

MARCELO GUIMARÃES RIBEIRO

**INTEGRAÇÃO DE DADOS ESPECTRAIS E ALTIMÉTRICOS
PARA A CLASSIFICAÇÃO DE MATERIAIS DE TELHADOS
COMO SUBSÍDIO A ESTUDOS DE POLUIÇÃO URBANA.**

Dissertação apresentada ao Curso de Pós-Graduação
em Ciências Geodésicas da Universidade Federal do
Paraná, como requisito parcial à obtenção do grau e
título de Mestre em Ciências Geodésicas.

Orientador: Prof. Dr. Jorge Antonio Silva Centeno
Co-Orientador: Prof. Dr. Hideo Araki.

Curitiba
Novembro, 2008

Livros Grátis

<http://www.livrosgratis.com.br>

Milhares de livros grátis para download.

*“A mente que se abre a uma nova idéia, jamais
voltará ao seu tamanho original”*

Albert Einstein.

*Dedico este trabalho, aos
meus amados pais Juarez e
Mariluz, que nunca
economizaram esforços, em
sua luta incessante para
proporcionar todo o
conhecimento e educação aos
seus filhos.*

Agradecimentos

Existem pessoas que nos deixam felizes pelo simples fato de terem cruzado a estrada da nossa vida. Todas elas deixam sua marca, por mais efêmera que seja a sua passagem. Neste espaço, agradeço a todos que a sua maneira contribuíram para o andamento deste trabalho, em especial à:


- Aos meus pais, pelo incentivo, cobranças e carinho, sem vocês não teria chegado ao fim desta jornada.
- Ao professor doutor Jorge Antonio Silva Centeno, meu orientador e amigo, agradeço por sua inestimável parcela para o engrandecimento desta pesquisa, seja com idéias ou simplesmente como bom ouvinte.
- Ao professor doutor Cristovam Vicente Scapulatempo Fernandes, pelo apoio e incentivo para ingressar no programa de pós-graduação.
- À minha noiva Vaniely, pelo apoio e compreensão nos fim de semanas dedicado a este trabalho.
- À Universidade Federal do Paraná por toda a estrutura cedida para os meus estudos na graduação e pós-graduação.
- À empresa Esteio e ao LACTEC pelos dados cedidos.
- Ao DER-PR (Departamento de Estradas de Rodagens) na pessoa do engenheiro Marcus Vinicius Talamini, por todo o apoio para a conclusão deste trabalho.
- As minhas amigas da pensão: Aninha, Camila e Jordana, pela companhia agradável durante o decorrer do meu curso.
- À CAPES pelo fomento em forma de bolsa e ao CNPq pelo projeto de pesquisa.

TERMO DE APROVAÇÃO

MARCELO GUIMARÃES RIBEIRO


"INTEGRAÇÃO DE DADOS ESPECTRAIS E ALTIMÉTRICOS PARA A
CLASSIFICAÇÃO DE MATERIAIS DE TELHADOS COMO SUBSÍDIO A ESTUDOS
DE POLUIÇÃO URBANA"

Dissertação nº 225 aprovada como requisito parcial do grau de Mestre no Curso de Pós-Graduação em Ciências Geodésicas, Setor de Ciências da Terra da Universidade Federal do Paraná, pela seguinte banca examinadora:




Orientador:

Prof. Dr. Jorge Antonio Silva Centeno
Departamento de Geomática, UFPR



Prof. Dr. Christel Lingnau
Departamento de Ciências Florestais, UFPR



Prof. Dr. Alzir Felipe Buffara Antunes
Departamento de Geomática, UFPR

.....	IV
1	V
LISTA DE FIGURAS	VII
LISTA DE TABELAS	IX
RESUMO	XI
ABSTRACT	XII
2 INTRODUÇÃO	1
3 OBJETIVOS	3
4 JUSTIFICATIVA	4
5 ESTADO DA ARTE	5
5.1 POLUIÇÃO AMBIENTAL	5
5.1.1 POLUIÇÃO URBANA.....	5
5.1.2 ESCOAMENTO SUPERFICIAL.....	6
5.1.3 POLUIÇÃO HÍDRICA.....	7
5.2 MATERIAIS POLUENTES	8
5.2.1 A POLUIÇÃO CONFORME O TIPO DE MATERIAL.....	10
5.3 SENSORIAMENTO REMOTO	12
5.3.1 SENSORIAMENTO REMOTO E A POLUIÇÃO.....	12
5.4 SISTEMA LASER SCANNER	14
5.5 INTEGRAÇÃO DOS DADOS	15

