NO PROCESSO DE CLASSIFICAÇÃO DAS CENAS URBANAS EM CADA UMA DAS ABORDAGENS PARA AS IMAGENS 720×720 DE 1999.	71

SUMÁRIO

1	INTRODUÇÃO	9
1.1	ESTRUTURA DO TRABALHO	11
2	FUNDAMENTAÇÃO TEÓRICA	13
2.1	SENSORIAMENTO REMOTO	13
2.1.1	Sensor orbital Landsat TM 5	14
2.1.2	Textura e reflectância na obtenção de imagens	15
2.2	PROCESSAMENTO DIGITAL DE IMAGENS	17
2.3	CLASSIFICAÇÃO DE IMAGENS	20
2.3.1	Redes Neurais	23
2.4	RECONHECIMENTO DE PADRÕES EM IMAGENS DE SATÉLITE	26
2.4.1	Detecção de Regiões Urbanas em Imagens de Satélite	26
2.4.2	Detecção de Áreas Cafeeiras em Imagens de Satélite	27
3	METODOLOGIA	29
3.1	IMAGENS UTILIZADAS	29
3.2	EXTRAÇÃO DOS DESCRITORES DAS IMAGENS	35
3.2.1	Descritores baseados nos níveis de cinza - Abordagens 01, 02 e 03	39
3.2.2	Descritores baseados nos valores de reflectância - Abordagens 04, 05 e 06	39
3.3	TREINAMENTO DAS RNAS	40
3.4	CLASSIFICAÇÃO DAS IMAGENS	41
3.5	MÉTODO DE AVALIAÇÃO	42
4	RESULTADOS E DISCUSSÃO	44
4.1	RESULTADOS OBTIDOS PARA O CENÁRIO01: ZONAS CAFEIRAS	44
4.1.1	Abordagem01: Níveis de cinza	45
4.1.2	Abordagem02: Média dos níveis de cinza	47
4.1.3	Abordagem03: Média e desvio-padrão dos níveis de cinza	49
4.1.4	Abordagem04: Valores de reflectância	51
4.1.5	Abordagem05: Média dos valores de reflectância	53
4.1.6	Abordagem06: Média e desvio-padrão dos valores de reflectância	55
4.1.7	Discussões	57
4.2	RESULTADOS OBTIDOS PARA O CENÁRIO02: CENAS URBANAS	58
4.2.1	Seleção das melhores bandas	59
4.2.2	Abordagem01: Níveis de cinza	65
4.2.3	Abordagem02: Média dos níveis de cinza	66
4.2.4	Abordagem03: Média e desvio-padrão dos níveis de cinza	67
4.2.5	Abordagem04: Valores de reflectância	68
4.2.6	Abordagem05: Média dos valores de reflectância	69
4.2.7	Abordagem06: Média e desvio-padrão dos valores de reflectância	70
4.2.8	Discussões	71
5	CONCLUSÕES	74
5.1	PROPOSTAS DE CONTINUIDADE	75
	REFERÊNCIAS	76

1 INTRODUÇÃO

Informações obtidas por sensoriamento remoto vêm sendo empregadas em diversas aplicações, como no gerenciamento de recursos renováveis, na classificação e avaliação de recursos terrestres, no mapeamento da utilização do solo, no monitoramento de áreas de vegetação e plantações, na detecção de desastres naturais e na previsão de safras (NISHIDA; BASTOS, 1998).

Esta técnica de coleta e análise de dados, cujo termo foi cunhado no início dos anos de 1960 por Evelyn L. Pruitt e colaboradores, consiste na obtenção de imagens de objetos da superfície terrestre sem que haja qualquer tipo de contato físico entre o sensor e o objeto (MENESES; ALMEIDA, 2012).

O rápido avanço no desenvolvimento do sensoriamento remoto em poucas décadas se deu, em grande parte, devido à evolução dos recursos disponíveis para se observar a Terra em uma escala global e periódica. Além disso, pode-se considerar também a rapidez na monitoração dos fenômenos dinâmicos e das mudanças das feições terrestres (MENESES; ALMEIDA, 2012).

Contudo, na maioria das vezes, os dados (imagens) originais do sensoriamento remoto necessitam ser pré-processados, tanto para se realçar ou suavizar as características que se pretende utilizar quanto para alterar a interpretação dos dados. No primeiro caso, o tratamento consiste na execução de operações matemáticas sobre as imagens de modo a alterar suas características espectrais e/ou espaciais, tornando-as mais apropriadas para uma determinada aplicação e resolução de um problema. Por exemplo, ao utilizar como informação a textura da imagem, é tipicamente necessário um tratamento para a remoção de artefatos indesejados (MENESES; ALMEIDA, 2012). No segundo caso, a conversão dos valores em níveis de cinza para refletância é um exemplo de procedimento.

Após esta etapa de pré-processamento, são utilizadas técnicas de classificação de imagens para apresentar resultados mais adequados para a posterior análise e interpretação das informações contidas (NISHIDA, 1998). Em suma, o objetivo da classificação é particionar a imagem em classes pré-definidas pelo usuário, visando proporcionar uma melhor análise dos dados

por parte dos especialistas, tanto por métodos de análise computadorizados quanto manualmente (CRÓSTA, 1993). Existem diversos métodos de classificação que podem ser usados, e estes podem ser divididos nos que executam a classificação por pixel ou por regiões (MENESES; ALMEIDA, 2012). No contexto de sensoriamento remoto, o uso de tecnologias baseadas em conceitos de inteligência artificial tem se mostrado uma alternativa promissora (NISHIDA; BASTOS, 1998).

A partir de um processamento robusto, que realce de forma adequada as características de interesse, algumas dificuldades relacionadas à interpretação visual por parte de especialistas podem ser minimizadas. Apesar de a visão humana ter uma grande capacidade no reconhecimento de padrões, ela dificilmente consegue processar o grande volume de informações presentes numa imagem. Além disso, as degradações e distorções, inerentes à aquisição, transmissão e visualização das imagens, influenciam para limitar ainda mais essa capacidade do olho humano (CRÓSTA, 1993).

Do mesmo modo, a partir dos dados processados, é possível definir métodos de análise automáticos, que possam ser facilmente replicados posteriormente (JARS, 1999). Com isso, os resultados ficam menos suscetíveis à interferência da personalidade dos indivíduos, dado que cada pessoa interpreta os dados a sua maneira, baseado em suas experiências e conhecimentos (JARS, 1999). Também impacta no processo a grande quantidade de imagens, que muitas vezes torna demorado o processo de análise e interpretação (MENESES; ALMEIDA, 2012).

Além desse aspecto, cabe ressaltar que a constante evolução na qualidade das imagens de sensoriamento remoto requer um aumento no investimento em recursos computacionais que deem suporte ao tratamento dessas informações. Em suma, o desenvolvimento de procedimentos robustos e confiáveis resulta em qualidade e produtividade no trabalho, reduzindo significativamente os gastos com recursos humanos necessários na análise e interpretação de imagens (FIGUEIREDO, 2005).

Neste contexto, a principal motivação para a concepção desse trabalho está associada ao fato da extração de informações das imagens de sensoriamento remoto auxiliar nos estudos e na tomada de decisões de especialistas.

O presente trabalho tem como objetivo geral desenvolver uma metodologia baseada em Redes Neurais Artificiais (RNAs) para reconhecimento de padrões em imagens de sensoriamento remoto em dois cenários distintos. O primeiro refere-se à imagens de satélite da região de Três Pontas, localizada ao Sul de Minas Gerais, onde a cultura cafeeira encontra-se presente. Neste caso, o objetivo é identificar automaticamente zonas produtores de café, diferenciando-a de regiões de mata e de outros usos. O segundo cenário é composto por imagens da região da Baía

de Paranaguá referentes à duas datas de aquisição distintas, 1986 e 1999. Este trabalho tem como objetivo delimitar as regiões correspondentes à zonas urbanas. Dessa forma, é possível determinar diferentes itens, incluindo invasão de zonas de preservação e crescimento urbano.

Dada a multiplicidade de abordagens que o tema permite, organizaram-se os seguintes objetivos específicos:

- Agregar conhecimento teórico baseado no estudo de técnicas de classificação de imagens;
- Identificar áreas urbanas através do processo de classificação realizado em imagens de sensoriamento remoto;
- Identificar zonas de café através do processo de classificação realizado em imagens de sensoriamento remoto;
- Avaliar o desempenho do processo de classificação a partir da utilização de diferentes abordagens;
- Desenvolver um artefato textual com conceitos básicos das áreas de pesquisa relacionadas e com a descrição do processo de pesquisa.

Os testes experimentais envolveram a aplicação de diversas características como base para o processo de classificação, bem como o uso de diferentes configurações de RNAs. Os resultados obtidos foram satisfatórios, e permitiram a aplicação de diferentes disciplinas relacionadas ao curso de Sistemas de Informação.

1.1 ESTRUTURA DO TRABALHO

Este documento está dividido em cinco capítulos. O referencial teórico, que visa apresentar um embasamento para a compreensão do restante do trabalho, está descrito no Capítulo 2 e aborda a origem do sensoriamento remoto, além de como ocorre o processo de captação de imagens por parte dos satélites. Também são apresentados conceitos sobre técnicas de classificação de imagens, destacando as diferenças entre os métodos de classificação supervisionados e não supervisionados, e dando ênfase na técnica de classificação de Redes Neurais Artificiais. Ao final deste capítulo, é realizada uma revisão sobre detecção de padrões em imagens de satélite, havendo um maior detalhamento a respeito da detecção de áreas urbanas e zonas de café. Em ambos os tópicos são apresentadas as características principais na extração de informações das imagens, bem como alguns trabalhos já realizados envolvendo cada um desses temas.

No Capítulo 3, é descrita a metodologia utilizada na elaboração deste trabalho, detalhando as imagens utilizadas e cada uma das técnicas escolhidas e aplicadas nas diferentes abordagens. O Capítulo 4, por sua vez, descreve todos os experimentos realizados e avalia o resultado de cada um dos testes.

Por último, o Capítulo 5 aborda as conclusões deste trabalho, onde são apresentadas os resultados obtidos, bem como as dificuldades encontradas durante a execução da proposta. Além disso, são descritas as ideias de continuidade do trabalho e os possíveis trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

A seguir são descritos de forma sucinta os principais temas que permeiam o projeto aqui abordado.

2.1 SENSORIAMENTO REMOTO

Sensoriamento remoto consiste em uma técnica de obtenção de imagens da superfície terrestre onde não há contato físico de qualquer espécie entre o sensor e a superfície (FLORENZANO, 2002).

Esta técnica começou a se desenvolver, como a maioria das tecnologias, a partir de suas aplicações no âmbito militar. A câmera fotográfica, instrumento utilizado para obtenção das fotos aéreas, era inicialmente fixada em pombos-correios e balões não tripulados com o objetivo de capturar fotos dos territórios inimigos. Posteriormente, começaram a ser utilizados aviões para transportar as câmeras, sendo estes utilizados até hoje. Em 1995, por exemplo, aviões de espionagem norte-americanos foram utilizados para monitoramento de queimadas e mapeamentos diversos nas regiões Norte e Centro-Oeste do Brasil (FIGUEIREDO, 2005).

Contudo, a revolução do sensoriamento remoto ocorreu na década de 60. Neste período, conhecido como “corrida espacial” devido aos grandes investimentos na área espacial, viabilizou-se a utilização de satélites artificiais para a tomada das fotos (MENESES; ALMEIDA, 2012). Quatro aspectos foram determinantes para esse processo: a evolução dos sensores, que são os instrumentos que compõem o sistema de coleta de dados e imagens - e que possibilitaram o registro de fotos com maior qualidade e definição; a evolução dos sistemas de telemetria, que são responsáveis pela transmissão dos dados e imagens dos satélites para as estações terrestres - e permitiram o envio de um maior volume de dados; a evolução dos sistemas de processamento das imagens - que incrementaram a capacidade de manutenção de acervos e as opções de tratamento digital das imagens; e a evolução dos lançadores, que são responsáveis por colocar os satélites em órbita (FIGUEIREDO, 2005).

As principais vantagens dos satélites com relação aos aviões no sensoriamento remoto é que, embora demandem grandes investimentos e muita energia para os seus lançamentos, orbitam em torno da Terra por vários anos, têm um gasto de energia muito baixo (não há resistência do ar e a força gravitacional terrestre é equilibrada pela força centrífuga do movimento orbital do satélite). Além disso, executam um processo contínuo no registro de imagens da superfície terrestre (MENESES; ALMEIDA, 2012).

O primeiro satélite de sensoriamento remoto utilizado foi o ERTS-1 (mais tarde renomeado para Landsat 1), colocado em órbita em julho de 1972 pela NASA a cerca de 919 km de altura (BORSOI, 2008). Além deste satélite, a NASA lançou até os dias atuais outros sete satélites da série Landsat, e foram os satélites desta série os primeiros a registrarem imagens da superfície terrestre com média resolução.

O imageamento das cenas coletadas pelos sensores pode ser realizado por diferentes categorias de satélite, incluindo os militares, os científicos e os meteorológicos. Os sensores utilizados para dados em nível orbital tipicamente visam o estudo dos recursos naturais da Terra e operam em diferentes números de bandas que estão associadas aos comprimentos de onda. Dentre os sensores multiespectrais mais utilizados podem-se citar os sensores *Thematic Mapper* (TM) dos satélites Landsat, o *High Resolution Visible* (HRV) do satélite SPOT e os sensores embarcados nos satélites IKONOS e QUICKBIRD. A série NOAA é utilizada no campo da meteorologia (FIGUEIREDO, 2005)(ANDRADE, 2011).

2.1.1 Sensor orbital Landsat TM 5

O satélite Landsat 5 teve seu lançamento realizado no dia primeiro de Março de 1984 e opera em órbita equatorial a 705 Km de altitude. O sensor TM a bordo do satélite produz imagens que representam uma área de 185×185 km e com resolução de 30m, ou seja, cada pixel da imagem representa uma área de 0.09 hectares. O satélite revisita uma mesma região a cada 16 dias (BORSOI, 2008).

Conforme apresentado na Tabela 1, o sensor TM possui sete bandas espectrais, sendo que cada uma se aplica melhor a um tipo de situação.

Observe que a operação ocorre em 7 faixas espectrais, também chamadas bandas espectrais do espectro eletromagnético, que correspondem aos comprimentos de onda específicos listados na Tabela 1. A resolução espacial, relacionada à capacidade do sensor em captar e registrar a menor área possível no terreno, é de $30\text{m} \times 30\text{m}$ em todas as bandas exceto a 6, caso em que a resolução é igual a $120\text{m} \times 120\text{m}$ (ANDRADE, 2011).

Fonte: (INPE, 2013)

Canal	Faixa espectral (μm)	Principais aplicações
1	0.45 - 0.52	Mapeamento de águas costeiras. Diferenciação entre solo e vegetação. Diferenciação entre vegetação coníferas e decídua
2	0.52 - 0.60	Reflectância de vegetação verde sadia
3	0.63 - 0.69	Absorção de clorofila. Diferenciação de espécies vegetais
4	0.76 - 0.90	Levantamento de biomassa. Delineamento de corpos d'água
5	1.55 - 1.75	Medidas de umidade da vegetação. Diferenciação entre nuvens e neve
6	10.4 - 12.5	Mapeamento de estresse térmico em plantas. Outros mapeamentos térmicos
7	2.08 - 2.35	Mapeamento hidrotermal

Tabela 1: Bandas espectrais do sensor TM.

2.1.2 Textura e reflectância na obtenção de imagens

Tomando como base um ponto de vista mais detalhado e técnico, para registrar as imagens da superfície terrestre, o processo de sensoriamento remoto utiliza os sensores para detectar e medir quantitativamente a radiação eletromagnética refletida e/ou emitida pelos objetos a serem analisados (MENESES; ALMEIDA, 2012).

É importante ressaltar que, do mesmo modo que a luz solar é refletida na superfície de qualquer objeto, também ocorre com a radiação eletromagnética, que possui comportamento tanto de onda quanto de energia - o que significa que esta se propaga pelo espaço vazio, como a luz solar. Sensores que obtêm imagens sem utilizar a radiação eletromagnética não devem ser categorizados como sensoriamento remoto (MENESES; ALMEIDA, 2012). A Figura 1 ilustra esse processo de captação de imagens.

Objetos da superfície terrestre, como vegetação, água e solo refletem, transmitem e absorvem radiação eletromagnética de maneiras distintas, uma vez que possuem propriedades físico-químicas e biológicas diferentes. Além disso, o tipo físico que dá origem à energia eletromagnética também influencia na interação desta com os objetos. São essas variações que possibilitam distinguir os diferentes objetos analisados nas imagens de sensores remotos. Esses objetos são representados nas imagens variando do tom do branco (quando refletem muita energia) até o preto (quando refletem pouca energia) (BORSOI, 2008). Essa variação de energia captada pode ser representada utilizando curvas espectrais, como ilustra a Figura 2.

Outro fator que influencia no processo de interação da radiação eletromagnética com os objetos é a textura dos materiais, que são as variações verticais da superfície dos objetos. As texturas podem ser classificadas em dois tipos: difusoras e especulares, dependendo do compri-




Figura 1: Processo de obtenção das imagens de sensoriamento remoto utilizando satélites artificiais.

Fonte: (FLORENZANO, 2002)




Figura 2: Curva espectral.

Fonte: (FLORENZANO, 2002)

mento da onda e o ângulo de incidência do raio incidente. Um solo gradeado, por exemplo, cuja variação de altura da sua superfície varia alguns centímetros, pode ter sua textura classificada como difusora quando o comprimento das ondas eletromagnéticas incidentes é muito pequeno (na ordem de $0,40 \mu\text{m}$). Já utilizando ondas de maior comprimento, na ordem de 100 cm, a mesma textura do solo é observada como lisa (MENESES; ALMEIDA, 2012).

Com relação ao comportamento dos raios refletidos em cada um dos dois casos, a Figura 3 ilustra as diferenças. Em um objeto com superfície lisa, o raio incidente é refletido no sentido oposto, mas com o mesmo ângulo Figura 3(a). Já em um objeto com superfície rugosa, os raios incidentes possuem reflectância difusora, com os raios espalhados em todas as direções Figura

3(b). Além disso, em alguns casos, os dois tipos de reflectância podem se misturar. Para efeito de classificação, uma superfície é classificada como difusora quando 25% ou mais da radiação é refletida difusamente. Assim, podemos definir reflectância como sendo a razão da quantidade de radiação refletida por objeto pela quantidade de radiação que incide nele (MENESES; ALMEIDA, 2012).