6 MATERIAL E MÉTODOS.....	17
6.1 ÁREAS DE ESTUDO.....	18
6.2 PREPARAÇÃO DOS DADOS.....	19
6.2.1 PRÉ-PROCESSAMENTO DOS DADOS LASER SCANNER.....	19
6.2.2 CORREÇÃO GEOMÉTRICA DA IMAGEM DE SATÉLITE.....	21
6.2.3 FUSÃO DAS IMAGENS.....	22
6.3 ROTACÃO DO ESPAÇO RGB.....	24
6.4 INTEGRAÇÃO DOS DADOS.....	24
6.5 SEGMENTAÇÃO E CLASSIFICAÇÃO.....	25
6.5.1 SEGMENTAÇÃO MULTI-RESOLUÇÃO.....	26
6.5.1.1 Segmentação orientada a regiões.....	27
6.5.1.2 NÍVEIS DE SEGMENTAÇÃO.....	28
6.5.2 SELEÇÃO DOS ATRIBUTOS.....	29
6.5.2.1 CODIFICAÇÃO E DEFINIÇÃO DA POPULAÇÃO.....	30
6.5.2.2 FUNÇÃO OBJETIVO.....	30
6.5.2.3 ELITISMO, CRUZAMENTO E MUTAÇÃO.....	31
6.5.3 MÉTODOS DE CLASSIFICAÇÃO.....	33
6.5.3.1 MÉTODO DA DISTÂNCIA MÍNIMA.....	33
6.5.3.2 MÉTODO DA MÁXIMA VEROSSIMILHANÇA.....	34
6.5.3.3 REDES NEURAS ARTIFICIAIS.....	35
6.5.3.3.1 Funcionamento da Rede Neural Artificial.....	37
6.5.4 AVALIAÇÃO DA CLASSIFICAÇÃO.....	39
7 RESULTADOS E DISCUSSÕES.....	42
7.1 PREPARAÇÃO DOS DADOS.....	42
7.2 ROTACÃO DO ESPAÇO DE CORES.....	45
7.2.1 IMAGEM QUICKIBIRD II.....	45
7.2.2 ORTOFOTO.....	47
7.2.2.1 DISTÂNCIA MÍNIMA.....	48
7.2.2.2 MÉTODO DA MÁXIMA VEROSSIMILHANÇA.....	49
7.3 INTEGRAÇÃO ESPECTRAL E ALTIMÉTRICA.....	50
7.3.1.1 CLASSIFICAÇÃO BASEADA NO ELEMENTO PIXEL.....	50
7.4 SEGMENTAÇÃO MULTIRESOLUÇÃO.....	52
7.5 SELEÇÃO DOS DESCRITORES.....	54
7.5.1 – FUNÇÃO OBJETIVO E NÚMERO DE DESCRITORES.....	54
7.5.2 ALGORITMOS GENÉTICOS.....	56
7.6 CLASSIFICAÇÃO COM REDES NEURAS ARTIFICIAS.....	57
7.6.1.1 DEFINIÇÃO DA ARQUITETURA DA RNA.....	57
8 CONCLUSÕES E RECOMENDAÇÕES.....	61
REFERÊNCIAS.....	63

LISTA DE FIGURAS

FIGURA 1 – DIFERENÇAS ENTRE O HIDROGRAMA EM UMA BACIA URBANA E RURAL.....	7
FIGURA 2 – VARREDURA DO SISTEMA LASER AEROTRANSPORTADO FONTE (SWANSEA GEOGRAPHER, 2007).....	14
FIGURA 3 – ESTRUTURA DA METODOLOGIA PROPOSTA.....	18
FIGURA 4 – EXEMPLO DE UM MDSN.....	20
FIGURA 5 – REDE HIERÁRQUICA DE CLASSIFICAÇÃO.	27
FIGURA 6 – CRUZAMENTO E MUTAÇÃO DOS ALGORITMOS GENÉTICOS.....	32
FIGURA 7 – ARQUITETURA DE UMA REDE NEURAL ARTIFICIAL).....	38
FIGURA 8 – VERDADE DE CAMPO.....	40
FIGURA 9 – MDS ORIGINAL.....	42
FIGURA 10 – MDS CORRIGIDO.....	43
FIGURA 11 – DENSIDADE DAS DIFERENTES FAIXAS DE VÔO.....	44
FIGURA 12 – EXEMPLO DOS DADOS DE ENTRADA: A. ORTOFOTO B. NDVI C. MDSN.....	45

FIGURA 13 – EXEMPLO DA ROTAÇÃO DO ESPAÇO DE CORES. A) RGB B) RGB ROTACIONADO C) IRB D) IRB ROTACIONADO.....	46
FIGURA 14 – RECORTE DA ORTOFOTO.....	47
FIGURA 15 – CLASSIFICAÇÃO PELA DISTÂNCIA MÍNIMA. A) SEM ROTAÇÃO B) COM ROTAÇÃO.....	48
FIGURA 16 – CLASSIFICAÇÃO PELO MÉTODO DA MÁXIMA VEROSSIMILHANÇA.....	49
FIGURA 17– MATRIZ DE CONFUSÃO DA COMBINAÇÃO RGB+MDSN.....	51
FIGURA 18 – EXEMPLO DAS AMOSTRAS COLETADAS.....	52
FIGURA 19 – GRÁFICO APTIDÃO X NÚMERO DE DESCRITORES.....	55
FIGURA 20 – ÁREA RECORTADA PARA CLASSIFICAÇÃO.....	58
FIGURA 21 – SAÍDA DA CLASSIFICAÇÃO PELAS RNA'S.....	59
FIGURA 22 – MAPA TEMÁTICO COM O POTENCIAL POLUIDOR.....	60

LISTA DE TABELAS

TABELA 1 - ORIGEM DOS POLUENTES GERADOS EM RODOVIAS, ADAPTADO DE LEITÃO (2005).....	9
TABELA 2 - DADOS DISPONÍVEIS.....	19
TABELA 3 – CONFIGURAÇÃO DAS BANDAS APÓS A INTEGRAÇÃO DOS DADOS.	25
TABELA 4 – PARÂMETROS UTILIZADOS NA SEGMENTAÇÃO.....	28
TABELA 5 – MAGNITUDE DO ÍNDICE KAPPA. ADAPTADO DE LANDIS & LOCH (1977).....	41

TABELA 6 – DENSIDADE DOS DADOS LASER SCANNER.....	44
TABELA 7 – CLASSIFICAÇÕES BASEADAS NO PIXEL: ACURÁCIA GLOBAL.....	46
TABELA 8 – COMPARAÇÃO ENTRE AS CLASSIFICAÇÕES, USANDO O CLASSIFICADOR DA DISTÂNCIA MÍNIMA.....	48
TABELA 9 – CLASSIFICAÇÃO PELA MÁXIMA VEROSSIMILHANÇA.....	49
TABELA 10 – RESUMO DA CLASSIFICAÇÃO BASEADA NO PIXEL.....	50
TABELA 11 – EXEMPLO DOS DESCRITORES EXPORTADOS PELO ECOGNITION.....	53
TABELA 12 – ANÁLISE DA FUNÇÃO OBJETIVO.....	54
TABELA 13 – DESCRITORES SELECIONADOS: ARQUIVO 5BANDAS;.....	56
TABELA 14 – DESCRITORES SELECIONADOS: ARQUIVO RGB ROTACIONADO	57
TABELA 15 – DESCRITORES SELECIONADOS: ARQUIVO INFRAVERMELHO ROTACIONADO.....	57
TABELA 16 – ARQUITETURA E ACURÁCIA DA RNA.....	58
TABELA 17 – ÁREA POTENCIALMENTE POLUIDORA.....	60

RESUMO

A qualidade da água de escoamento superficial, em ambiente urbano, tem apresentado uma crescente preocupação da comunidade científica e das autoridades responsáveis pela gestão das cidades. Neste contexto as técnicas de sensoriamento remoto se inserem como importante ferramenta de auxílio para que técnicos em hidrologia possam avaliar e definir o potencial poluidor de áreas urbanas. A base de dados sobre as áreas urbanas é formada através da integração de dados espectrais com informação altimétrica. Para tanto, diferentes sensores são utilizados, como imagens de satélite, fotografias aéreas e LIDAR (*Light Detection And Ranging*). A metodologia proposta prevê uma análise voltada ao objeto, com a utilização de uma segmentação multiresolução FNEA (*Fractal Net Evolution Approach*). Objetivando-se uma segmentação das imagens mais eficiente foi testada uma rotação do espaço de cores. Para se evitar o problema da dimensionalidade devido ao grande número de descritores de cada segmento gerado no processo, são usados os Algoritmos Genéticos para selecionar os atributos mais eficientes resultantes do processo de segmentação. A classificação digital é realizada através do uso das Redes Neurais Artificiais. Resultando deste processo uma caracterização temática das feições presentes na cena urbana, principalmente dos materiais constituintes dos telhados das edificações que são elementos chave no entendimento da poluição do escoamento superficial.

ABSTRACT

The scientific community and the management authorities of the cities show special concern with water quality in urban environment, especially runoff. Remote sensing became an important tool in this context, helping hydrologists to evaluate and estimate the polluting potential of urban areas. Within an urban environment, a great amount of rain is intercepted by roofs and streets, covered by different materials with different pollution potential. In this document, a study aimed at the detection and mapping of different material within an urban scene is presented. For this purpose, a database, composed by spectral data and altimetric information, is used. Because different sensors are used, as satellite images, photographs and LIDAR (Light Detection And Ranging). The approach is based on an object oriented classification, the FNEA segmentation (Fractal Net Evolution Approach). In order to improve the segmentation, a spectral rotation was also tested. Genetic Algorithms are also used to select the most efficient features for the segmentation and classification. The digital classification is carried out using Artificial the Neural Nets. The result is a thematic map, describing the spatial distribution of different materials within the scene, according to its pollution potential, specially materials used in roofs.