Figura 3: Comportamento da reflectância dos raios condicionado às elevações verticais da superfície do objeto: (a) superfície lisa e (b) superfície difusora.

Fonte: (MENESES; ALMEIDA, 2012)

A textura é outro atributo empregado para auxiliar no processo de classificação e pode ser definida como uma variação de tonalidade repetitiva e organizada em uma pequena região da imagem, de modo que suas medidas de propriedades podem ser descritas de modo qualitativo, como “suave”, “rugosa”, “uniforme”, “grosseira”, “regular” e “fina” (DOUGHERTY, 1992). Dentre as abordagens utilizadas em processamento de imagens para a descrição de texturas pode-se destacar:

- Estática: caracteriza as texturas como suave, áspera, granular, entre outras;
- Estrutural: trata de arranjos de primitivas de imagens, como, por exemplo, a utilização de linhas paralelas regularmente espaçadas para descrever uma textura;
- Espectral: utiliza propriedades do espectro de Fourier, sendo utilizada, na maioria das vezes, para detectar periodicidades em uma imagem (GONZALEZ; WOODS, 2009).

2.2 PROCESSAMENTO DIGITAL DE IMAGENS

Técnicas de processamento e análise de imagens têm sido consideradas em um grande número de aplicações, tais como compressão e reconhecimento de padrões, por exemplo. Em alguns casos, os termos processamento e análise de imagens são definidos separadamente. Contudo, aplicações práticas tipicamente envolvem técnicas pertencentes a ambas as categorias, uma vez que fatores tais como ruído e iluminação não-uniforme (minimizadas pelo pro-

cessamento da imagem) podem comprometer etapas subsequentes de identificação e descrição (realizadas por técnicas denominadas de análise de imagens) (VERNON, 1991).

Uma imagem digital é tipicamente definida como uma função bidimensional, $f(x,y)$, em que x e y são coordenadas espaciais (plano), e a amplitude de f no par de coordenadas (x,y) é denominado nível de intensidade da imagem naquele ponto. O número de elementos que representam uma imagem, denominados pixels (*picture elements*), é determinado pela taxa de amostragem sendo considerada. Esta é responsável pela resolução da imagem, realizada a uma melhor ou pior visualização dos detalhes de cada objeto (JAIN; SCHUNCK, 1995)(MUSCI,). A Figura 4 representa os elementos que compõem uma imagem digital.




Figura 4: Elementos que constituem uma imagem digital.

Fonte: (MUSCI,)

O valor que cada pixel pode assumir é determinado pela quantização considerada para codificar os níveis de intensidade. Quanto maior a taxa de amostragem ou a quantização, maior o custo de armazenamento e processamento (JAIN; SCHUNCK, 1995). Dessa forma, são definidos os diferentes modos de representação digital de imagens. Neste trabalho, serão descritas brevemente as principais características de imagens binárias, em níveis de cinza e coloridas.

Imagens binárias constituem o tipo de representação mais básica, uma vez que os valores da matriz são lógicos (1 ou 0) e representam diretamente as regiões do objeto e as do fundo, como ilustra a Figura 5. Tais imagens são frequentemente utilizadas em diferentes contextos, dado que pesquisadores observaram que o ser humano consegue fazer a distinção entre objetos que utilizam apenas dois níveis de cinza.

Nas imagens de níveis de cinza, a matriz é composta por valores que representam a intensidade de cada pixel, seguindo a escala de cinza. Imagens em níveis de cinza tipicamente consideram uma codificação em oito bits, em que a intensidade de um pixel varia de zero (preto)




Figura 5: Representação de imagem binária.

Fonte: (CAMPOS, 2008)

a 255 (branco). Contudo, em algumas aplicações, a faixa de intensidade pode chegar a 4096, por exemplo (GONZALEZ; WOODS, 2001). A Figura 6 ilustra um exemplo de imagem de intensidade, mas com os valores normalizados, adotando o mesmo padrão implementado pela ferramenta utilizada neste trabalho.




Figura 6: Representação de imagem de níveis de cinza.

Fonte: (CAMPOS, 2008)

Ao contrário dos tipos de imagens mencionados até agora, que utilizam uma matriz bidimensional para representar as tonalidades, as imagens coloridas requerem uma matriz tridimensional para representar cada uma das cores. Um dos sistemas de cores que pode ser utilizado é o RGB (*Red, Green, Blue*), que relaciona cada dimensão da matriz com uma das cores primárias aditivas para constituir a tonalidade desejada utilizando valores normalizados no intervalo $[0,1]$. A Figura 7 mostra um exemplo deste tipo de imagem.



Figura 7: Representação de imagem colorida.

Fonte: (CAMPOS, 2008)

Em imagens de sensoriamento remoto, foco deste trabalho, as imagens obtidas são tipicamente separadas em diferentes bandas. O valor de cada pixel em cada banda corresponde à intensidade da energia eletromagnética medida pelo sensor naquela posição em uma determinada faixa espectral. Em outras palavras, o valor de um pixel em uma banda corresponde à média da intensidade da energia eletromagnética refletida ou emitida pelos diferentes materiais presentes na região deste pixel em uma faixa espectral (CRÓSTA, 1993).

Segundo (FLORENZANO, 2002), as imagens obtidas por sensores eletrônicos nas diferentes bandas são representadas em escala de cinza, sendo que o nível de cinza depende da quantidade de energia refletida pelos objetos: o branco representa o caso quando refletem e o preto quando absorvem toda a energia. Alguns programas, tais como o ENVI (ENVI...), possibilitam gerar as imagens coloridas através da projeção e sobreposição das imagens em escala de cinza utilizando filtros coloridos nas cores primárias.

2.3 CLASSIFICAÇÃO DE IMAGENS

O principal interesse nas imagens de sensoriamento remoto é extrair informações e transformá-las em gráficos, mapas ou tabelas para que possam ser melhor analisadas por especialistas.

Como mencionado anteriormente, quando realizado de forma manual, tal processo apresenta diferentes limitações. Uma delas se encontra no fato de que bons critérios de extração devem ser estabelecidos para que os mesmos resultados possam ser obtidos por qualquer profissional da área, dado que cada indivíduo avalia a imagem conforme os seus conhecimentos e a sua percepção em relação à imagem. Outro problema é o elevado número de imagens ou até mesmo a grande extensão da área de estudo, que tornam custoso o trabalho de interpretação (MENESES; ALMEIDA, 2012).

Surgem como solução a esses problemas as técnicas automáticas de classificação de imagens, que automatizam a extração das informações e minimizam a subjetividade humana, melhorando a eficiência do trabalho dos especialistas.

Em geral, técnicas de classificação tomam como base características extraídas de modelos conhecidos de objetos (também denominados protótipos) para descrever classes e inferir a qual delas uma nova região sendo analisada pertence. Em outras palavras, dada uma imagem contendo um ou mais objetos de interesse (e o fundo) e o conjunto de classes (ou rótulos) para um conjunto de modelos conhecidos, o sistema pode atribuir corretamente rótulos para as regiões, ou um conjunto de regiões, na imagem (GONZALEZ; WOODS, 2001).

No contexto deste trabalho, a classificação de imagens consiste em, a partir da análise de determinadas características da imagem, associar a cada pixel uma classe que represente alguma categoria, tal como vegetação ou área urbana, por exemplo. Ao estender essa classificação a todos os pixels da imagem, o resultado obtido é um mapa temático da área geográfica contida na imagem (BELUCO, 2002).

A definição do conjunto de características, também denominadas descritores, é determinante para o sucesso da classificação. Elas devem possibilitar a discriminação de componentes pertencentes a classes distintas, mesmo quando estas são similares. São diversas as características usadas para o reconhecimento de objetos. A maioria delas é baseada em propriedades das regiões ou contornos de uma imagem, assumindo-se que uma região ou contorno fechado corresponde a uma entidade do objeto ou parte do objeto. De forma genérica, podem ser categorizadas em características globais, locais e relacionais (JAIN; SCHUNCK, 1995):

- Características globais : usualmente referem-se à propriedades da imagem como um todo, tal como uma área e momentos de Hu. Uma definição mais aprofundada pode ser obtida em (GONZALEZ; WOODS, 2001), (JAIN, 1989) ou (VERNON, 1991).
- Características locais: são determinadas geralmente no limite de um objeto ou representam uma pequena área distinguível de uma região. Propriedades como a curvatura são

comumente usadas como características locais.

- Características relacionais: baseadas nas posições relativas das diferentes entidades, sejam estas regiões, contornos fechados ou características locais. Incluem geralmente a distância entre as características e medidas de orientação relativa e são muito úteis na definição de objetos compostos por muitas regiões.

De forma geral, os métodos de classificação de imagens de sensoriamento remoto extraem características de uma determinada cena considerando mais de uma banda espectral (NISHIDA, 1998). As informações de níveis de cinza nas bandas selecionadas, bem como a geração de dados derivados (como a média ou a reflectância, por exemplo), podem ser utilizados para definir descritores e realizar o processo de classificação.

As abordagens de classificação são categorizadas em supervisionadas e não supervisionadas, dependendo da disponibilidade ou não de um conjunto de protótipos e do conhecimento de quais são as classes existentes. Na classificação não supervisionada, o padrão é associado a uma classe que é aprendida com base na similaridade entre os padrões de treinamento (JAIN; MAO, 2000), ou seja, é realizada por meio de observações e descobertas. Como o sistema de dados é provido com objetos, mas nenhuma classe é previamente definida, é necessário observar os exemplos e reconhecer padrões apenas com base nestas informações. O algoritmo k-means é um exemplo de técnica de classificação não supervisionada.

A classificação supervisionada é realizada por meio de exemplos, onde um supervisor auxilia o sistema a construir um modelo, definindo classes e exemplos abastecedores destas. A partir da descrição de cada classe, isto é, das propriedades comuns nos exemplos, uma regra de classificação pode ser usada para prever a classe dos novos objetos. Neste caso, são duas as etapas: treinamento (aprendizagem) e teste (classificação), ilustradas na Figura 8.

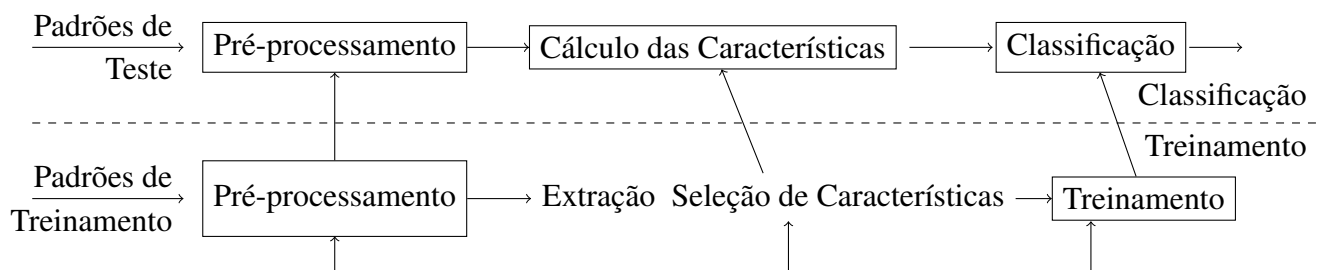


Figura 8: Modelo para reconhecimento de padrões.

Fonte: baseado em (JAIN; MAO, 2000)

Neste esquema, é possível observar a relação entre cada um dos módulos. Na etapa de treinamento, o módulo extração/seleção de características encontra as características apropriadas

para representar os padrões de entrada e o classificador é treinado para particionar o espaço de características. Na etapa de classificação, o classificador treinado atribui as novas entradas um padrão para uma das classes previamente estipuladas, baseado nas características comuns.

Em suma, na etapa de aprendizagem, os descritores (características) de cada padrão considerado são utilizados para treinamento do algoritmo de classificação. Na etapa de teste, tal algoritmo classifica as entradas com base nos descritores extraídos das mesmas. Tipicamente, a grande dificuldade está na otimização do classificador, de forma a garantir uma precisão máxima na classificação de futuras entradas (que serão provavelmente diferentes dos exemplos utilizados no treinamento). Portanto, quanto menos informações disponíveis, maior a dificuldade e também a probabilidade de erro.

O método empregado neste trabalho se encaixa na categoria de classificação supervisionada, onde o treinamento ocorre a partir de uma imagem de referência, na qual as regiões da imagem são classificadas manualmente por um especialista. O treinamento é realizado com base nesta imagem. Existem vários métodos para comparar os dados de treinamento com os dados da imagem, entre eles, o método do paralelepípedo, método da distância mínima e método da máxima verossimilhança (BELUCO, 2002).

No contexto deste trabalho, serão utilizadas RNAs, as quais auxiliam na identificação de padrões e, desta maneira, conseguem realizar a tarefa de identificar a qual classe cada região da imagem pertence. Assim como os outros métodos supervisionados, é preciso selecionar uma amostra de treinamento para que a rede neural artificial aprenda como classificar as imagens. A próxima seção apresenta brevemente os principais conceitos relacionados.

2.3.1 Redes Neurais

Intuitivamente, pode-se definir redes neurais artificiais (RNAs) como modelos matemáticos inspirados no funcionamento dos neurônios biológicos e na estrutura do cérebro (GOLDSCHMIDT; PASSOS, 2005). Existem dois aspectos em que as RNAs se assemelham ao cérebro humano e que podem ser destacados (HAYKIN, 2001). O primeiro deles é que o conhecimento é adquirido por um processo de aprendizado e o segundo é que o conhecimento é armazenado pelos pesos sinápticos, que são as conexões criadas entre os neurônios.

Nas RNAs, as unidades de processamento de informação fundamentais para o seu funcionamento são os neurônios artificiais, os quais consistem em estruturas lógicas com o objetivo de simular o funcionamento de um neurônio biológico, fazendo com que a rede atue de forma indutiva (PACHECO, 1996). A estrutura de um neurônio, como mostrado na Figura 9, apre-

senda como entrada um conjunto de informações (x_1, x_2, \dots, x_m) e produz uma saída única (y_k) . As entradas são ponderadas com seus respectivos pesos sinápticos, $(w_{k1}, w_{k2}, \dots, w_{km})$, e combinadas para fornecer uma entrada para a função de ativação, que reduz a amplitude do valor de saída. Tipicamente, o valor da saída é normalizado no intervalo $[0,1]$ e, em alguns casos, $[-1,1]$.

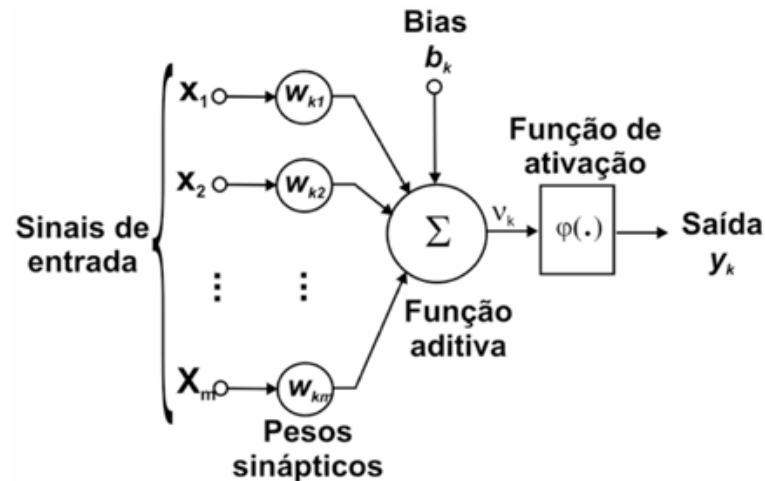


Figura 9: Modelo de neurônio artificial.

Fonte: (CHOREN; GOLDSCHIMIDT; RIBEIRO, 2009)

A função de ativação pode apresentar características lineares ou não-lineares. No primeiro caso, destacam-se a função linear e a função de limiar. Em geral, as funções não-lineares simulam com maior precisão os neurônios biológicos, sendo a função sigmóide uma das mais utilizadas (CHOREN; GOLDSCHIMIDT; RIBEIRO, 2009).

Os neurônios artificiais estão interconectados nas RNAs de modo que formem uma estrutura que pode variar quanto ao número de camadas, neurônios em cada camada, função de ativação dos neurônios em uma camada e a forma como as camadas são conectadas (totalmente ou parcialmente) (CHOREN; GOLDSCHIMIDT; RIBEIRO, 2009). As diferentes arquiteturas de redes neurais são classificadas em função do número de camadas de neurônios, de sua estruturação e da forma como os sinais calculados são propagados (*feedforward* ou recorrentes) (NISHIDA, 1998).

Uma das aplicações de RNAs é a classificação de dados, sendo que diversas arquiteturas podem ser utilizadas. Entre as redes com apenas uma camada de neurônios, o Perceptron é muito difundido (HAYKIN, 2001). Desenvolvido por Rosenblatt em 1958, ele consiste em um único neurônio que recebe várias entradas através de conexões com pesos ajustáveis. Contudo, pode-se ser utilizado apenas para classificar padrões que sejam linearmente separáveis. Outra

característica é que ele é *feedforward*, ou seja, os sinais sempre passam adiante na rede e não retornam nunca (NISHIDA, 1998).

Arquiteturas com várias camadas também são utilizadas para a classificação de dados, sendo que o Perceptron Multicamadas é uma delas. Normalmente, esta extensão do Perceptron de Rosenblatt possui uma arquitetura constituída por duas camadas de neurônios escondidos e uma camada de neurônios de saída, sendo tipicamente treinada com o algoritmo *backpropagation* (NISHIDA, 1998). Ela também apresenta a característica de ser *feedforward*. Com este tipo de arquitetura, é possível classificar padrões linearmente não separáveis, o que a posiciona como uma rede adequada a solucionar problemas mais próximos da realidade.

Outros tipos de arquitetura utilizados são os Mapas Auto-Organizáveis de Kohonen, que procuram aumentar similaridade das RNAs com cérebro humano quanto à disposição dos neurônios, e as Redes Neurais com Função de Base Radial, que utilizam uma função de base radial como função de transferência, associada aos neurônios da camada escondida.

Como visto anteriormente, os neurônios artificiais possuem pesos sinápticos entre eles, os quais precisam ser ajustados para que a rede produza o resultado esperado. O ajuste dos pesos é realizado por algoritmos de aprendizado que fazem com que a rede melhore seu desempenho. Tais algoritmos podem ser divididos em algoritmos supervisionados e não supervisionados. Como mencionado anteriormente, os primeiros são utilizados com a presença de um professor ou supervisor que tem a função de monitorar a resposta da mesma para cada vetor de entrada. Já os não supervisionados são autônomos, ou seja, eles não necessitam de um “professor”, sendo o processo direcionado por correlações existentes nos dados de entrada (REZENDE, 2003).