2 INTRODUÇÃO

A água é um recurso natural, essencial para a vida na terra, todos os seres vivos dependem dela para a sua sobrevivência. Embora a quantidade de água no planeta esteja se mantendo constante ao longo dos tempos, o produto “água” vem se tornando escasso. A responsabilidade deste fato recai sobre o ser humano e as atividades realizadas por ele para manter o seu modo de vida. Estima-se que em pouco tempo este recurso possa vir a se tornar motivo de conflito entre os povos.

Neste sentido, medidas de manutenção e até mesmo recuperação da qualidade dos corpos de água se tornam necessárias. O planejamento das ações da sociedade deve levar em conta a preservação das condições ambientais, para garantir a oferta deste bem no futuro.

As principais pressões sobre o meio ambiente ocorrem no ambiente urbano, onde o acúmulo de indivíduos em espaços reduzidos acaba por gerar uma série de problemas ambientais. Pode-se destacar a disposição final do lixo sólido, produzido diariamente, como um dos principais problemas enfrentados pelos administradores destes centros urbanos. Outro problema é a demanda cada vez maior por água potável, fazendo com que empresas fornecedoras de água tenham que realizar a captação em locais excessivamente distantes dos pontos de consumo.

Estes problemas acima citados são de fácil percepção da sociedade, isto é, o cidadão consegue visualizar, de uma forma simples, a necessidade de medidas de mitigação para resolver a situação.

Por outro lado existem certos riscos ambientais que não são de fácil percepção. A busca incessante por conforto é uma característica da sociedade ocidental. Neste contexto edificações são construídas para proteção contra intempéries, estradas são pavimentadas para proporcionar um rolamento agradável aos veículos. Estes exemplos trazem consigo uma característica em

comum, a cobertura natural do solo é substituída por materiais sintéticos que impermeabilizam o solo.

A impermeabilização do solo acaba por incrementar o escoamento superficial, aumentando com isso o poder destrutivo das enxurradas e enchentes. Além disso, um maior volume de água, associado com uma maior velocidade, acaba por acelerar o processo de lixiviação dos materiais da superfície do solo. Assim uma série de poluentes como óleos e graxas de automóveis, substâncias orgânicas proveniente de deposição fecal de animais e metais pesados dos materiais sintéticos utilizados na fabricação de telhas ou usados na pavimentação de vias, acabam por poluir os corpos receptores que drenam a água do escoamento superficial.

Para se combater este problema se faz necessário um conhecimento a respeito da distribuição espacial dos materiais que compõem a cobertura dos solos, deve-se conhecer os caminhos percorridos pela água durante o seu escoamento, e as substâncias que ela entra em contato neste percurso. Também são necessárias informações a respeito da qualidade atual da água dos corpos receptores.

O profissional de recursos hídricos necessita então de informações atualizadas e de qualidade para lidar com este problema. A utilização de dados proveniente de sensores remotos aparece como uma saída de custo reduzido e de rápida aquisição quando comparada aos métodos de investigação *in situ*.

A possibilidade de utilização informação integrada de dados multiespectrais e tridimensionais aparece como uma alternativa promissora nesta área. Países desenvolvidos como os da Europa e América do norte têm feito uso desta tecnologia para avaliar o efeito da atividade humana nos recursos hídricos superficiais e subterrâneos.

Nesta pesquisa técnicas de sensoriamento remoto foram utilizadas para fazer o uso integrado de dados de diferentes sensores, com diferentes resoluções, para determinar a ocorrência e distribuição espacial dos diferentes materiais na cena urbana.

3 OBJETIVOS

O objetivo principal deste trabalho é fazer o uso integrado de dados altimétricos de um sensor laser scanner aerotransportado e imagens, fotográficas e orbitais, na região do visível e infravermelho próximo para a caracterização do potencial de produção de poluição difusa em áreas urbanas.

Como objetivos específicos têm-se:

- Definir uma metodologia para classificação automática de feições da cena urbana;
- Avaliar o potencial do uso da rotação do espaço RGB para a caracterização das diferentes feições da cena urbana;
- Avaliar o uso de Algoritmos Genéticos para a seleção de descritores de forma, espectrais e textura;
- Implementar rotinas computadorizadas para realização da classificação utilizando Redes Neurais Artificiais;
- Elaboração de um mapa temático de uso e cobertura do solo, onde o tipo de material de cada elemento seja caracterizado e a distribuição espacial de diferentes materiais seja visível.

4 JUSTIFICATIVA

No ano 2000, a União Européia implementou a *water framework directive*. Esta regulamentação obriga que todo estado membro da organização estude o impacto das atividades humanas sobre as condições das águas de superfície e subterrâneas, (LEMP E WEIDNER, 2004). Um importante assunto, neste contexto, diz respeito à mensuração e espacialização das fontes de poluentes no ambiente urbano.

O ambiente urbano é caracterizado por apresentar uma grande quantidade de materiais heterogêneos que guardam complexas relações espaciais entre si. Estes materiais, normalmente sintéticos, podem afetar a qualidade da água da chuva que escoar sobre eles. Dependendo do nível de contaminação dos corpos receptores, estas substâncias químicas sintéticas afetam a reprodução de aves, causam tumores em peixes e dificultam o tratamento da água para consumo humano e de outros seres vivos.

Este trabalho justifica-se por utilizar dados de diferentes sensores para a caracterização da cena urbana, e com isso determinar o potencial poluidor de uma bacia hidrográfica, contribuindo com a gestão dos recursos hídricos.

5 ESTADO DA ARTE

5.1 POLUIÇÃO AMBIENTAL

A preocupação com a produção de poluentes em áreas urbanas é um tema que preocupa a comunidade científica e os órgãos responsáveis pelo gerenciamento dos recursos hídricos e o meio ambiente. Segundo Butz e Fuchs (2003), países desenvolvidos, como os da União Européia, já apresentaram iniciativas para avaliar o efeito da atividade humana nos recursos hídricos superficiais e subterrâneos (*European Union*, 2000). Esta iniciativa inclui a estimativa e identificação de fontes de poluição difusa de poluentes e a divulgação desta informação para o gerenciamento da bacia.

5.1.1 POLUIÇÃO URBANA

Segundo dados do censo demográfico do ano 2000 do IBGE (Instituto Brasileiro de Geografia e Estatística), oitenta por cento da população brasileira reside em centros urbanos. Esta aglomeração de indivíduos, em um reduzido espaço físico, acaba por gerar fortes pressões sobre o meio ambiente. Tais pressões são produzidas pelas atividades diárias, decorrentes da vida em sociedade nas grandes cidades.

Todas as atividades humanas geram resíduos, sejam eles oriundos de atividades econômicas como indústria, comércio e serviço, ou simplesmente de atividades biológicas, naturais à vida. No ambiente rural o impacto produzido pelos resíduos gerados pelo ser humano tem uma maior facilidade de ser absorvido e depurado pelo meio ambiente. Este processo não ocorre da mesma forma no meio urbano, onde a grande aglomeração de pessoas acaba por gerar imensas quantidades de resíduos impossíveis de serem absorvidas, ao mesmo tempo, pela natureza.

É esta impossibilidade do meio ambiente em depurar todos os materiais lançados sobre ele que gera a poluição. Segundo Braga et al (2005) poluição é

uma alteração indesejável nas características físicas, químicas ou biológicas da atmosfera, litosfera ou hidrosfera que cause ou possa causar prejuízo à saúde, à sobrevivência ou as atividades dos seres humanos e outras espécies ou ainda deteriorar materiais.

A poluição pode ser classificada segundo a sua origem em pontual ou difusa. Poluição pontual é aquela onde a fonte poluidora pode ser detectada facilmente. Um bom exemplo é o lançamento de efluentes líquidos gerados por uma indústria. Por outro lado a poluição difusa é de difícil mensuração, a origem dos poluentes ocorre em vários pontos simultaneamente, sendo gerada por diferentes fontes. Podemos citar os gases lançados pelo escapamento dos automóveis na atmosfera como um exemplo de poluição difusa.

5.1.2 ESCOAMENTO SUPERFICIAL

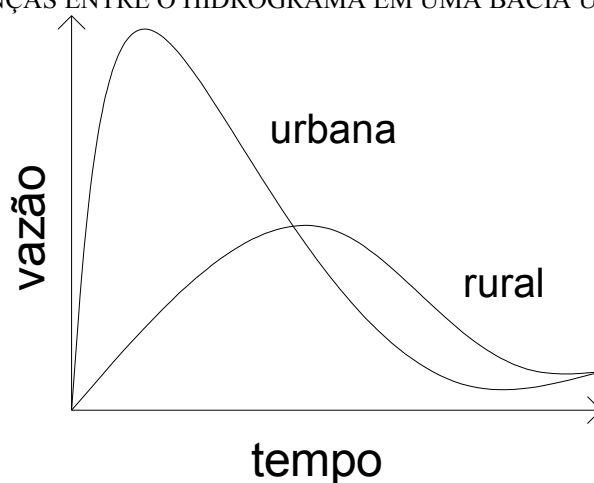
O escoamento superficial urbano é a principal causa da poluição dos corpos receptores de água, Akan, (2003). Este foi definido por Garcez (1988) como parte do volume precipitado através da chuva, que não é infiltrado, evaporado ou interceptado e retorna a um corpo receptor, que pode ser um rio, lago ou outro.