O processo de treinamento da rede neural tem como aspecto fundamental a escolha do número de neurônios e camadas intermediárias. Em geral, eles são escolhidos com base em uma análise prévia dos dados e da complexidade do problema. A quantidade de dados, as características, a dimensão e a variabilidade desses dados são algumas maneiras de realizar a inspeção prévia (ANDRADE, 2011). O treinamento da RNA deve resultar em um equilíbrio entre sua rigidez (bias) e sua flexibilidade (variância), que é obtido por meio de seu dimensionamento (ANDRADE, 2011). Um dimensionamento ruim da rede pode provocar erros de *overfitting* ou *underfitting*.

Erros de *overfitting* ocorrem quando a rede perde a sua capacidade de generalização, não produzindo as saídas adequadas para os dados de teste. Este erro pode ocorrer quando se escolhe uma quantidade muito grande de neurônios. Já os erros de *underfitting* ocorrem quando existe uma quantidade pequena de neurônios e a rede acaba não sendo treinada suficientemente para produzir seus resultados (ANDRADE, 2011).

Neste trabalho, as RNAs são utilizadas para classificar as imagens de sensoriamento remoto, identificando a qual classe pertence cada região da imagem original e gerando uma mapa temático como resultado.

2.4 RECONHECIMENTO DE PADRÕES EM IMAGENS DE SATÉLITE

O cérebro humano reconhece padrões a partir da classificação de certas texturas, formas e cores identificadas em classes alvos, sendo esse processo inerente a um treinamento neuro-cerebral que ocorre ao longo da vida. Já em um computador, o reconhecimento de padrões em imagens é realizado de um modo mais exato, onde cada um dos pixels de uma imagem é associado a uma determinada classe a partir de regras de decisão específicas que utilizam como base informações relacionadas à cor, textura e forma, por exemplo (MENESES; ALMEIDA, 2012).

Assim, o processo de reconhecimento de padrões busca identificar dados e porções das imagens que sejam semelhantes e que possam ser extraídos utilizando operadores automatizados. A detecção de padrões em imagens de satélite já foi utilizada para auxiliar na resolução de diversos problemas, como na identificação de ocupações urbanas como subsídio para planejamentos (BESSA, 2005); na identificação de cicatrizes do fogo de queimadas em regiões do cerrado brasileiro (LOMBARDI, 2005); e no mapeamento de ambientes costeiros tropicais e de índices de sensibilidade ambiental ao derramamento de óleo no Golfão Maranhense (TEIXEIRA, 2006).

No contexto deste trabalho, visa-se extrair padrões em dois cenários de testes distintos: (a) imagens de cenas urbanas e (b) imagens de regiões cafeeiras. Na sequência, serão discutidos alguns trabalhos relacionados a cada um destes casos.

2.4.1 Detecção de Regiões Urbanas em Imagens de Satélite

A detecção dos diversos tipos de cobertura do solo é um exemplo das aplicações das técnicas de processamento digital de imagens em sensoriamento remoto. Em especial, a detecção de regiões urbanas é de grande importância, pois pode subsidiar os estudos de pesquisadores em urbanismo, hidrologia, questões ambientais e energia, entre outros (QUINTANILHA; OHATA, 2005).

Diversos trabalhos que atuam com processamento de imagens de sensoriamento remoto visando detectar regiões urbanas podem ser encontrados. Em (OLIVEIRA; ZEILHOFER; SANTOS, 2007), é realizada uma comparação do desempenho dos algoritmos de Máxima Verossimilhança e *Bhattacharya* para classificação áreas urbanas em imagens do satélite Landsat

7 da cidade de Cuiabá-MT. Para o primeiro algoritmo aplicado foi alcançado um resultado de 54,65% de acerto e para o segundo de 60,67%.

No trabalho de (ANDRADE; BOTELHO; CENTENO, 2003) são considerados, além de atributos espectrais, as relações espaciais entre os pixels. Desta maneira é possível analisar a forma dos objetos e a classificação de cenas urbanas tem um ganho significativo, uma vez que existe um predomínio de formas geométricas neste cenário. A acurácia da classe “construções” neste trabalho subiu de 38% para 84%.

O trabalho de (BELUCO, 2002), através da aplicação de filtros de Gabor, avaliou a aplicação de atributos texturais na classificação de imagens da cidade de Porto Alegre de dimensões 256×256 pixels, através de RNAs. Os bons resultados, como conclui o autor, instigam a pesquisa de RNAs na classificação de imagens de sensoriamento remoto.

Em (QUINTANILHA; OHATA, 2005), os autores utilizaram técnicas de classificação não-supervisionadas para mensurar a expansão urbana na região metropolitana de São Paulo em imagens do satélite Landsar. Foram aplicados os algoritmos k-means e ISODATA em imagens do ano de 1991 e 2002. Chegou-se a um resultado de crescimento de 12,78% na área urbana, que é compatível com a taxa de crescimento demográfico de 15,5% do censo realizado no mesmo período pelo IBGE. Com este resultado, os autores mostraram que é possível analisar o crescimento urbano a partir de imagens classificadas digitalmente.

2.4.2 Detecção de Áreas Cafeeiras em Imagens de Satélite

Antes da utilização das imagens de satélite, o mapeamento de áreas cafeeiras era realizado com pesquisa de campo, o que demandava muito tempo e um alto custo para a aquisição dos dados. As imagens orbitais, que surgiram na década de 70, tornaram-se um importante instrumento nesta tarefa (ANDRADE, 2011).

A utilização de classificadores automáticos para identificar áreas cafeeiras já foi abordada por diversos autores. Em (MARQUES, 2003), o autor analisou a região de Machado (MG), utilizando o software SPRING para aplicar os algoritmos *Battacharya* e *Maxver* (máxima verossimilhança). Já em (BERNARDES et al., 2007), foi comparado o desempenho dos algoritmos *Battacharya*, *Maxver* e *Isoseg* para classificar a região de Serra Negra, no município de Patrocínio(MG). O relevo movimentado de parte da região foi um fator que dificultou a classificação realizada neste trabalho. Outro autor que também relatou a influência do relevo na classificação das imagens foi Machado (2002), que realizou um estudo na região de Manhuaçu (MG).

Assim como para o caso de detecção de cenas urbanas, diversos trabalhos utilizam RNAs

no processo de classificação. Em (VARELLA et al., 2002), a cobertura do solo é estimada com RNAs treinadas por retropropagação de erro. O resultado obtido, com exatidão de 82.10%, mostrou que as RNAs podem ser utilizadas como alternativa para classificar imagens. Já em (RIBEIRO et al., 2005), os autores compararam diferentes métodos de classificação de imagens digitais multiespectrais de alta resolução do sensor IKONOS II. Os métodos de melhor desempenho para mapear a cobertura terrestre das imagens foram as RNAs e a Máxima Verossimilhança.

Em (VIEIRA; LACERDA; BOTELHO, 2009), é relatada a dificuldade de se identificar culturas cafeeiras devido à similaridade entre os padrões espectrais de café e de mata. Dados auxiliares, como a forma dos objetos e a sua textura, podem ajudar a solucionar este problema. No processamento digital de imagens, a representação de uma região não consiste apenas na diferenciação dos níveis de cinza dos objetos, mas também da delimitação de sua fronteira através da forma dos objetos (região) e também de sua textura (ANDRADE, 2011).

Visando melhorar o mapeamento das coberturas vegetais, (CARVALO, 2001) incorporou dados auxiliares e, além dos dados espectrais das imagens, utilizou séries temporais, dados de textura e feições topográficas para identificar florestas semidecíduais na região de Lavras (MG). O autor relata que os dados topográficos foram importantes como dados de entrada para a classificação por RNAs.

Em (MARTINS; SIMÕES; PRADO, 2007), foi utilizada uma RNA para a classificação de texturas. Na mesma temática, os autores de (SOUZA et al., 2009) desenvolveram um importante trabalho sobre os padrões texturais que diferenciam o cafezal e a mata e concluíram que medidas texturais podem ser usadas satisfatoriamente na discriminação entre as classes de café e mata.

Ainda trabalhando com RNAs, (ANDRADE, 2011) realizou a classificação de imagens da região sul de Minas Gerais buscando identificar áreas cafeeiras. O processo de classificação foi dividido em três etapas: pré-processamento dos dados, treinamento da RNA e análise dos resultados. Utilizou-se o índice Kappa para avaliar o desempenho da RNA e o melhor resultado alcançado foi na região de Guaxupé, com um percentual de acerto de 71.85%. Apesar de terem sido alcançados bons resultados, a autora sugere que outros dados, além das bandas espectrais sejam fornecidos como entrada para a RNA, visando se otimizar a classificação.

Outro trabalho envolvendo a utilização de RNAs é o de (PEREIRA, 2013). O foco do trabalho foi a classificação da região de Três Pontas, no sul de Minas Gerais, utilizando o software MATLAB. O índice de acurácia Kappa obtido na região cafeeira de Três Pontas foi de 0.67, com um índice global de acerto de 79.60%. O autor também ressalta a utilização de outras informações no processo de classificação para alcançar melhores resultados.

3 METODOLOGIA

Este capítulo descreve a metodologia empregada para a definição de um protótipo de sistema de classificação automática de imagens de satélite baseada em RNAs. Tal sistema pode ser aplicado na identificação e no mapeamento do uso e ocupação de terras em dois cenários de testes distintos. No primeiro, o objetivo é identificar áreas de cultivo de café a partir de dados multiespectrais da região de Três Pontas, localizada no sul de Minas Gerais. No outro cenário, o objetivo é determinar áreas de ocupação urbana na região da Baía de Paranaguá, Paraná.

Para cada cenário, foram utilizadas seis abordagens distintas para extração de descritores, que são a base do processo de treinamento das RNAs. Além disso, 15 diferentes configurações de RNAs foram consideradas, visando analisar qual conduz ao melhor desempenho. A avaliação dos resultados se dá por meio do índice Kappa, dado que o uso desse coeficiente é considerado satisfatório para a avaliação da precisão de uma classificação temática (ANDRADE, 2011). Mais detalhes sobre o índice Kappa, como sua fórmula, são apresentados ao final deste capítulo.

Na sequência, cada etapa da metodologia é detalhada.

3.1 IMAGENS UTILIZADAS

No primeiro cenário de testes, doravante denominado Cenário01, foram utilizadas imagens da região de Três Pontas, localizada no sul de Minas Gerais. Segundo (VIEIRA et al., 2006), a cafeicultura desta região está localizada em um relevo mais suavizado e contém áreas de café contíguas, fatores que a tornam privilegiada para o mapeamento devido à maior incidência solar na cultura. A cafeicultura representa 70% da renda agrícola (ANDRADE et al., 2010).

Os dados multiespectrais utilizados são imagens do satélite TM/Landsat 5, bandas 3, 4 e 5, e com data de passagem de 16/07/2007. Elas foram originalmente adquiridas junto ao Instituto Nacional de Pesquisas Espaciais e utilizadas no trabalho (ANDRADE, 2011). A autora, Lívia Naiara de Andrade, atualmente professora no Departamento de Ciência da Computação da Universidade Federal de Lavras, gentilmente forneceu todas as imagens necessárias ao de-

envolvimento do presente trabalho. A Figura 10 ilustra as três bandas consideradas.


Contudo, visando facilitar a extração de informações durante o processo de treinamento da RNA e a validação da classificação, foi necessário realizar um pré-processamento para criar máscaras em cada uma das três bandas. Para tal, (ANDRADE, 2011) utilizou a Linguagem Espacial para Geoprocessamento Algébrico (LEGAL), do SPRING. A partir das linhas de drenagem e suas regiões de preservação associadas (obtidas a partir de informações do Instituto Mineiro de Gestão das Águas), bem como da determinação da área urbana representando a cidade de Três Pontas, foram geradas as imagens ilustradas na Figura 11. Dessa forma, são descartadas áreas que não deveriam possuir o cultivo do café e poderiam causar confusão na classificação pela RNA.

No segundo cenário de testes, doravante denominado Cenário02, foram utilizadas imagens da região da Baía de Paranaguá, no Paraná. Diferentes informações de interesse estão presentes e podem ser exploradas como, por exemplo, a análise de regiões correspondentes a manguezais. No contexto deste trabalho, o objetivo é a identificação de regiões de ocupação urbana em imagens de diferentes datas, de forma a possibilitar a análise de fatores tais como crescimento de zonas ocupadas e invasão de áreas de preservação.


Os dados multiespectrais utilizados são imagens do satélite Landsat 7 adquiridas em duas datas de passagem: 14/09/1986 e 26/09/1999. As imagens foram gentilmente fornecidas pelo prof. Maurício Almeida Noernebrg, do Centro de Estudos do Mar da Universidade Federal do Paraná. Nos testes realizados neste trabalho, foram consideradas informações extraídas das bandas 1, 2, 3, 4 e 5, ilustradas nas Figuras 12 e 13.

Observe que imagens de mesmas bandas apresentam diferenças significativas de acordo com a data de aquisição. Isso se deve à influência da iluminação do sol e de características atmosféricas e geometria (ângulo de iluminação sensor e sol) diferentes. Mesmo aplicando uma correção atmosférica para diminuir alguns destes fatores, haveriam diferenças. Outro aspecto é que na data de 1986 há grande quantidade de nuvens, o que causa saturação e diminui o contraste da área de interesse.


Neste trabalho, foram utilizadas apenas três das cinco bandas para extração dos descritores. O procedimento realizado para determinação da melhor configuração será detalhado posteriormente no Capítulo 4.



(a) Banda 3




(b) Banda 4




(c) Banda 5

Figura 10: Imagens TM/Landsat 5, bandas 3, 4 e 5 do Cenário01 - região de Três Pontas.


Fonte: (ANDRADE, 2011)



(a) Banda 3



(b) Banda 4



(c) Banda 5

Figura 11: Imagens TM/Landsat 5, bandas 3, 4 e 5 do Cenário01 - região de Três Pontas - com máscara de drenagem.

Fonte: (ANDRADE, 2011)




Figura 12: Imagens TM/Landsat 7, bandas 1, 2, 3, 4 e 5 do Cenário02 - região da baía de Paranaguá - aquisição em 14/09/1986.

Fonte: (INPE, 2013)

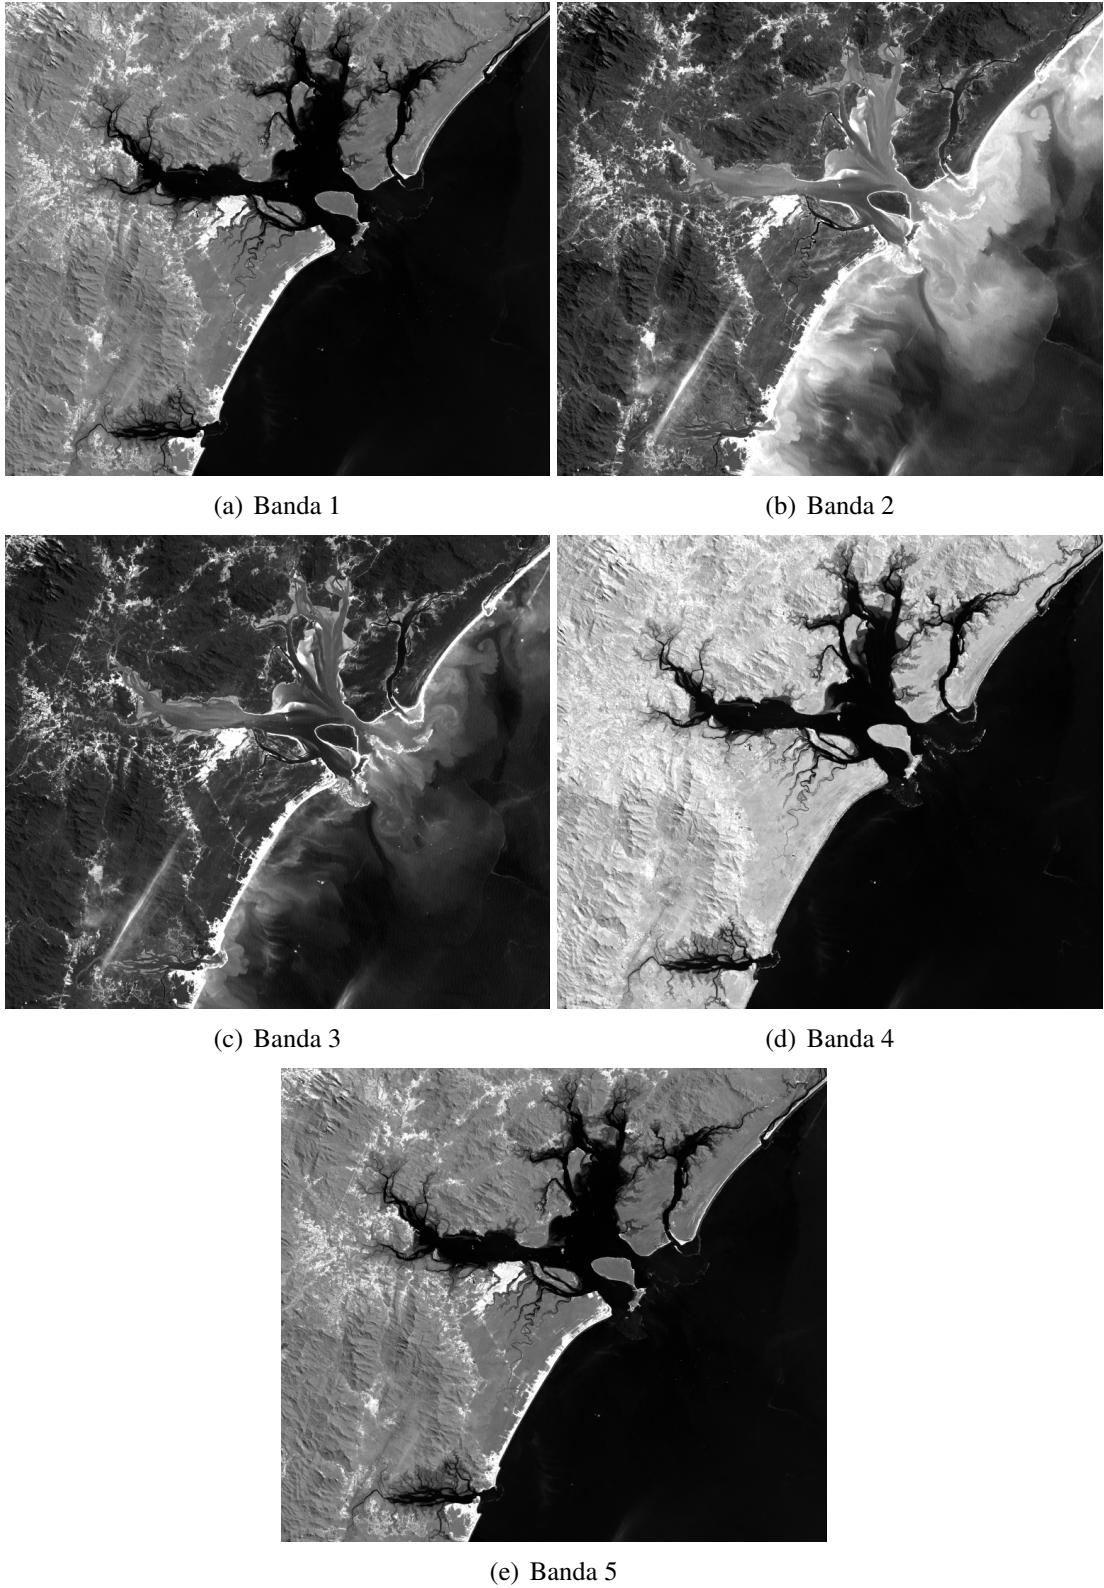


Figura 13: Imagens TM/Landsat 7, bandas 1, 2, 3, 4 e 5 do Cenário02 - região da baía de Paranaguá - aquisição em 26/09/1999.