O hidrograma é o gráfico que relaciona a vazão que flui em uma bacia no tempo (TUCCI, 1993). Ainda segundo este autor, em ambientes urbanos onde a cobertura da bacia é alterada, substituindo o solo e a vegetação por superfícies impermeáveis, o pico do hidrograma aumenta, isto representa um acréscimo na velocidade e quantidade de água escoada. A figura 1 relaciona as diferenças entre o hidrograma em uma bacia rural e uma urbana. Nota-se que na bacia urbana o pico da vazão em um evento de chuva, acontece mais rápido e com maior intensidade, o que acaba gerando as enchentes nas grandes cidades.

Quanto mais rápido é o escoamento superficial, maior será o poder destrutivo das águas e, portanto as superfícies dos objetos serão mais facilmente lixiviadas, aumentando com isso o aporte de sedimentos e poluentes aos corpos receptores.

Akan et al, (2003), comentam que as superfícies das cidades acumulam vários tipos de poluentes durante a fase seca. Estes poluentes têm as mais diversas origens: gasolina e óleo de veículos automotores, sedimentos das atividades da construção civil, substâncias químicas de gramados, lixo e materiais sólidos descartados pelas pessoas, além de matéria fecal de animais. Estes poluentes em um período de chuva podem ser lavados e transportados por escoamento superficial, atingindo os corpos de água receptores e diminuindo a qualidade da água destes.

FIGURA 1 – DIFERENÇAS ENTRE O HIDROGRAMA EM UMA BACIA URBANA E RURAL.



5.1.3 POLUIÇÃO HÍDRICA

Entende-se por poluição da água a alteração de suas características por quaisquer ações ou interferências, sejam elas naturais ou provocadas pelo homem. Essas alterações podem produzir impactos estéticos, fisiológicos ou ecológicos. O conceito de poluição da água tem-se tornado cada vez mais amplo em função de maiores exigências com relação à conservação e ao uso racional dos recursos hídricos, (BRAGA et al, 2005).

As políticas de qualidade de água no Brasil são definidas pelo ministério do meio ambiente através do CONAMA (Conselho Nacional do Meio Ambiente) que é o órgão consultivo e deliberativo do sistema nacional do meio ambiente. O CONAMA dispõe sobre a classificação dos corpos de água e as diretrizes ambientais para o seu enquadramento, pela resolução nº 357, de 17 de março de

2005. Esta resolução define a classificação dos corpos de água e os padrões de qualidade de água através de parâmetros orgânicos e inorgânicos.

O CONAMA define carga poluidora como a quantidade de um determinado poluente transportado ou lançado em um corpo de água receptor. Esta mensuração é expressa em unidade de massa pelo tempo. Esta resolução apresenta os padrões de qualidade das águas doces através de parâmetros orgânicos e inorgânicos. Alguns destes parâmetros são como: Sólidos dissolvidos totais, Zinco total, Demanda Química de Oxigênio (DQO) e coliformes são afetados pelas condições do escoamento superficial urbano, proveniente dos telhados das edificações e das ruas pavimentadas como será mostrado nas seções futuras.

Na Literatura são encontrados vários estudos que discorrem sobre a produção de poluentes nas superfícies dos diferentes materiais encontrados na cena urbana e que afetam os corpos receptores de água. A se destacar os trabalhos de Quek e Förster (1993), Ekstrand et al (2001), Chang et al (2004), Gnecco et al (2005) e Figueroa et al (2007).

5.2 MATERIAIS POLUENTES

Segundo a EPA (*The United States Environmental Protection Agency*), poluentes são definidos como substâncias introduzidas no meio ambiente que afetam adversamente a utilidade de um recurso natural.

Para Gnecco et al (2005) a principal causa da deterioração da qualidade da água em corpos receptores é a poluição difusa resultante de escoamento superficial urbano. Artina¹ et al (1999) apud Gnecco et al (2005), aponta que a carga de poluição associada ao primeiro fluxo de escoamento em eventos de

¹ ARTINA, S.; BARDASI, G.; FRANCO, C.; MAGLIONICO, M.; PAOLETTI, A.; SANFILIPO, S.;

Water quality modeling in ephemeral streams receiving urban overflows. The pilot study in

Bologna. In 8th int. Conf. on Urban Storm Drainage, ICUSD, 1689-1596 p.; Sydney, 1999.

chuvas pode ser maior que o aporte de poluentes de efluentes domésticos em períodos secos.

Basicamente a carga de poluentes associada a um escoamento superficial é produzida pelo tráfego veicular, telhados de edificações e outras atividades humanas. A interação da água da chuva com as superfícies encontradas no ambiente urbano transporta os poluentes para os corpos de água, que podem ser os rios, lagos, oceanos e outros.

Os diversos materiais encontrados em rodovias tornam-se uma fonte de poluição difusa, que pode afetar o solo e a água em sua vizinhança. Usualmente os efeitos da descarga deste escoamento no meio ambiente não provocam efeitos agudos. As contaminações em longo prazo, normalmente por metais pesados, são a principal causa da degradação do solo e da água, (LEITÃO, 2005). A origem dos poluentes em uma rodovia é bastante diversa, a tabela 1 mostra um resumo destes focos.

TABELA 1 - ORIGEM DOS POLUENTES GERADOS EM RODOVIAS, ADAPTADO DE LEITÃO (2005).

TIPOS DE POLUENTES	FONTES DA POLUIÇÃO
Metais Pesados	Pneus e pastilhas de freio, combustível, aditivos para motor, ferrugem e barreiras de choque.
Cádmio	Pneus e pastilhas de freio.
Cromo	Mancais, pneus e pastilhas de freio.
Cobre	Pneus, pastilhas de freio, radiadores.
Chumbo	Combustível, pneus e pastilhas de freio.
Zinco	Óleos lubrificantes, barreiras de choque, pneus e pastilhas de freios.
Hidrocarbonetos	Óleos, combustíveis e gases emitidos.
PAHs ²	Combustível, plásticos e pavimentos
Material Orgânico	Vegetação, Lixo e excrementos de animais.

² PAH: Polieletrólito catiônico Hidrocloro de poli(alilamina).

Figuroa et al. (2007) estudaram a distribuição de metais pesados sedimentados em telhados na cidade de Sonora, México. Adachi e Tainosho³ (2005) apud Figuroa et al (2007) demonstram que partículas provenientes da ação antrópica são geradas a partir das vias (asfalto, concreto e pinturas), automóveis (pó de pneu e freios), contribuições industriais ou de deposição atmosférica. Este material particulado, que pode trazer prejuízo a saúde da população, é transportado pelo vento e acaba sendo depositado sobre as coberturas das edificações.

A precipitação que cai sobre as coberturas das edificações também pode ser considerada como uma fonte de poluição difusa. Chang et al (2004) apontam duas razões que justificam a preocupação com as águas escoadas por telhados. A primeira seria com os materiais constituintes das telhas, que podem ser lixiviados pelo escoamento, assim como poluentes depositados pelo vento e substâncias orgânicas, que são provenientes de animais e plantas. A segunda razão é que as temperaturas nas telhas são muito maiores do que em outras superfícies, devido ao menor albedo. Esta elevação da temperatura pode acelerar as reações químicas e decomposição orgânica de materiais e compostos que são acumulados nos telhados.

Chang et al. (2004) também conclui que telhados podem ser uma perigosa fonte de poluição urbana, mas que existe uma variação da agressividade da poluição conforme o material constituinte das telhas. Outros trabalhos como o de Quek e Förster (1993), também reforçam esta afirmação.

5.2.1 A POLUIÇÃO CONFORME O TIPO DE MATERIAL

Os materiais constituintes das telhas das edificações, podem afetar de forma diferente a qualidade da água da chuva que cai sobre os mesmos. Chang et al (2004) concluem que os telhados podem ser fontes de poluição difusa, porém eles alertam para o fato de que os efeitos desta poluição podem variar. A variação

³ ADACHI, K.; TAINOSHO, Y.; **Single particle characterization of size-fractioned road sediments.**

In Applied Geochemistry 20, 849-859 p.; 2005.

reflete os diferentes materiais utilizados na fabricação das telhas, cuidados e manutenção, idade, condições climáticas e a qualidade do ar na região.

Segundo Metre e Mahler (2003) telhas de materiais metálicos tornam-se uma maior fonte de contaminação, por cádmio e zinco, quando comparadas com telhas de materiais asfálticos. Por outro lado o betume das telhas asfálticas é uma importante fonte de contaminação por chumbo.

Yaziz et al (1989) apontou que a concentração de coliformes fecais na água da chuva escoada é maior em amostras coletadas do escoamento de telhas cerâmicas, quando comparado a coberturas metálicas. Este fenômeno pode ser explicado devido a maior temperatura alcançada na superfície dos telhados metálicos que acaba por eliminar muitos coliformes.