Fonte: (INPE, 2013)

3.2 EXTRAÇÃO DOS DESCRITORES DAS IMAGENS

Neste trabalho, será considerada uma abordagem de classificação supervisionada. Como mencionado anteriormente, a partir da descrição gerada para cada classe (representando propriedades comuns nos exemplos), uma regra de classificação pode ser usada para prever a classe dos novos objetos. São duas as etapas: treinamento (aprendizagem) e teste (classificação).

Na primeira, os descritores (características) de cada padrão considerado são utilizados para treinamento do algoritmo de classificação. Na etapa de teste, tal algoritmo classifica as entradas com base nos descritores extraídos das mesmas. Neste trabalho, a extração de dados de treinamento considerou 80% da área de cada imagem. Os 20% restantes são reservados para a realização dos testes.

Para que bons resultados sejam obtidos, a escolha de descritores robustos é fundamental. Neste trabalho, foram considerados descritores baseados nos níveis de cinza das imagens de cada banda e também no valor de reflectância associado. Para que a RNA seja treinada a partir de amostras representativas de cada classe de interesse, foram utilizadas diferentes abordagens. No caso das imagens do Cenário01 (região de Três Pontas), os descritores são extraídos com auxílio da imagem de referência mostrada na Figura 14. Observe que ela corresponde ao mapa de uso da área.




Figura 14: Imagem de referência do Cenário01 - região de Três Pontas.

Fonte: (ANDRADE, 2011)

Esta imagem está rotulada de acordo com a seguinte convenção: (a) vermelho: café em produção, (b) verde: mata, (c) azul: corpos d'água, (d) cinza: área urbana e (e) branco: outros usos. Como o presente trabalho visa apenas a identificação de duas classes (café e não-café), descritores da classe café foram extraídos a partir das regiões em vermelho (rótulo 1) e os descritores da classe não-café a partir das demais regiões.

Visando minimizar o custo computacional dos testes relacionados à escolha da melhor configuração de RNA (discutida na próxima seção), eles consideraram sub-imagens de dimensão 200×200 (recorte a partir das coordenadas (2365, 320)) para extração dos descritores, as quais são ilustradas nas Figuras 15(a)-(c) (a Figura 10 mostra as originais). A imagem de referência associada a esse caso é ilustrada na Figura 15(d).




Figura 15: Sub-imagens utilizadas para a escolha da melhor configuração de RNA no Cenário01: (a) banda 3, (b) banda 4, (c) banda 5 e (d) máscara de referência.

No caso das imagens do Cenário02 (região da Baía de Paranaguá), a máscara de referência utilizada para extrair os descritores é formada por 12 regiões pré-selecionadas (seis para a classe urbana e seis para a classe não-urbana). Tal imagem de referência é ilustrada na Figura 16.




Figura 16: Imagem de referência do Cenário02 - Baía de Paranaguá, Paraná.

Visando minimizar o custo computacional dos testes relacionados à escolha da melhor configuração de RNA, eles consideraram sub-imagens de dimensão 720×720 (recorte a partir das coordenadas (1100, 1040)) para extração dos descritores. Tais sub-imagens são ilustradas nas Figuras 17 (passagem de 1986) e 18 (passagem de 1999). As imagens originais (sem este recorte) são apresentadas nas Figuras 12 e 13, respectivamente.




Figura 17: Sub-imagens utilizadas para a determinação da melhor configuração de RNA no Cenário02 - passagem de 1986: (a) banda 1, (b) banda 2, (c) banda 3, (d) banda 4 e (e) banda 5.

As imagens de referência associadas estão ilustradas na Figura 19. Como mencionado anteriormente, são consideradas 12 regiões pré-selecionadas (seis para a classe urbana e seis para a classe não-urbana), e estas são representadas por quadrados pretos, observados na Figura 19. Como as imagens das diferentes datas de passagem estão alinhadas, a localização das máscaras é a mesma para ambos os casos.

É importante ressaltar que, neste cenário de testes, a imagem de referência acima é utilizada apenas para extração dos descritores. A validação dos resultados de classificação considera outra imagem.

O procedimento para extração dos descritores com base nas imagens de referência mostradas é detalhado na sequência.




Figura 18: Sub-imagens utilizadas para a determinação da melhor configuração de RNA no Cenário02 - passagem de 1999: (a) banda 1, (b) banda 2, (c) banda 3, (d) banda 4 e (e) banda 5.

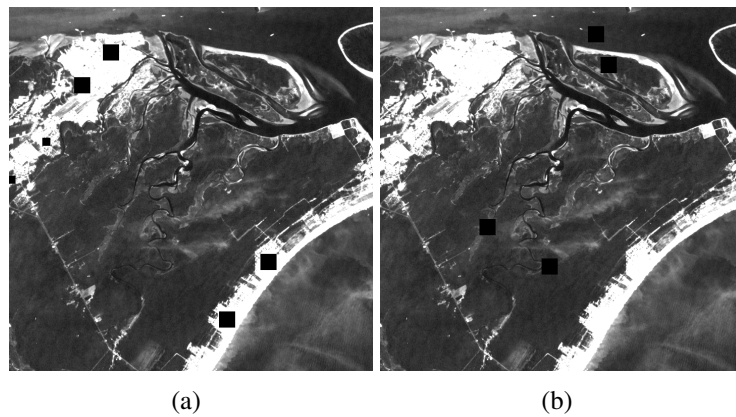


Figura 19: Máscaras utilizadas no Cenário02 para extração de descritores de (a) regiões urbanas e (b) regiões não-urbanas. Fonte: Autoria própria.

3.2.1 Descritores baseados nos níveis de cinza - Abordagens 01, 02 e 03

A primeira abordagem considerada para extrair os descritores baseia-se nos níveis de cinza originais de cada banda sendo analisada (doravante denominada Abordagem01). A leitura destes valores é realizada utilizando-se uma janela quadrada e de tamanho parametrizável, dependendo do cenário sendo explorado.

No caso das imagens do Cenário01, os descritores são extraídos a partir de janelas de tamanho 3×3 centralizadas em cada pixel - esse procedimento é feito em cada banda.

Mais especificamente, para cada pixel rotulado com o valor um (regiões de café), em cada banda é extraída a janela 3×3 centralizada no pixel. Este procedimento gera um vetor coluna de dimensão 27×1 (nove pixels em cada uma das três bandas). A partir deste procedimento, é obtida uma matriz de dimensão $n \times 27$, em que n representa a quantidade de pixels com o rótulo um (café). O mesmo procedimento é realizado com os pixels que possuem rótulo diferente de um, gerando uma matriz de dimensão $m \times 27$, em que m representa a quantidade de pixels possuindo rótulos diferentes de um. Estas duas matrizes são utilizadas como descritores para fins de treinamento de RNAs.

Foram utilizadas ainda mais duas formas para compor os descritores. A Abordagem02 leva em conta apenas a média dos níveis de cinza da janela utilizada na varredura da imagem. Neste caso, um único valor é utilizado para representar cada pixel em cada banda (ao invés dos nove considerados na abordagem anterior). Portanto, o descritor final de cada posição teria dimensão 3×1 . A Abordagem03 consiste em utilizar, além da média, o desvio padrão para composição do descritor (que teria dimensão 6×1 em cada posição).

No caso das imagens do Cenário02, o procedimento é semelhante. Contudo, ao invés de extrair descritores a partir de todos os pixels de uma determinada classe, isso é feito apenas a partir das 12 sub-regiões (seis de cada classe) ilustradas anteriormente na Figura 16.

3.2.2 Descritores baseados nos valores de reflectância - Abordagens 04, 05 e 06

As abordagens 04, 05 e 06 seguem exatamente o mesmo procedimento que as abordagens 01, 02 e 03, respectivamente. Contudo, ao invés dos níveis de cinza são considerados os valores de reflectância associado.

Esta transformação foi realizada com o auxílio de uma planilha de cálculo disponível no site do Instituto Nacional de Pesquisas Espaciais. A planilha leva em conta informações sobre o sensor e sobre a imagem para calcular a reflectância de cada ponto e utiliza o método de correção

atmosférica de subtração de objeto escuro ou DOS (*dark object subtraction*)(GURTLER et al., 2005).

O cálculo realizado pela planilha consiste em remover a interferência atmosférica contida na imagem. O método DOS primeiramente realiza uma estimativa da interferência presente em cada banda espectral. Em seguida, transforma os números digitais em valores de radiância e, finalmente, em valores de reflectância. Para realizar esta transformação diversos parâmetros são necessários: radiância mínima e máxima, irradiância no topo da atmosfera e ganho do sensor, parâmetros que variam para cada banda. Além disso, são necessários outros parâmetros que dependem da data da imagem, como a distância Terra-Sol e o ângulo de elevação solar (GURTLER et al., 2005).

3.3 TREINAMENTO DAS RNAS

Após a etapa de extração dos descritores, é necessário treinar a RNA que será utilizada na classificação. Para tal, é necessário fornecer como parâmetro os descritores e as correspondentes respostas esperadas pela rede em cada caso.

A *toolbox* para redes neurais do MATLAB implementa diferentes funções de treinamento. Neste trabalho, foram realizados testes com cinco diferentes funções, visando identificar qual é a melhor escolha para os cenários trabalhados. São elas: (a) *Levenberg-Marquadt* (`trainlm`), (b) *Gradient descent backpropagation* (`traingd`), (c) *Bayesian Regulation backpropagation* (`trainbr`), (d) *Scaled conjugate gradient backpropagation* (`trainscg`) e (e) *Resilient Backpropagation* (`trainrp`).

O número de camadas da RNA, assim como o número de neurônios da camada escondida pode ser alterado conforme desejado. Como consequência, o desempenho da classificação também é alterado. Como o objetivo é maximizar o desempenho, foram realizados treinamentos com diferentes arquiteturas de rede.

As configurações escolhidas para os testes estão apresentadas na Tabela 2. Elas foram aplicadas considerando descritores definidos a partir das seis abordagens de extração de descritores em sub-imagens dos dois cenários de testes. A configuração que obteve o melhor desempenho foi aplicada na imagem completa.

Config.	Algoritmo de treinamento	Nro.Camadas	Qtde. Neurônios	
			1a. Camada	2a. Camada
1	Levenberg-Marquardt	1	10	-
2	Levenberg-Marquardt	2	10	5
3	Levenberg-Marquardt	2	50	15
4	Gradient descent backpropagation	1	10	-
5	Gradient descent backpropagation	1	80	-
6	Gradient descent backpropagation	2	50	2
7	Bayesian Regulation backpropagation	1	3	-
8	Bayesian Regulation backpropagation	1	5	-
9	Bayesian Regulation backpropagation	1	10	-
10	Scaled conjugate gradient backpropagation	1	10	-
11	Scaled conjugate gradient backpropagation	2	8	2
12	Scaled conjugate gradient backpropagation	1	50	-
13	Resilient Backpropagation	1	5	-
14	Resilient Backpropagation	1	10	-
15	Resilient Backpropagation	2	100	1

Tabela 2: Configurações das RNAs utilizadas para a realização dos testes nas imagens.

Com as RNAs treinadas foi possível então realizar a classificação.

3.4 CLASSIFICAÇÃO DAS IMAGENS

A partir das RNAs treinadas foi possível realizar a classificação. Basicamente, o procedimento consiste em extrair descritores dos 20% da imagem correspondentes à região de treinamento e, então, utilizar a RNA treinada para sua classificação. A Figura 20 ilustra a forma com que as imagens foram divididas (as 80% primeiras colunas foram utilizadas para treinamento).




Figura 20: Delimitação das regiões de treinamento e teste (exemplo para a banda 3 do Cenário01).

3.5 MÉTODO DE AVALIAÇÃO

A última etapa consiste em avaliar os resultados alcançados. Neste trabalho, foi realizada a comparação entre os dados de imagens de referência e aqueles obtidos na classificação.

Para o Cenário01, as imagens de referência são aquelas mostradas anteriormente nas Figuras 14 (para a imagem toda) e 15(d) (para as sub-imagens).

Para o Cenário02, a imagem mostrada na Figura 21(b) - selecionada manualmente pelos autores deste trabalho - foi considerada para determinar os erros e acertos da classificação para o caso da utilização das sub-imagens 720×720 .




Figura 21: Validação dos testes para escolha da configuração de RNA do Cenário02 (sub-imagens 720×720): (a) imagem original e (b) imagem referência (b) representa regiões urbanas).

Não foi possível criar uma imagem de referência para a imagem completa, cujos resultados foram avaliados apenas qualitativamente.

Para os casos onde a imagem de referência estava disponível, além da taxa de classificação foi possível calcular o índice Kappa, que mede a acurácia dos resultados com base na matriz de confusão entre a imagem classificada e o mapa de referência (ANDRADE, 2011).

Considerando que existem apenas duas classes nos cenários trabalhados neste trabalho, a matriz de confusão dos testes realizados é semelhante àquela apresentada na Tabela 3, onde A representa os valores que foram associados a classe 1 e realmente pertencem a classe 1; B foi classificado como pertencente a classe 2, porém pertence a classe 1; C foi atribuído a classe 1, porém pertence a classe 2; e finalmente D foi classificado como classe 2 e de fato pertence a

classe 2.

	Classe 1	Classe 2
Classe 1	A	B
Classe 2	C	D

Tabela 3: Matriz de confusão.

Em (ANDRADE, 2011), o índice Kappa é calculado a partir da tabulação cruzada da seguinte forma:

$$Kappa = \frac{Po - Pe}{1 - Pe} \quad (1)$$

em que $Po = A + D$ e $Pe = (A + B)(A + C) + (B + D)(C + D)$

Os coeficientes calculados neste trabalho são qualificados de acordo com a Tabela 4.

Fonte: (ANDRADE, 2011)

Valor do Kappa	Concordância
< 0,20	Pobre
0,21 - 0,40	Fraca
0,41 - 0,60	Moderada
0,61 - 0,80	Boa
0,81 - 1,00	Muito boa

Tabela 4: Qualificação do índice Kappa a partir de seu valor.

Os resultados são discutidos no próximo capítulo. Em suma, são considerados dois cenários de testes: o Cenário01 considera dados multiespectrais de 2007 e o Cenário02 dados de 1986 e 1999. As imagens utilizadas são detalhadas na Seção 3.1.

Para cada conjunto de dados, são selecionadas sub-imagens que serão consideradas para determinar qual a melhor configuração de RNA. Para tal, são extraídos seis diferentes tipos de descritores (níveis de cinza, média dos níveis de cinza, média e desvio padrão dos níveis de cinza, valores de reflectância, média dos valores de reflectância e média e desvio padrão dos valores de reflectância - detalhados na Seção 3.2). Eles são usados para o treinamento de 15 configurações de RNA (definidas na Seção 3.3). A configuração que leva à melhor taxa de classificação (segundo processo explicado na Seção 3.4), medida em termos do índice Kappa (Seção 3.5), é utilizada para classificar a imagem completa.

4 RESULTADOS E DISCUSSÃO

Neste capítulo são apresentados e discutidos os resultados obtidos a partir da metodologia descrita no capítulo anterior para os dois cenários de teste: Cenário01 (região de Três Pontas - identificação de zonas cafeeiras) e Cenário02 - (região da Baía de Paranaguá - delimitação de zonas urbanas).

4.1 RESULTADOS OBTIDOS PARA O CENÁRIO01: ZONAS CAFEIRAS

Os experimentos para o Cenário01 foram realizados com base em dados multiespectrais do satélite TM/Landsat 5, bandas 3, 4 e 5, e com data de passagem de 16/07/2007. Elas foram originalmente adquiridas junto ao Instituto Nacional de Pesquisas Espaciais e utilizadas no trabalho (ANDRADE, 2011).

Como mencionado anteriormente, visando minimizar o custo computacional dos testes relacionados à escolha da melhor configuração de RNA para cada uma das seis abordagens de extração de descritores, tais experimentos consideraram sub-imagens de dimensão 200×200 . Alguns parâmetros foram mantidos para todas as configurações das RNAs, sumarizados na Tabela 5.

Configurações	Valor padrão
Função de ativação	Sigmoidal
Critério de parada	1000 iterações
Taxa de aprendizado	0.01
Momentum	0.9

Tabela 5: Configurações padrão de todas as arquiteturas de RNA testadas no Cenário01.

Após a determinação da melhor RNA para cada uma das seis abordagens de extração de descritores, a configuração associada foi utilizada para classificação da imagem completa, ou seja, com base nas bandas originais (ilustradas na Figura 10). Em todos os casos, o desempenho é medido em função do índice Kappa.

4.1.1 Abordagem01: Níveis de cinza

A Tabela 6 apresenta o índice Kappa para cada configuração de RNA considerada neste trabalho ao utilizar no treinamento descritores gerados a partir dos níveis de cinza da imagem.

Config.	Algoritmo de treinamento	Nro.Camadas	Qtde. Neurônios		Kappa
			1a. Camada	2a. Camada	
1	Levenberg-Marquardt	1	10	-	0.47
2	Levenberg-Marquardt	2	10	5	0.49
3	Levenberg-Marquardt	2	50	15	0.44
4	Gradient descent backpropagation	1	10	-	0.52
5	Gradient descent backpropagation	1	80	-	0.53
6	Gradient descent backpropagation	2	50	2	0.14
7	Bayesian Regulation backpropagation	1	3	-	0.52
8	Bayesian Regulation backpropagation	1	5	-	0.47
9	Bayesian Regulation backpropagation	1	10	-	0.5
10	Scaled conjugate gradient backpropagation	1	10	-	0.5
11	Scaled conjugate gradient backpropagation	2	8	2	0.51
12	Scaled conjugate gradient backpropagation	1	50	-	0.53
13	Resilient Backpropagation	1	5	-	0.52
14	Resilient Backpropagation	1	10	-	0.49
15	Resilient Backpropagation	2	100	1	0.52

Tabela 6: Resultados para cada RNA - testes realizados com as sub-imagens 200×200 do Cenário01 utilizando os níveis de cinza como descritores.

Note que as RNAs que apresentaram melhor resultado foram as configurações (com índice Kappa de 0.53): (a) 12, que utilizou o algoritmo de treinamento *Scaled conjugate gradient backpropagation* com apenas uma camada oculta de 50 neurônios e a (b) 5, que utilizou o algoritmo de treinamento *Gradient descent backpropagation* com apenas uma camada oculta e 80 neurônios. A parada do treinamento da RNA aconteceu pelo número de iterações do algoritmo *backpropagation*.

Nos testes realizados, observou-se que o simples aumento do número de neurônios em uma camada, bem como a aumento do número de camadas ocultas, não necessariamente produziu melhores resultados. Em alguns casos, como na configuração 6, tal aumento conduziu a erros de classificação significativamente maiores.

A configuração 12, que apresentou o melhor resultado, foi empregada para classificar a imagem de testes completa. O índice Kappa obtido foi de 0.78, o que pode ser considerado bom segundo (GALPARSORO; FERNÁNDEZ, 2001). Este processo teve uma taxa de 91% de acerto na classificação, e os erros ficaram igualmente divididos nas regiões de café e nas outras regiões (4.5% em cada caso). Todo o processo (extração de descritores, treinamento da rede e

classificação) levou aproximadamente sete horas.

As Figuras 22(a) e 22(b) apresentam, respectivamente, a imagem classificada pela RNA (branco representa a classe café) e as regiões em que ocorreram erros na classificação.




Figura 22: Resultado de classificação para a região de teste completa do Cenário01 utilizando como descritores os níveis de cinza e a configuração de RNA 12: (a) imagem classificada pela RNA (branco representa a classe café) e (b) regiões onde ocorreram os erros de classificação.

Fonte: Autoria própria

Na Figura 22(b), pode-se observar que os erros estão associados a regiões produtoras de café que possuem áreas pequenas.

4.1.2 Abordagem02: Média dos níveis de cinza

A Tabela 7 apresenta o índice Kappa para cada configuração de RNA considerada neste trabalho ao utilizar no treinamento descritores gerados a partir da média dos níveis de cinza da imagem.

Config.	Algoritmo de treinamento	Nro.Camadas	Qtde. Neurônios		Kappa
			1a. Camada	2a. Camada	
1	Levenberg-Marquardt	1	10	-	0.46
2	Levenberg-Marquardt	2	10	5	0.46
3	Levenberg-Marquardt	2	50	15	0.44
4	Gradient descent backpropagation	1	10	-	0.14
5	Gradient descent backpropagation	1	80	-	0.25
6	Gradient descent backpropagation	2	50	2	0.3
7	Bayesian Regulation backpropagation	1	3	-	0.45
8	Bayesian Regulation backpropagation	1	5	-	0.45
9	Bayesian Regulation backpropagation	1	10	-	0.46
10	Scaled conjugate gradient backpropagation	1	10	-	0.5
11	Scaled conjugate gradient backpropagation	2	8	2	0.5
12	Scaled conjugate gradient backpropagation	1	50	-	0.48
13	Resilient Backpropagation	1	5	-	0.52
14	Resilient Backpropagation	1	10	-	0.5
15	Resilient Backpropagation	2	100	1	0.48

Tabela 7: Resultados para cada RNA - testes realizados com as sub-imagens 200×200 do Cenário01 utilizando a média dos níveis de cinza como descritor.

Observe que a configuração de RNA que apresentou melhor resultado foi a de número 13, que utilizou o algoritmo de treinamento *Resilient backpropagation*, com apenas uma camada oculta de cinco neurônios. A parada do treinamento da RNA aconteceu pelo número de iterações do algoritmo *backpropagation*. O índice Kappa foi de 0.52.

Assim como na abordagem anterior, observou-se que o aumento do número de neurônios e da quantidade de camadas ocultas não está diretamente relacionado com melhores resultados. Além disso, de forma geral, o algoritmo *Gradient descent backpropagation* obteve os piores resultados.

A configuração que apresentou o melhor resultado foi empregada para classificar a imagem de testes completa, conduzindo a um índice Kappa de 0.72 (considerado bom (GALPARSORO; FERNÁNDEZ, 2001)). A utilização desta RNA resultou em uma taxa de 90% de acerto na classificação, sendo que os erros ficaram igualmente divididos nas regiões de café e nas outras regiões (5% de erro em cada caso). Todo o processo, desde a definição dos descritores até a classificação, demorou 23 minutos, sendo esta duração bastante inferior às sete horas da aborda-

gem 1, uma vez que são utilizados menos valores para treinar a posteriormente testar as RNAs.

As Figuras 23(a) e 23(b) apresentam, respectivamente, a imagem classificada pela RNA (branco representa a classe café) e as regiões em que ocorreram erros na classificação.




Figura 23: Resultado de classificação para a região de teste completa do Cenário01 utilizando como descritor a média dos níveis de cinza e a configuração de RNA 13: (a) imagem classificada pela RNA (branco representa a classe café) e (b) regiões onde ocorreram os erros de classificação.

Fonte: Autoria própria

Pode-se observar que os resultados são similares àqueles obtidos na Abordagem01 mas, de forma geral, possuem índice Kappa menor (isso só não ocorre para as configurações 6 e 14). Contudo, ao considerar tanto o índice Kappa quanto o tempo de execução, pode-se afirmar que os resultados obtidos com a média são aceitáveis. O ganho de apenas 1% na taxa de acerto não necessariamente compensa o maior tempo de execução para a Abordagem01.

4.1.3 Abordagem03: Média e desvio-padrão dos níveis de cinza

A Tabela 8 apresenta o índice Kappa para cada configuração de RNA considerada neste trabalho ao utilizar no treinamento descritores gerados a partir da média e do desvio padrão dos níveis de cinza da imagem.

Config.	Algoritmo de treinamento	Nro.Camadas	Qtde. Neurônios		Kappa
			1a. Camada	2a. Camada	
1	Levenberg-Marquardt	1	10	-	0.52
2	Levenberg-Marquardt	2	10	5	0.51
3	Levenberg-Marquardt	2	50	15	0.48
4	Gradient descent backpropagation	1	10	-	0.34
5	Gradient descent backpropagation	1	80	-	0.31
6	Gradient descent backpropagation	2	50	2	0.33
7	Bayesian Regulation backpropagation	1	3	-	0.58
8	Bayesian Regulation backpropagation	1	5	-	0.56
9	Bayesian Regulation backpropagation	1	10	-	0.47
10	Scaled conjugate gradient backpropagation	1	10	-	0.54
11	Scaled conjugate gradient backpropagation	2	8	2	0.59
12	Scaled conjugate gradient backpropagation	1	50	-	0.6
13	Resilient Backpropagation	1	5	-	0.54
14	Resilient Backpropagation	1	10	-	0.55
15	Resilient Backpropagation	2	100	1	0.55

Tabela 8: Resultados para cada RNA - testes realizados com as sub-imagens 200×200 do Cenário01 utilizando a média e o desvio-padrão dos níveis de cinza como descritor.

A RNA que apresentou o melhor resultado foi a configuração 12, que utilizou o algoritmo de treinamento *Scaled conjugate gradiente backpropagation*, com apenas uma camada oculta de 50 neurônios. A parada do treinamento da RNA aconteceu pelo número de iterações do algoritmo *backpropagation*. O índice Kappa foi de 0.60. A configuração 11 conduziu a resultados similares.

A utilização da configuração 12 para o treinamento e posterior classificação da imagem de testes completa resultou em um índice Kappa de 0.80, considerado bom. A RNA treinada segundo estes parâmetros conduziu a uma taxa de 92% de acerto na classificação, e os erros ficaram igualmente divididos nas regiões de café e nas outras regiões (4% de erro em cada).

Assim como foi o caso para os testes anteriores, a parada do treinamento da RNA também ocorreu devido ao número de iterações do algoritmo de treinamento. O processo completo demorou cerca de duas horas.

As Figuras 24(a) e 24(b) apresentam, respectivamente, a imagem classificada pela RNA

(branco representa a classe café) e as regiões em que ocorreram erros na classificação.




Figura 24: Resultado de classificação para a região de teste completa do Cenário01 utilizando como descritores a média e o desvio padrão dos níveis de cinza e a configuração de RNA 12: (a) imagem classificada pela RNA (branco representa a classe café) e (b) regiões onde ocorreram os erros de classificação.

Fonte: Autoria própria

Comparados aos resultados das Abordagem01 (Tabela 6) e da Abordagem02 (Tabela 7), os índices Kappa obtidos neste experimento são melhores. Como consequência, a taxa de classificação também foi a maior.

4.1.4 Abordagem04: Valores de reflectância

A Tabela 9 apresenta o índice Kappa para cada configuração de RNA considerada neste trabalho ao utilizar no treinamento descritores gerados a partir dos valores de reflectância.

Config.	Algoritmo de treinamento	Nro.Camadas	Qtde. Neurônios		Kappa
			1a. Camada	2a. Camada	
1	Levenberg-Marquardt	1	10	-	0.51
2	Levenberg-Marquardt	2	10	5	0.49
3	Levenberg-Marquardt	2	50	15	0.47
4	Gradient descent backpropagation	1	10	-	0.46
5	Gradient descent backpropagation	1	80	-	0.51
6	Gradient descent backpropagation	2	50	2	0.46
7	Bayesian Regulation backpropagation	1	3	-	0.53
8	Bayesian Regulation backpropagation	1	5	-	0.48
9	Bayesian Regulation backpropagation	1	10	-	0.49
10	Scaled conjugate gradient backpropagation	1	10	-	0.49
11	Scaled conjugate gradient backpropagation	2	8	2	0.53
12	Scaled conjugate gradient backpropagation	1	50	-	0.5
13	Resilient Backpropagation	1	5	-	0.51
14	Resilient Backpropagation	1	10	-	0.54
15	Resilient Backpropagation	2	100	1	0.52

Tabela 9: Resultados para cada RNA - testes realizados com as sub-imagens 200×200 do Cenário01 utilizando os valores de reflectância como descritor.

Note que a configuração de RNA que apresentou melhor resultado foi a de número 14, que utilizou o algoritmo de treinamento *Resilient backpropagation*, com apenas uma camada oculta de 10 neurônios (índice Kappa de 0.54). A parada do treinamento da RNA aconteceu pelo número de iterações do algoritmo *backpropagation*. As configurações 11 e 7 também conduziram a resultados similares.

Assim como nas abordagens que utilizam os níveis de cinza como descritores, o desempenho das RNAs não está diretamente relacionado com um aumento do número de neurônios nas camadas ou com uma maior quantidade de camadas ocultas. A configuração 7, com apenas uma camada de três neurônios, obteve o mesmo desempenho da configuração 11, que conta com duas camadas.

A utilização desta arquitetura na classificação da imagem de testes completa apresentou um índice Kappa de 0.80, um bom índice segundo (GALPARSORO; FERNÁNDEZ, 2001). Este processo resultou em uma taxa de 90% de acerto na classificação, sendo que os erros ficaram igualmente divididos nas regiões de café e nas outras regiões (5% de erro em cada).

O processo completo, desde a extração de descritores até a classificação levou aproximadamente duas horas. As Figuras 25(a) e 25(b) apresentam, respectivamente, a imagem classificada pela RNA (branco representa a classe café) e as regiões em que ocorreram erros na classificação.




Figura 25: Resultado de classificação para a região de teste completa do Cenário01 utilizando como descritor o valor de reflectância e a configuração de RNA 14: (a) imagem classificada pela RNA (branco representa a classe café) e (b) regiões onde ocorreram os erros de classificação.

Fonte: Autoria própria

Em comparação às abordagens anteriores, pode-se observar uma maior estabilidade entre todas as configurações. Ao utilizar os níveis de cinza, as configurações 4, 5 e 6 apresentaram baixos índices Kappa, o que não ocorreu aqui. Contudo, nos demais casos, o uso da reflectância não teve um grande impacto na taxa de classificação.

4.1.5 Abordagem05: Média dos valores de reflectância

A Tabela 10 apresenta o índice Kappa para cada configuração de RNA considerada neste trabalho ao utilizar no treinamento descritores gerados a partir da média dos níveis de reflectância.

Config.	Algoritmo de treinamento	Nro.Camadas	Qtde. Neurônios		Kappa
			1a. Camada	2a. Camada	
1	Levenberg-Marquardt	1	10	-	0.53
2	Levenberg-Marquardt	2	10	5	0.5
3	Levenberg-Marquardt	2	50	15	0.48
4	Gradient descent backpropagation	1	10	-	0.49
5	Gradient descent backpropagation	1	80	-	0.5
6	Gradient descent backpropagation	2	50	2	0.51
7	Bayesian Regulation backpropagation	1	3	-	0.5
8	Bayesian Regulation backpropagation	1	5	-	0.48
9	Bayesian Regulation backpropagation	1	10	-	0.52
10	Scaled conjugate gradient backpropagation	1	10	-	0.49
11	Scaled conjugate gradient backpropagation	2	8	2	0.51
12	Scaled conjugate gradient backpropagation	1	50	-	0.51
13	Resilient Backpropagation	1	5	-	0.51
14	Resilient Backpropagation	1	10	-	0.51
15	Resilient Backpropagation	2	100	1	0.54

Tabela 10: Resultados para cada RNA - testes realizados com as sub-imagens 200×200 do Cenário01 utilizando a média dos níveis de reflectância como descritor.

Tomando como base os dados da Tabela 10, percebe-se que a RNA que apresentou melhor resultado foi a configuração 15, que utilizou o algoritmo de treinamento *Resilient backpropagation*, com duas camadas ocultas, uma com 100 neurônios e outra com apenas 1. O índice Kappa foi de 0.54. A parada do treinamento da RNA aconteceu pelo número de iterações do algoritmo *backpropagation*.

A utilização da configuração 15 na classificação da imagem de testes completa conduziu a um índice Kappa de 0.78. A classificação a partir desta RNA conduziu a uma taxa de 88% de acerto na classificação, na qual os erros ficaram igualmente divididos nas regiões de café e nas outras regiões (5.5% de erro em cada caso). A execução de todo o processo de classificação demorou cerca de três horas.

As Figuras 26(a) e 26(b) apresentam, respectivamente, a imagem classificada pela RNA (branco representa a classe café) e as regiões em que ocorreram erros na classificação.




Figura 26: Resultado de classificação para a região de teste completa do Cenário01 utilizando como descritor a média do valor de reflectância e a configuração de RNA 15: (a) imagem classificada pela RNA (branco representa a classe café) e (b) regiões onde ocorreram os erros de classificação.

Fonte: Autoria própria

Em comparação aos resultados da Abordagem02 (Tabela 7) pode-se afirmar que, em geral, foram superiores. Além disso, os resultados foram mais estáveis ao comparar todas as configurações, sendo que todos ficaram entre 0.48 e 0.54. Ao considerar a Abordagem02, as configurações 4, 5 e 6 apresentaram uma queda no índice, o que não ocorre aqui.

4.1.6 Abordagem06: Média e desvio-padrão dos valores de reflectância

A Tabela 11 apresenta o índice Kappa para cada configuração de RNA considerada neste trabalho ao utilizar no treinamento descritores gerados a partir da média dos níveis de reflectância.

Config.	Algoritmo de treinamento	Nro.Camadas	Qtde. Neurônios		Kappa
			1a. Camada	2a. Camada	
1	Levenberg-Marquardt	1	10	-	0.58
2	Levenberg-Marquardt	2	10	5	0.55
3	Levenberg-Marquardt	2	50	15	0.58
4	Gradient descent backpropagation	1	10	-	0.56
5	Gradient descent backpropagation	1	80	-	0.54
6	Gradient descent backpropagation	2	50	2	0.51
7	Bayesian Regulation backpropagation	1	3	-	0.57
8	Bayesian Regulation backpropagation	1	5	-	0.59
9	Bayesian Regulation backpropagation	1	10	-	0.57
10	Scaled conjugate gradient backpropagation	1	10	-	0.57
11	Scaled conjugate gradient backpropagation	2	8	2	0.57
12	Scaled conjugate gradient backpropagation	1	50	-	0.55
13	Resilient Backpropagation	1	5	-	0.51
14	Resilient Backpropagation	1	10	-	0.48
15	Resilient Backpropagation	2	100	1	0.55

Tabela 11: Resultados para cada RNA - testes realizados com as sub-imagens 200×200 do Cenário01 utilizando a média e o desvio-padrão dos níveis de reflectância como descritor.

A configuração de RNA que apresentou melhor resultado foi a de número 8, que utilizou o algoritmo de treinamento *Bayesian Regulation backpropagation*, com apenas uma camada oculta de 5 neurônios. A parada do treinamento da RNA aconteceu pelo número de iterações do algoritmo *backpropagation*.

A utilização desta arquitetura na classificação da imagem inteira apresentou um índice Kappa de 0.81. A RNA teve uma taxa de 93% de acerto na classificação, e os erros ficaram igualmente divididos nas regiões de café e nas outras regiões (3.5% de erro em cada caso).

A parada do treinamento da RNA também ocorreu devido ao número de iterações do algoritmo de treinamento, sendo que todo o processo levou cerca de cinco horas.

As Figuras 27(a) e 27(b) apresentam, respectivamente, a imagem classificada pela RNA (branco representa a classe café) e as regiões em que ocorreram erros na classificação.




Figura 27: Resultado de classificação para a região de teste completa do Cenário01 utilizando como descritores a média e o desvio padrão do valor de reflectância e a configuração de RNA 8: (a) imagem classificada pela RNA (branco representa a classe café) e (b) regiões onde ocorreram os erros de classificação.

Fonte: Autoria própria

Em comparação aos resultados da Abordagem03 (Tabela 8) pode-se afirmar que, em geral, foram superiores. Além disso, os resultados foram mais estáveis ao comparar todas as configurações, assim como aconteceu para a abordagem acima. A taxa de classificação obtida para a imagem completa foi a maior entre os descritores que utilizam como base os valores de reflectância (93%).

4.1.7 Discussões

As Tabelas 12 e 13 mostram, respectivamente, as arquiteturas das RNAs que apresentaram melhor desempenho na classificação das sub-imagens 200×200 e das imagens completas.

Abordagem	Algoritmo de treinamento	Nro.Camadas	Qtde. Neurônios		Kappa
			1a. Camada	2a. Camada	
1	Scaled conjugate gradient backpropagation	1	50	-	0.53
2	Resilient Backpropagation	1	5	-	0.52
3	Scaled conjugate gradient backpropagation	1	50	-	0.6
4	Resilient Backpropagation	1	10	-	0.54
5	Resilient Backpropagation	2	100	1	0.54
6	Bayesian Regulation backpropagation	1	5	-	0.59

Tabela 12: Melhores desempenhos das RNAs no processo de classificação para o Cenário01 em cada uma das abordagens para as imagens 200×200 .

Abordagem	Algoritmo de treinamento	Nro.Camadas	Qtde. Neurônios		Kappa
			1a. Camada	2a. Camada	
1	Scaled conjugate gradient backpropagation	1	50	-	0.78
2	Resilient Backpropagation	1	5	-	0.72
3	Scaled conjugate gradient backpropagation	1	50	-	0.80
4	Resilient Backpropagation	1	10	-	0.80
5	Resilient Backpropagation	2	100	1	0.78
6	Bayesian Regulation backpropagation	1	5	-	0.81

Tabela 13: Melhores desempenhos das RNAs no processo de classificação para o Cenário01 em cada uma das abordagens para as imagens originais (completas).

Os resultados obtidos no processo de classificação da imagem completa obtiveram um índice Kappa melhor que os gerados nos testes para imagens 200×200 . Provavelmente, isso se deve ao fato que, como são passados muito mais valores para o treinamento das RNAs, pode-se chegar a uma maior precisão.

As taxas de classificação para as imagens completas foram melhores quando comparados àqueles obtidos em (ANDRADE, 2011), onde o índice Kappa obtido para este cenário foi de 67.61%. Contudo, cabe ressaltar que aqui são consideradas apenas duas classes (café e não-café), em comparação às cinco classes de (ANDRADE, 2011).

Como não houve um grande impacto nos resultados utilizando como descritores todos os valores da janela em comparação àqueles obtidos considerando apenas a média (ou a média e o desvio padrão), é possível ver que, mesmo usando todos os dados para treinamento não ocorreu *overfitting* no treinamento das RNAs.

Além disso, pode-se perceber que a utilização dos níveis de cinza e dos valores de reflectância apresentou resultados muito semelhantes para o mesmo tipo de informação passada para as RNAs (valores individuais, média dos valores da vizinhança, e média e desvio-padrão dos valores da vizinhança). Assim, o que influenciou mais foi o a forma de processamento das informações passadas para a RNA. Neste contexto, a utilização da média e do desvio-padrão das janelas se mostrou a melhor abordagem. Contudo, cabe ressaltar que o algoritmo *Gradient descent backpropagation* se mostrou sensível à utilização dos níveis de cinza.

Com relação aos resultados da classificação para a imagem inteira, estes tiveram um desempenho bom, com pouca variação entre cada uma das abordagens. A que apresentou o melhor resultado dentre todas foi a RNA com o algoritmo de treinamento *Bayesian Regulation backpropagation*, com apenas uma camada oculta de 5 neurônios, utilizando como descritor a média e o desvio-padrão dos níveis de reflectância da imagem.

Os erros de classificação em cada uma das abordagens que obtiveram os melhores resultados apresentaram comportamento semelhante, sendo estes quase igualmente divididos nas regiões cafeeiras e nas outras regiões. A utilização de técnicas de pré-processamento de imagens poderia diminuir ainda mais estes erros.

Por fim, como já abordado no trabalho de (ANDRADE, 2011), as RNAs mostraram-se uma ferramenta promissora para a análise de áreas cafeeiras em imagens de sensoriamento remoto.

4.2 RESULTADOS OBTIDOS PARA O CENÁRIO02: CENAS URBANAS

Os experimentos para o Cenário02 foram realizados com base em dados multiespectrais do satélite TM/Landsat 7, bandas 1, 2 3, 4 e 5, e com datas de passagem de 14/09/1986 e 26/09/1999.

Como mencionado anteriormente, visando minimizar o custo computacional dos testes relacionados à escolha da melhor configuração de RNA, estes consideraram sub-imagens de dimensão 720×720 . As imagens de referência utilizadas para extração dos descritores consideram 12 regiões pré-selecionadas (seis para a classe urbana e seis para a classe não-urbana). Como as imagens das diferentes datas de passagem estão alinhadas, a localização das máscaras é a mesma para ambos os casos.

É importante ressaltar que, para o Cenário02, a imagem de referência acima mencionada é utilizada apenas para extração dos descritores. A validação dos resultados de classificação para os experimentos de escolha da melhor configuração de RNA (utilizando as sub-imagens 720×720) usam uma imagem selecionada manualmente pelos autores deste trabalho (Figura 21(b)).

Em todas as 15 configurações de RNAs testadas, alguns parâmetros foram mantidos. A Tabela 14 apresenta estas configurações.

Configurações	Valor padrão
Função de ativação	Sigmoidal
Critério de parada	1.500 interações
Taxa de aprendizado	0.01
Momentum	0.9

Tabela 14: Configurações padrão de todas as arquiteturas de RNA testadas no cenário 1.

A melhor configuração geral é então utilizada para treinamento e classificação da imagem completa (considerando-se 80% da imagem para treinamento e 20% para testes). Neste caso, a avaliação foi apenas visual, dado que não foi possível criar a máscara de referência para a imagem completa.

Antes dos testes experimentos para definição da RNA com melhor desempenho no Cenário02, foi necessário selecionar quais bandas apresentavam informações mais relevantes. Esta análise é apresentada na Seção 4.2.1. O melhor resultado para cada uma das datas de aquisição (1986 e 1999) foi utilizado como base para os todos os testes subsequentes.

A seguir, são apresentados os resultados obtidos para a seleção das bandas a serem utilizadas nos testes e, posteriormente, para a classificação considerando diferentes abordagens de extração de descritores e configurações de RNAs.

4.2.1 Seleção das melhores bandas

A escolha das bandas que serão utilizadas para extrair descritores usados no treinamento de uma RNA influencia diretamente no processo de classificação, uma vez que cada banda captura diferentes aspectos da textura dos objetos.

Para definir as bandas que propiciam o melhor desempenho (medido em função do índice Kappa), foram realizados cinco testes de classificação com diferentes combinações destas. Em todos eles foi mantida a mesma arquitetura de RNA, sendo esta composta por uma camada oculta de 10 neurônios e utilizando o algoritmo de treinamento *Levenberg-Marquardt*. Além disso, também foi utilizado o mesmo descritor para todos os testes, o qual utiliza os valores dos níveis de cinza.

A Tabela 15 apresenta os resultados dos testes para as bandas registradas no ano de 1986.

Observe que, de forma geral, os resultados não tiveram um desempenho satisfatório. Um

Configuração	Bandas	Índice Kappa	Taxa de classificação correta
1	B1 - B2 - B3	0.19	63%
2	B3 - B4 - B5	0.2	65%
3	B1 - B3 - B5	0.28	75%
4	B2 - B3 - B4	0.11	47%
5	B5 - B5 - B5	0.22	73%

Tabela 15: Desempenho da classificação da RNA utilizando diferentes bandas do registro de 1986.

fator determinante é o fato que, em todas as cinco bandas registradas na data 14/09/1986, foi capturada uma massa de ar (nuvem) sobre região da baía de Paranaguá. Como tal massa possui características texturais bastante semelhantes às das cenas urbanas, elas foram classificadas erroneamente (este problema compreendeu a taxa de erro quase inteira de todos os testes). Outro fator que apresentou um pequeno erro de classificação foram as áreas com areia, também classificadas como cenas urbanas.

A configuração 3, que apresentou melhor resultado, foi a utilizada para testar os diferentes descritores e arquiteturas de RNAs para as imagens de 1986, como apresentado nas próximas seções. Ela teve 75% de acerto nas classificações, sendo os 25% de erro compreendendo majoritariamente a classificação da massa de ar e zonas de areia como cena urbana.

As Figuras 28 e 29 apresentam, respectivamente, os resultados de classificação e as regiões classificadas erroneamente.

A Tabela 16 apresenta os resultados dos testes para as bandas registradas no ano de 1999.

Configuração	Bandas	Índice Kappa	Taxa de classificação correta
1	B1 - B2 - B3	0.71	95%
2	B3 - B4 - B5	0.62	87%
3	B1 - B3 - B5	0.64	89%
4	B2 - B3 - B4	0.68	92%
5	B5 - B5 - B5	0.75	96%

Tabela 16: Desempenho da classificação da RNA utilizando diferentes bandas do registro de 1999.

Como pode-se perceber, os resultados foram bem melhores se comparados com os testes realizados nas imagens de 1986. Isso se deve à ausência de uma massa de ar sobre a região, o que levou a menos falsos positivos e contribuiu para uma taxa de acerto maior. Contudo, os problemas de classificação das zonas de areia também se fizeram presentes.

A configuração 5, que apresentou melhor resultado, foi a utilizada para testar os diferentes




Figura 28: Resultados de classificação para as diferentes combinações de banda - 1986.

Fonte: Autoria própria.

descritores e arquiteturas de RNAs para as imagens de 1999, como apresentado nas próximas seções. Esta obteve 96% de acerto na classificação, com um índice Kappa de 0.75. Quase todo o erro de classificação se deu pela atribuição de áreas com areia como sendo cenas urbanas.

Contudo, cabe observar que a escolha das bandas mais adequadas é fundamental. É preciso analisar em qual delas as características de interesse são melhor representadas. Note que, para a melhor configuração, apenas a banda 5 foi considerada. Isso mostra que, em alguns casos, a utilização de mais características pode confundir o algoritmo de treinamento ao invés de aprimorá-lo.

As Figuras 30 e 31 apresentam, respectivamente, os resultados de classificação e as regiões

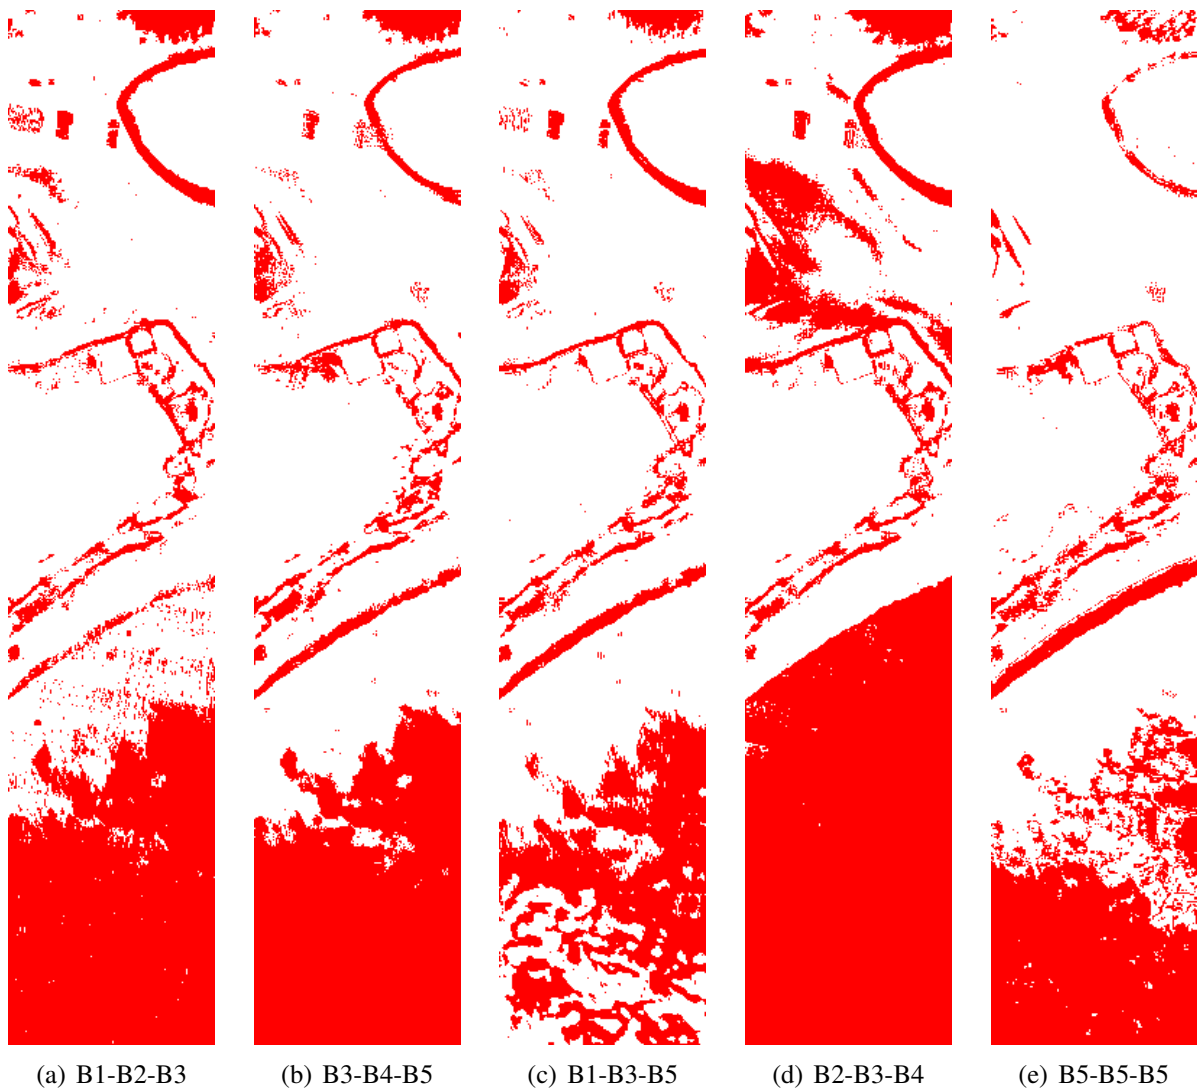


Figura 29: Erros de classificação para as diferentes combinações de banda - 1986.

Fonte: Autoria própria.

classificadas erroneamente. Observe os erros existentes na região de mar nos itens (b)-(d).

Testes futuros poderiam utilizar descritores compostos por dados extraídos uma única vez de cada banda.

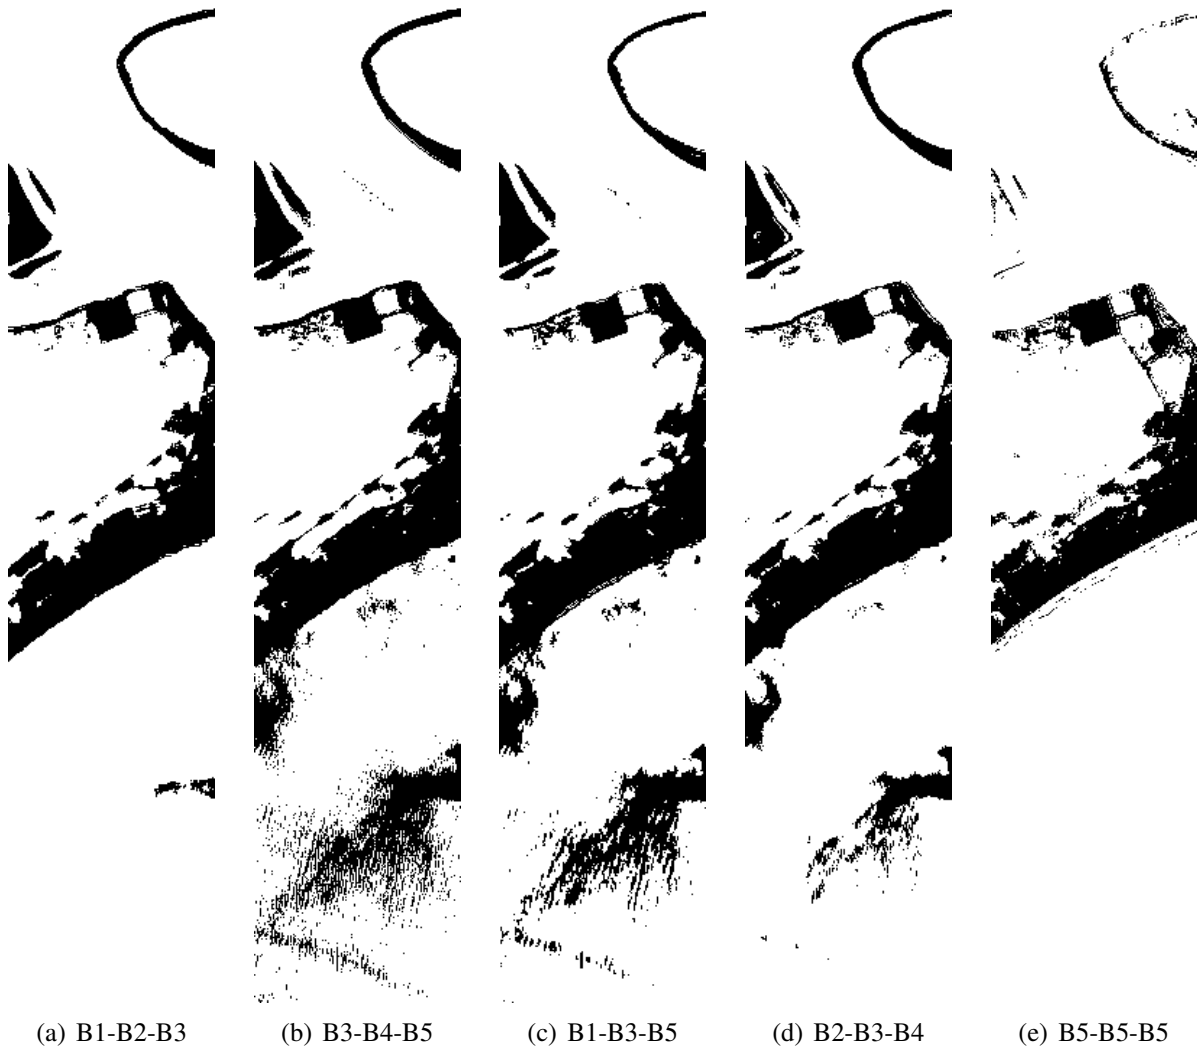


Figura 30: Resultados de classificação para as diferentes combinações de banda - 1999.

Fonte: Autoria própria.

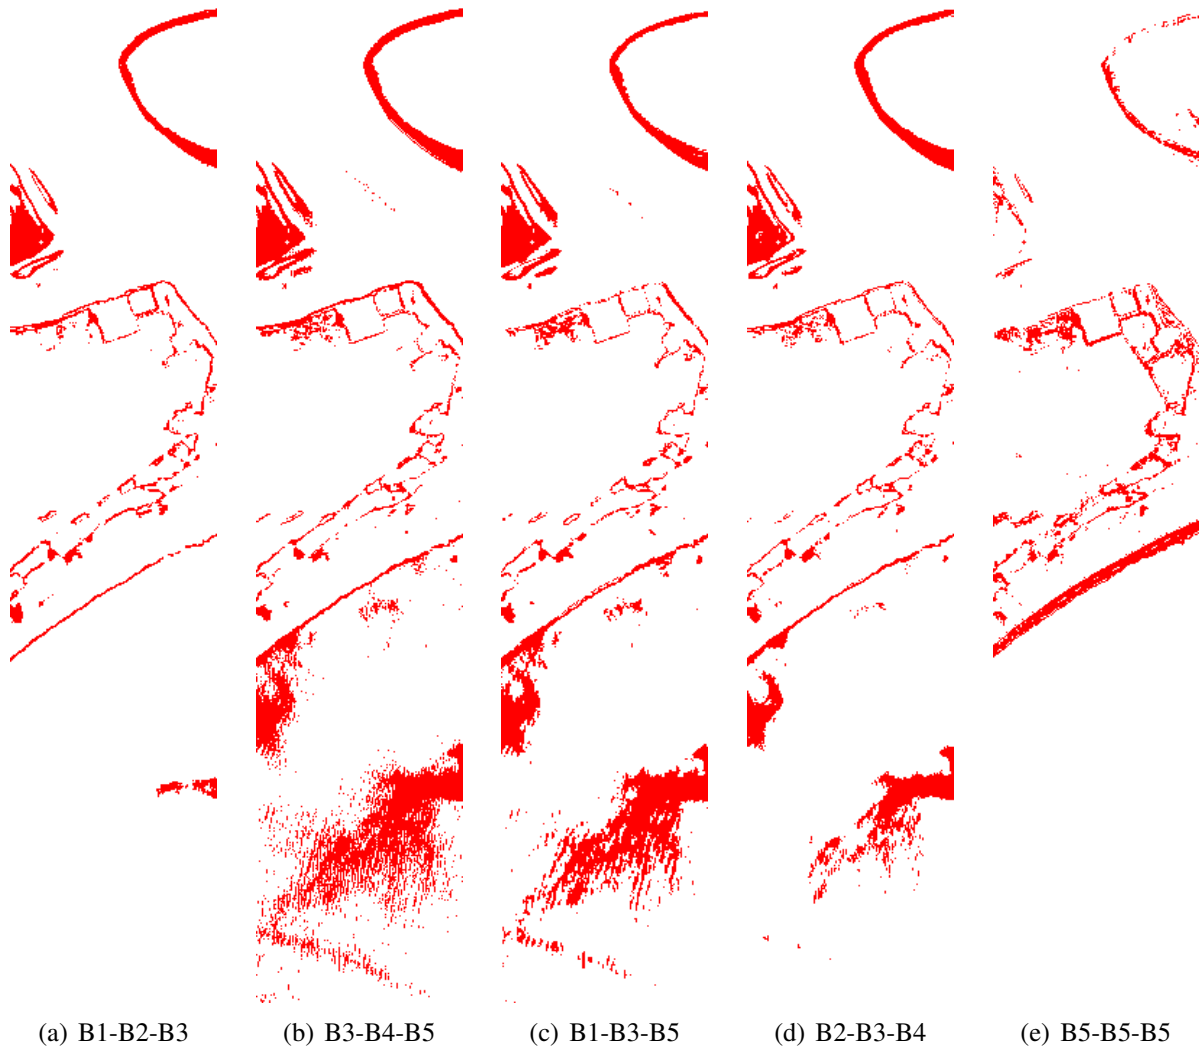


Figura 31: Erros de classificação para as diferentes combinações de banda - 1999.

Fonte: Autoria própria.

4.2.2 Abordagem01: Níveis de cinza

A Tabela 17 apresenta o índice Kappa para cada configuração de RNA considerada neste trabalho ao utilizar no treinamento descritores gerados a partir dos níveis de cinza. São apresentados tanto os resultados referentes à passagem de 1986 quanto de 1999.

Config.	Algoritmo de treinamento	Nro.Camadas	Qtde. Neurônios		Kappa (86)	Kappa (99)
			1a. Cam.	2a. Cam.		
1	Levenberg-Marquardt	1	10	-	0.26	0.71
2	Levenberg-Marquardt	2	10	5	0.31	0.76
3	Levenberg-Marquardt	2	50	15	0.33	0.73
4	Gradient descent backprop.	1	10	-	0.12	0.54
5	Gradient descent backprop.	1	80	-	0.14	0.58
6	Gradient descent backprop.	2	50	2	0.16	0.55
7	Bayesian Regulation backprop.	1	3	-	0.28	0.77
8	Bayesian Regulation backprop.	1	5	-	0.22	0.78
9	Bayesian Regulation backprop.	1	10	-	0.25	0.77
10	Scaled conj. gradient backprop.	1	10	-	0.26	0.76
11	Scaled conj.gradient backprop.	2	8	2	0.26	0.80
12	Scaled conj. gradient backprop.	1	50	-	0.26	0.78
13	Resilient backprop.	1	5	-	0.27	0.77
14	Resilient backprop.	1	10	-	0.25	0.78
15	Resilient backprop.	2	100	1	0.17	0.76

Tabela 17: Resultados para cada RNA - testes realizados com as imagens 720×720 das zonas urbanas utilizando os níveis de cinza como descritores.

Para o ano de passagem de 1986, note que a RNA que apresentou melhor resultado foi a configuração 3, que utilizou o algoritmo de treinamento *Levenberg-Marquardt*, com duas camada ocultas, uma com 50 neurônios e outra com 15.

Para a imagem de 1999, a RNA que apresentou melhor resultado foi a configuração 11, que utilizou o algoritmo de treinamento *Scaled conjugate gradient backpropagation*, com duas camada ocultas, a primeira com 8 neurônios e a segunda com 2.

Assim como foi o caso para as imagens do Cenário01, o algoritmo *Gradient descent backpropagation* apresentou os menores índices kappa.

Nos dois casos a parada do treinamento da RNA aconteceu pelo número de iterações do algoritmo *backpropagation*. Para a passagem de 1986, o maior índice Kappa obtido foi de 0.33 e para a de 1999 de 0.8 (este último considerado um bom índice segundo (GALPARSORO; FERNÁNDEZ, 2001)).

4.2.3 Abordagem02: Média dos níveis de cinza

A Tabela 18 apresenta o índice Kappa para cada configuração de RNA considerada neste trabalho ao utilizar no treinamento descritores gerados a partir da média dos níveis de cinza. São apresentados tanto os resultados referentes à passagem de 1986 quanto de 1999.

Config.	Algoritmo de treinamento	Nro.Camadas	Qtde. Neurônios		Kappa (86)	Kappa (99)
			1a. Cam.	2a. Cam.		
1	Levenberg-Marquardt	1	10	-	0.26	0.77
2	Levenberg-Marquardt	2	10	5	0.26	0.76
3	Levenberg-Marquardt	2	50	15	0.27	0.76
4	Gradient descent backprop.	1	10	-	0.24	0.79
5	Gradient descent backprop.	1	80	-	0.26	0.76
6	Gradient descent backprop.	2	50	2	0.12	0.77
7	Bayesian Regulation backprop.	1	3	-	0.26	0.77
8	Bayesian Regulation backprop.	1	5	-	0.22	0.75
9	Bayesian Regulation backprop.	1	10	-	0.28	0.76
10	Scaled conj. gradient backprop.	1	10	-	0.25	0.78
11	Scaled conj.gradient backprop.	2	8	2	0.25	0.77
12	Scaled conj. gradient backprop.	1	50	-	0.27	0.74
13	Resilient backprop.	1	5	-	0.21	0.77
14	Resilient backprop.	1	10	-	0.26	0.76
15	Resilient backprop.	2	100	1	0.25	0.75

Tabela 18: Resultados para cada RNA - testes realizados com as imagens 720×720 das zonas urbanas utilizando a média dos níveis de cinza como descritores.

Para a passagem de 1986, a RNA que apresentou melhor resultado foi a configuração 9, que utilizou o algoritmo de treinamento *Bayesian Regulation backpropagation*, com apenas uma camada oculta de 10 neurônios. O índice Kappa obtido foi de 0.28. A parada do treinamento da RNA aconteceu pelo número de iterações do algoritmo *backpropagation*.

Por outro lado, a RNA que apresentou melhor resultado para o ano de 1999 foi a configuração 4, que utilizou o algoritmo de treinamento *Gradient descent backpropagation*, com apenas uma camada oculta de 10 neurônios. Neste caso, o melhor índice Kappa obtido foi de 0.79.

Em ambos os casos, a parada do treinamento da RNA aconteceu devido ao número de iterações do algoritmo *backpropagation*.

Em comparação aos resultados da Abordagem01, pode-se afirmar que, se fosse necessário um *trade-off* entre tempo de execução e desempenho, poderia ser considerada apenas a média para definição dos descritores.

4.2.4 Abordagem03: Média e desvio-padrão dos níveis de cinza

A Tabela 19 apresenta o índice Kappa para cada configuração de RNA considerada neste trabalho ao utilizar no treinamento descritores gerados a partir da média e do desvio padrão calculados com base nos níveis de cinza. São apresentados tanto os resultados referentes à passagem de 1986 quanto de 1999.

Config.	Algoritmo de treinamento	Nro.Camadas	Qtde. Neurônios		Kappa (86)	Kappa (99)
			1a. Cam.	2a. Cam.		
1	Levenberg-Marquardt	1	10	-	0.24	0.78
2	Levenberg-Marquardt	2	10	5	0.26	0.77
3	Levenberg-Marquardt	2	50	15	0.27	0.79
4	Gradient descent backprop.	1	10	-	0.15	0.77
5	Gradient descent backprop.	1	80	-	0.19	0.76
6	Gradient descent backprop.	2	50	2	0.20	0.74
7	Bayesian Regulation backprop.	1	3	-	0.19	0.75
8	Bayesian Regulation backprop.	1	5	-	0.21	0.75
9	Bayesian Regulation backprop.	1	10	-	0.20	0.78
10	Scaled conj. gradient backprop.	1	10	-	0.20	0.76
11	Scaled conj.gradient backprop.	2	8	2	0.19	0.78
12	Scaled conj. gradient backprop.	1	50	-	0.23	0.77
13	Resilient backprop.	1	5	-	0.23	0.78
14	Resilient backprop.	1	10	-	0.22	0.75
15	Resilient backprop.	2	100	1	0.22	0.76

Tabela 19: Resultados para cada RNA - testes realizados com as imagens 720×720 das zonas urbanas utilizando a média e o desvio padrão dos níveis de cinza como descritores.

A partir dos dados da Tabela 19, pode-se afirmar que a RNA que apresentou melhor resultado para a passagem de 1986 foi a configuração 3, que utilizou o algoritmo de treinamento *Levenberg-Marquardt*, com duas camadas ocultas, uma com 50 neurônios e outra com 15. O índice Kappa foi de 0.79.

A RNA que apresentou melhor resultado para a passagem de 1999 também foi a configuração 3, que utilizou o algoritmo de treinamento *Levenberg-Marquardt*, com duas camadas ocultas - uma com 50 neurônios e outra com 15. Neste caso, o índice Kappa é de 0.27.

Em ambas os casos, a parada do treinamento da RNA aconteceu pelo número de iterações do algoritmo *backpropagation*. Os resultados são similares àqueles obtidos com apenas a média.

4.2.5 Abordagem04: Valores de reflectância

A Tabela 20 apresenta o índice Kappa para cada configuração de RNA considerada neste trabalho ao utilizar no treinamento descritores gerados a partir dos valores de reflectância. São apresentados tanto os resultados referentes à passagem de 1986 quanto de 1999.

Config.	Algoritmo de treinamento	Nro.Camadas	Qtde. Neurônios		Kappa (86)	Kappa (99)
			1a. Cam.	2a. Cam.		
1	Levenberg-Marquardt	1	10	-	0.18	0.78
2	Levenberg-Marquardt	2	10	5	0.25	0.75
3	Levenberg-Marquardt	2	50	15	0.27	0.75
4	Gradient descent backprop.	1	10	-	0.12	0.31
5	Gradient descent backprop.	1	80	-	0.16	0.29
6	Gradient descent backprop.	2	50	2	0.13	0.14
7	Bayesian Regulation backprop.	1	3	-	0.10	0.77
8	Bayesian Regulation backprop.	1	5	-	0.18	0.77
9	Bayesian Regulation backprop.	1	10	-	0.13	0.76
10	Scaled conj. gradient backprop.	1	10	-	0.19	0.77
11	Scaled conj.gradient backprop.	2	8	2	0.21	0.76
12	Scaled conj. gradient backprop.	1	50	-	0.20	0.76
13	Resilient backprop.	1	5	-	0.17	0.79
14	Resilient backprop.	1	10	-	0.20	0.76
15	Resilient backprop.	2	100	1	0.21	0.76

Tabela 20: Resultados para cada RNA - testes realizados com as imagens 720×720 das zonas urbanas utilizando os valores de reflectância como descritores.

Para as imagens de 1986, a RNA que apresentou melhor resultado foi a configuração 3, que utilizou o algoritmo de treinamento *Levenberg-Marquardt*, com duas camadas ocultas - uma com 50 neurônios e outra com 15.

Pode-se observar também que a RNA que apresentou o melhor resultado para a passagem de 1999 foi a configuração 13, que utilizou o algoritmo de treinamento *Resilient Backpropagation*, com apenas uma camada oculta de cinco neurônios.

Assim como nos casos anteriores, a parada do treinamento da RNA aconteceu pelo número de iterações do algoritmo *backpropagation* em ambas as datas de passagem. Os melhores índices Kappa obtidos foram de 0.27 e 0.79, respectivamente.

Note que o algoritmo *Gradient descent backpropagation* apresentou os menores índices kappa, assim como ocorreu para a Abordagem01. Além disso, os resultados referentes à 1986 apresentaram índices menores quando comparados aos obtidos na Abordagem01 para quase todos os casos.

4.2.6 Abordagem05: Média dos valores de reflectância

A Tabela 21 apresenta o índice Kappa para cada configuração de RNA considerada neste trabalho ao utilizar no treinamento descritores gerados a partir da média calculada a partir dos valores de reflectância. São apresentados tanto os resultados referentes à passagem de 1986 quanto de 1999.

Config.	Algoritmo de treinamento	Nro.Camadas	Qtde. Neurônios		Kappa (86)	Kappa (99)
			1a. Cam.	2a. Cam.		
1	Levenberg-Marquardt	1	10	-	0.16	0.77
2	Levenberg-Marquardt	2	10	5	0.14	0.77
3	Levenberg-Marquardt	2	50	15	0.19	0.77
4	Gradient descent backprop.	1	10	-	0.13	0.76
5	Gradient descent backprop.	1	80	-	0.13	0.78
6	Gradient descent backprop.	2	50	2	0.14	0.79
7	Bayesian Regulation backprop.	1	3	-	0.22	0.77
8	Bayesian Regulation backprop.	1	5	-	0.07	0.75
9	Bayesian Regulation backprop.	1	10	-	0.17	0.76
10	Scaled conj. gradient backprop.	1	10	-	0.18	0.70
11	Scaled conj.gradient backprop.	2	8	2	0.14	0.77
12	Scaled conj. gradient backprop.	1	50	-	0.17	0.74
13	Resilient backprop.	1	5	-	0.19	0.73
14	Resilient backprop.	1	10	-	0.15	0.76
15	Resilient backprop.	2	100	1	0.18	0.76

Tabela 21: Resultados para cada RNA - testes realizados com as imagens 720×720 das zonas urbanas utilizando a média dos valores de reflectância como descritores.

A RNA que apresentou melhor resultado para a passagem de 1896 foi a configuração 7, que utilizou o algoritmo de treinamento *Bayesian Regulation backpropagation*, com apenas uma camada oculta de três neurônios. O índice Kappa foi de 0.22, um valor baixo.

A RNA que apresentou melhor resultado para o ano de 1999 foi a configuração 6, com um índice Kappa de 0.79. Neste caso, foi utilizado o algoritmo de treinamento *Gradient descent backpropagation*, com duas camadas ocultas - uma com 50 neurônios e outra com dois.

Da mesma forma que nos casos anteriores, a parada do treinamento da RNA também aconteceu pelo número de iterações do algoritmo *backpropagation*.

Para as imagens de 1999 não houveram diferenças significativas entre os resultados obtidos aqui e na Abordagem02. Por outro lado, para as imagens de 1986 a Abordagem02 apresentou resultados melhores.

4.2.7 Abordagem06: Média e desvio-padrão dos valores de reflectância

A Tabela 22 apresenta o índice Kappa para cada configuração de RNA considerada neste trabalho ao utilizar no treinamento descritores gerados a partir da média e do desvio padrão calculados a partir dos valores de reflectância. São apresentados tanto os resultados referentes à passagem de 1986 quanto de 1999.

Config.	Algoritmo de treinamento	Nro.Camadas	Qtde. Neurônios		Kappa (86)	Kappa (99)
			1a. Cam.	2a. Cam.		
1	Levenberg-Marquardt	1	10	-	0.18	0.78
2	Levenberg-Marquardt	2	10	5	0.18	0.79
3	Levenberg-Marquardt	2	50	15	0.16	0.78
4	Gradient descent backprop.	1	10	-	0.04	0.78
5	Gradient descent backprop.	1	80	-	0.10	0.77
6	Gradient descent backprop.	2	50	2	0.12	0.77
7	Bayesian Regulation backprop.	1	3	-	0.20	0.78
8	Bayesian Regulation backprop.	1	5	-	0.21	0.78
9	Bayesian Regulation backprop.	1	10	-	0.20	0.77
10	Scaled conj. gradient backprop.	1	10	-	0.22	0.76
11	Scaled conj.gradient backprop.	2	8	2	0.21	0.77
12	Scaled conj. gradient backprop.	1	50	-	0.19	0.78
13	Resilient backprop.	1	5	-	0.20	0.78
14	Resilient backprop.	1	10	-	0.18	0.74
15	Resilient backprop.	2	100	1	0.20	0.77

Tabela 22: Resultados para cada RNA - testes realizados com as imagens 720×720 das zonas urbanas utilizando a média e o desvio padrão dos valores de reflectância como descritores.

Para o ano de 1986, a RNA que apresentou melhor resultado foi a configuração 10, que utilizou o algoritmo de treinamento *Scaled conjugate gradient backpropagation*, com apenas uma camada oculta de 10 neurônios.

Para a passagem de 1999, a RNA que apresentou melhor resultado foi aquela associada à configuração 2, que utilizou o algoritmo de treinamento *Levenberg-Marquardt*, com apenas duas camadas ocultas - uma com 10 neurônios, e outra com cinco.

Em ambos os casos a parada do treinamento da RNA também aconteceu pelo número de iterações do algoritmo *backpropagation*.

Para as imagens de 1999 não houveram diferenças significativas entre os resultados obtidos aqui e na Abordagem02. Por outro lado, para as imagens de 1986 a Abordagem02 apresentou resultados melhores.

4.2.8 Discussões

Os resultados obtidos no processo de classificação das imagens registradas em 1999 foram bem melhores que os registrados em 1986, como mostram os dados das Tabelas 23 e 24. Os índices Kappa referem-se, respectivamente, as arquiteturas das RNAs que apresentaram melhor desempenho em cada uma das abordagens para os testes com as imagens 720×720 registradas em 1986 e em 1999.

Abordagem	Algoritmo de treinamento	Nro.Camadas	Qtde. Neurônios		Kappa
			1a. Camada	2a. Camada	
1	Levenberg-Marquardt	2	50	15	0.33
2	Bayesian Regulation backpropagation	1	10	-	0.28
3	Levenberg-Marquardt	2	50	15	0.27
4	Levenberg-Marquardt	2	50	15	0.27
5	Bayesian Regulation backpropagation	1	3	-	0.22
6	Scaled conjugate gradient backpropagation	1	10	-	0.22

Tabela 23: Melhores desempenhos das RNAs no processo de classificação das cenas urbanas em cada uma das abordagens para as imagens 720×720 de 1986.

Abordagem	Algoritmo de treinamento	Nro.Camadas	Qtde. Neurônios		Kappa
			1a. Camada	2a. Camada	
1	Scaled conjugate gradient backpropagation	2	8	2	0.8
2	Gradient descent backpropagation	1	10	-	0.79
3	Levenberg-Marquardt	2	50	15	0.79
4	Resilient Backpropagation	1	5	-	0.79
5	Gradient descent backpropagation	2	50	2	0.79
6	Levenberg-Marquardt	2	10	5	0.79

Tabela 24: Melhores desempenhos das RNAs no processo de classificação das cenas urbanas em cada uma das abordagens para as imagens 720×720 de 1999.

Como já abordado na primeira seção deste capítulo, um dos principais fatores que contribuiu para essa diferença de acerto na classificação foi a captura de uma massa de ar em todas as bandas do registro de 1986. Por essa massa de ar ter características semelhantes às zonas urbanas (considerando os descritores abordados neste trabalho), as RNAs não conseguiram diferenciar cada uma dessas regiões.

Por outro lado, em todos os testes com as imagens de 1986 e 1999 foi identificada uma grande dificuldade das RNAs em diferenciar as áreas com areia das zonas urbanas, por também apresentarem características semelhantes.

Assim como nos testes para o Cenário01, a utilização dos níveis de cinza e dos níveis de reflectância apresentou resultados muito semelhantes para o mesmo tipo de informação passada para as RNAs (valores individuais, média dos valores da vizinhança, e média e desvio-padrão dos valores da vizinhança). Ainda, ao contrário do Cenário01, o modo com que as informações

foram tratadas para serem passadas para a RNA também não influenciou significativamente os resultados. Portanto, apesar da utilização dos valores dos níveis de cinza ter sido a abordagem que apresentou melhor desempenho para os testes com as imagens das duas datas, a homogeneidade dos resultados dos testes no Cenário02 foi bem maior do que no Cenário01.

Como a abordagem 1 (utilização dos níveis de cinza) foi a que apresentou melhor desempenho na classificação das imagens 720×720 de 1986, esta foi utilizada para classificar a imagem inteira. Nela, foi utilizada uma RNA com algoritmo de treinamento *Levenberg-Marquardt* e com duas camadas ocultas, uma com 50 e outra com 15 neurônios. A imagem classificada pode ser observada na Figura 32(a).


Para a classificação das imagens 720×720 de 1999, a abordagem 1 também foi a que apresentou melhor desempenho. Ela utilizou uma RNA com algoritmo de treinamento *Scaled conjugate gradient backpropagation* e com duas camadas ocultas, uma com oito e outra com dois neurônios. A Figura 32(b) mostra o resultado da classificação ao considerar estes parâmetros.

Como exposto anteriormente, para o Cenário02, as classificações das imagens inteiras de 1986 e 1999 não foram avaliadas quantitativamente com relação à taxa de acerto. Isso se deu por não ter sido criada uma imagem de referência (utilizada na comparação com a imagem classificada) para a imagem completa (isso foi feito apenas para as imagens de dimensão 720×720 pixels). Contudo, a partir de uma análise qualitativa é possível perceber os mesmos problemas existentes na classificação das imagens menores, onde para as imagens de 1986 a massa de ar foi erroneamente classificada como cena urbana, e para as imagens das duas datas os locais com solo exposto também foram classificados de maneira incorreta.

Contudo, as RNAs mostraram-se uma ferramenta promissora para a análise de áreas urbanas em imagens de sensoriamento remoto. Contudo, etapas de pré-processamento das imagens poderiam melhorar ainda mais o resultado final de classificação, bem como a utilização de descritores mais robustos.



(a)



(b)

Figura 32: Classificação da imagem completa considerando a configuração com melhor desempenho (a) 1986 e (b) 1999.

Fonte: Autoria própria.

5 CONCLUSÕES

O emprego de RNAs para classificar imagens de satélite tem sido um tema muito abordado nos trabalhos acadêmicos dos últimos anos. Muitas abordagens de análise automática de imagens consideram apenas o conteúdo espectral dos objetos analisados. AO trabalhar com regiões mais complexas, como zonas cafeeiras e cenas urbanas, que apresentam diferentes fatores ambientais e fenológicos, as RNAs são uma boa alternativa por possibilitarem a utilização de outros fatores no processo de classificação.

No Cenário01, que envolveu a classificação de zonas cafeeiras, o teste que obteve melhor resultado classificou 93% da imagem com sucesso, correspondendo a um índice Kappa de 0.81. Assim, a metodologia proposta para este cenário obteve sucesso em discriminar as classes de saída utilizando apenas parâmetros espectrais para treinar a RNA. Além disso, o erro de classificação ocorreu principalmente em regiões de borda entre as zonas de café e as regiões de mata, o que poderia ser mitigado utilizando um pré-processamento das imagens para atenuar as bordas.

Já no cenário 2, de identificação de cenas urbanas, o teste que obteve melhor resultado para as sub-imagens de 720×720 pixels foi aquele associado às imagens de 1999. A taxa de acerto foi de 90%, correspondente a um índice Kappa de 0.80. Contudo, a metodologia proposta não teve um resultado satisfatório para as imagens de 1986. Neste contexto, a utilização de outros parâmetros não-espectrais para treinar a RNA pode melhorar o resultado, sendo esta uma sugestão para trabalhos futuros. Além disso, poderia ser quantificada a taxa de acerto da classificação das imagens inteiras a partir da criação de uma imagem de referência para esta.

O desenvolvimento do trabalho contribuiu na consolidação das técnicas que melhor se ajustam para solucionar problemas semelhantes, ou seja, que o foco seja a identificação de regiões de interesse.

5.1 PROPOSTAS DE CONTINUIDADE

A seguir, são apresentadas algumas sugestões de propostas de continuidade do presente trabalho:

- Utilizar outros descritores mais complexos na extração de características texturais das imagens, como os filtros de Gabor;
- Utilizar outros atributos das regiões a serem analisadas para o treinamento das RNAs, como forma, relevo (altitude, orientação de vertente e declive), entre outros;
- Aplicar técnicas de processamento de imagens nas diferentes bandas como uma pré-etapa de classificação com o intuito melhorar o desempenho das RNAs;
- Realizar outros testes com diferentes arquiteturas de RNAs, além de variar outros parâmetros, como função de ativação e taxa de aprendizado.

REFERÊNCIAS

- ANDRADE, A. F.; BOTELHO, M. F.; CENTENO, J. A. S. Classificação de imagens de alta resolução integrando variáveis espectrais e forma utilizando redes neurais artificiais. **Simpósio Brasileiro de Sensoriamento Remoto (SBSR), volume 11, Belo Horizonte. São José dos Campos: INPE**, p. 265–272, 2003.
- ANDRADE, L. N. et al. Aplicação de redes neurais artificiais (rna) na análise e classificação de áreas cafeeiras da região de machado-mg. **IX Congreso Latinoamericano y del Caribe de Ingeniería Agrícola - XXXIX Congresso Brasileiro de Engenharia Agrícola (CLIA/CONBEA). Vitória - ES**, 2010.
- ANDRADE, L. N. de. **Redes Neurais artificiais aplicadas na identificação automática de áreas cafeeiras em imagens de satélite**. Dissertação (Mestrado) — Universidade Federal de Minas Gerais. Departamento de Ciência da Computação., Belo Horizonte, 2011.
- BELUCO, A. **Classificação de imagens de sensoriamento remoto baseada em textura por redes neurais**. Dissertação (Mestrado) — Universidade Federal do Rio Grande do Sul. Centro Estadual de Pesquisa em Sensoriamento Remoto e Meteorologia - CEP SRM, Porto Alegre, 2002.
- BERNARDES, T. et al. Avaliação da acurácia do mapeamento do uso da terra no complexo serra negra, patrocínio, mg. **Simpósio Brasileiro de Sensoriamento Remoto - SBSR, volume 13, Florianópolis.**, 2007.
- BESSA, J. C. M. de. **Utilização de imagens de sensoriamento remoto de alta e média resoluções espaciais na geração de informação sobre ocupações urbanas como subsídio ao planejamento**. [S.l.], 2005.
- BORSOI, V. **Análise multitemporal da dinâmica da expansão urbana em áreas de proteção permanente no município Caçapava-SP**. [S.l.], 2008.
- CAMPOS, M. **Processamento de Imagens: MATLAB e OpenCV**. 01 2008. Disponível em: <<http://www.verlab.dcc.ufmg.br>>.
- CARVALO, L. M. T. **Mapping and monitoring forest remnants: a multiscale analysis of spatio-temporal data**. Tese (Doutorado) — Wageningen University, 2001.
- CHOREN, R.; GOLDSCHIMIDT, R.; RIBEIRO, C. **Métodos para Previsão de Séries Temporais e suas Tendências de Desenvolvimento**. [S.l.], 2009.
- CRÓSTA, A. P. **Processamento digital de imagens de sensoriamento remoto**. Campinas - São Paulo: IG-UNICAMP, 1993.
- DOUGHERTY, E. R. **An introduction to morphological image processing**. [S.l.]: SPIE Optical Engineering Press, 1992.

ENVI - Ferramentas Avançada para Processamento Espectral. Disponível em: <<http://www.envi.com.br/>>. Acesso em: 08 ago. 2013.

FIGUEIREDO, D. **Conceitos Básicos de Sensoriamento Remoto**. 2005.

FLORENZANO, T. G. **Imagens de Satélite para Estudos Ambientais**. São Paulo: Oficina de Textos., 2002.

GALPARSORO, L. U.; FERNÁNDEZ, S. P. **Medidas de concordancia: el índice Kappa**. 2001. Disponível em: <<http://www.fisterra.com/mbe/investiga/kappa/kappa.htm>>. Acesso em: 06 fev. 2014.

GOLDSCHMIDT, R. R.; PASSOS, E. P. L. **Data Mining: Um Guia Prático - Conceitos, Técnicas, Ferramentas, Orientações e Aplicações**. Rio de Janeiro: Editora Campos., 2005.

GONZALEZ, R. C.; WOODS, R. E. **Digital Image Processing**. [S.l.]: Prentice Hall, 2001.

GONZALEZ, R. C.; WOODS, R. E. **Processamento Digital de Imagens**. São Paulo: Pearson Education do Brasil Ltda., 2009.

GURTLER, S. et al. Planilha eletrônica para o cálculo da reflectância em imagens tm e etm+ landsat. **Revista Brasileira de Cartografia, Rio de Janeiro, v. 57, n. 2**, p. 162–167, 2005.

HAYKIN, S. **Redes Neurais - princípios e prática**. Porto Alegre: Editora Bookman, 2001.

INPE. Catálogo de imagens. <Http://www.dgi.inpe.br/CDSR/>. 2013.

JAIN, A. K. **Fundamentals of Digital Image Processing**. [S.l.: s.n.], 1989.

JAIN, R. K. R.; SCHUNCK, B. G. **Machine Vision**. [S.l.: s.n.], 1995.

JAIN, R. P. W. D. A. K.; MAO, J. Statistical pattern recognition: A review. **IEEE Transactions On In Pattern Analysis and Machine Intelligence**, v. 22, 2000.

JARS, J. A. of R. S. **Remote Sensing Note**. 1999.

LOMBARDI, R. J. R. **Estudo da recorrência de queimadas e permanências de cicatrizes do fogo em áreas selecionadas do cerrado brasileiro, utilizando imagens TM/Landsat**. Dissertação (Mestrado) — Instituto Nacional de Pesquisas Espaciais - INPE., 2005.

MARQUES, H. S. **Uso de geotecnologias no estudo das relações entre solos, orientação de vertentes e o comportamento espectral de áreas cafeeiras em Machado, Minas Gerais**. Dissertação (Mestrado) — Universidade Federal de Lavras., 2003.

MARTINS, A. C. G.; SIMÕES, A. S.; PRADO, G. I. Classificação de texturas usando redes neurais artificiais e o modelo de spot noise. **Anais do Encontro Nacional de Inteligência Artificial - ENIA 2007**, 2007.

MENESES, P. R.; ALMEIDA, T. d. **Introdução ao Processamento de Imagens de Sensoriamento Remoto**. Brasília: Universidade de Brasília - UnB, 2012.

MUSCI, M. **Representação Digital de Imagens**. Disponível em: <<http://www.musci.com.br/multimedia/ImagensDesenhos3D.pdf>>. Acesso em: 08 fev. 2014.

- NISHIDA, W. **Uma rede neural artificial para classificação de imagens multiespectrais de sensoriamento remoto.** Dissertação (Mestrado) — Universidade Federal de Santa Catarina - UFSC., Florianópolis, 1998.
- NISHIDA, W.; BASTOS, L. C. Classificação de imagens de sensoriamento remoto utilizando uma rede neural artificial com função de base radial. **Simpósio Brasileiro de Sensoriamento Remoto - SBSR, 9ed.**, 1998.
- OLIVEIRA, I. M.; ZEILHOFER, P.; SANTOS, E. S. Segmentação para classificação de áreas urbanas a partir de imagem digital do landsat7/etm+: Estudo de caso ? cuiabá-mt. **Anais XIII Simpósio Brasileiro de Sensoriamento Remoto, Florianópolis, Brasil, 21-26 abril 2007, INPE**, p. 6011–6018, 2007.
- PACHECO, R. C. S. **Hybrid Intelligent System for Prediction and Solving Financial Problems of Small Retail Firms.** Tese (Doutorado) — Universidade Federal de Santa Catarina - UFSC. Programa de Pós-Graduação em Engenharia de Produção - PPGEP, 1996.
- PEREIRA, L. A. A. **Classificação automática de áreas cafeeiras em imagens de satélite, utilizando Redes Neurais Artificiais.** Monografia (Graduação) — Universidade Federal de Lavras., 2013.
- QUINTANILHA, J. A.; OHATA, A. T. O uso de algoritmos de clustering na mensuração da expansão urbana e detecção de alterações na região metropolitana de são paulo. **Anais do XII Simpósio Brasileiro de Sensoriamento Remoto, Goiânia - GO**, p. 647–655, 2005.
- REZENDE, S. O. **Sistemas Inteligentes: Fundamentos e Aplicações.** 1st.. ed. São Paulo.: Editora Manole., 2003.
- RIBEIRO, S. R. A. et al. Extração de profundidade mediante redes neurais artificiais e modelo de regressão usando 85 dados de levantamento gps e de imagens ikonos ii - estudo comparativo. **Engevista, volume 7.**, 2005.
- SOUZA, V. C. O. et al. Mapeamento de áreas cafeeiras por classificação automática utilizando medidas texturais. **Simpósio de Pesquisa dos Cafés do Brasil - SPCB, volume 6, Vitória - ES**, 2009.
- TEIXEIRA, S. G. **Análise de imagens de sensores remotos orbitais para mapeamento de ambientes costeiros tropicais e de índices de sensibilidade ambiental ao derramamento de óleo no Golfão Maranhense.** Dissertação (Mestrado) — Universidade Federal do Pará - UFPA., Belém, 2006.
- VARELLA, C. A. A. et al. Determinação da cobertura do solo por análise de imagens e redes neurais. **Revista Brasileira de Engenharia Agrícola e Ambiental**, 2002.
- VERNON, D. **Machine Vision: Automated Visual Inspection and Robot Vision.** [S.l.]: Prentice Hall, 1991.
- VIEIRA, T. et al. Crop parameters and spectral response of coffee (coffea arábica.) areas within the state of minas gerais, brazil. **Coffee Science**, 2006.
- VIEIRA, T. G. C.; LACERDA, W. S.; BOTELHO, T. G. Mapeamento de áreas cafeeiras utilizando redes neurais artificiais: Estudo de caso na região de três pontas, minas gerais. **Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, 2009.