A cidade de Palo Alto⁴ nos Estados Unidos determinou através da *ordinance text (municipal code section 16.09.160(b))*, que a partir do ano de 2003 não seria mais permitido a utilização de telhas de cobre em qualquer tipo de edificação residencial. A razão que levou este município a tomar esta decisão foram os resultados de um estudo intitulado “*Architectural uses of copper: Na evauation of storm Water Pollution Loads and BMPs.*” O estudo realizado no ano de 2000 concluiu que:

- A quantidade de cobre liberada por ano na RWQCP (*Regional Water Quality Control Plant*) é maior que a quantidade de cobre lançada na mesma região por atividades industriais.
- Um incremento na área de telhados de cobre de aproximadamente 1000 pés quadrados, pode lançar em um riacho uma quantidade de poluição igual aos padrões crônicos de toxinas estabelecido pela agência de proteção ambiental norte-americana.
- Os telhados de cimento amianto podem ser uma fonte de poluição por amianto. Este material é potencialmente cancerígeno em certas quantidades. A EPA alerta que a utilização de produtos cimento amianto só torna-se potencialmente perigosa quando são produzidas partículas (pó) deste material. A deterioração das

⁴ **New palo alto ordinance Prohibits copper roofing Materials.** 2003.

telhas de cimento amianto pela chuva e vento pode produzir estas partículas, (BASSANI et al, 2007).

5.3 SENSORIAMENTO REMOTO

A estimativa e identificação de fontes de poluição difusa geralmente demandam de investigações em campo. Esta prática ao longo dos anos tem se demonstrado física e financeiramente onerosa. A solução para a determinação da distribuição espacial e intensidade da pavimentação em áreas urbanas passa pelo uso de técnicas de sensoriamento remoto (BUTZ e FUCHS ,2003).

Lillesand e Kiefer (1994) definiram que sensoriamento remoto é a ciência e a arte de obter informações sobre um objeto, área ou fenômeno através da análise de dados obtidos por um aparelho que não esteja em contato com o objeto, área ou fenômeno sob investigação.

Em 1960, quando o nome sensoriamento remoto foi utilizado pela primeira vez, ele se referia apenas a observação e mensuração de objetos sem contato com os mesmos, Fischer⁵ (1975) apud Curran (1985). Desde aquela data o SR tornou-se uma disciplina parte das ciências ambientais, geologia, botânica, zoologia, engenharia civil, engenharia florestal, meteorologia, que usualmente se referem ao uso de imagens do meio ambiente gravada de sensores que captam energia da radiação eletromagnética refletida. (CURRAN,1985).

5.3.1 SENSORIAMENTO REMOTO E A POLUIÇÃO

O mapeamento da distribuição espacial de materiais em uma cena urbana, com dados de SR pode trazer rapidez e economia tanto na atualização como na confecção de novos mapas.

Ekstrand et al. (2001) utilizaram fotografias aéreas digitais para o mapeamento da distribuição de telhados de cobre na cidade de Estocolmo,

⁵ FISCHER, W. A.; **History of remote sensing: In Reeves, Manual of Remote sensing.** American Society of Photogrammetric. 1975.

Suécia. Os autores utilizaram uma câmara analógica com sensor CIR (*colour infrared*), as fotografias foram escaneadas com resolução espacial de 0.4 metros, e um modelo digital de elevação derivado de fotografias aéreas em preto e branco. Ekstrand et al. (2001) apontam que telhados de cobre e outras classes urbanas são mais facilmente separadas nas faces iluminadas pelo sol. Os principais problemas ocorreram em telhados ou outros objetos com faces não expostas a luz solar.

Para uma estimativa da produção de poluentes em ambiente urbano, pode ser necessário além de discriminar os diferentes materiais, também, verificar o grau de deterioração de cada material. Bassani et al. (2007) realizaram uma pesquisa onde foram identificados a idade e o estado dos telhados com telha de cimento amianto na cidade de Follonica, Itália. Para este estudo foram coletadas imagens com o sensor MIVIS (*Multispectral Infrared and Visible Imaging Spectrometer*).

Park e Stenstrom (2006) apresentaram uma proposta para estimar a carga de poluentes que afetam o escoamento superficial através de imagens de satélite. O sensor escolhido foi o ETM+ que foi lançado a bordo do satélite Landsat 7 e através dele foram analisados alguns parâmetros de qualidade da água, incluindo: sólidos suspensos totais, demanda bioquímica de oxigênio, nutrientes, metais pesados, óleos e graxas. A classificação do uso do solo urbano foi realizada, neste trabalho, com o uso de Bayesian networks. Este método se utiliza de probabilidades condicionais para definir a relação entre os diferentes nós da rede.


Yin et al (2005) utilizaram-se de imagens do satélite Landsat 7 para encontrar padrões de uso e cobertura do solo na cidade de Shanghai, China. Os resultados foram utilizados para prever o potencial de poluição na área de estudo. Os autores concluíram que a utilização de dados de sensoriamento remoto é uma ferramenta mais eficiente para quantificar a carga poluidora, do que a densidade populacional.

5.4 SISTEMA LASER SCANNER

O laser scanner (LIDAR) é um sistema ativo usado para determinar a altitude de pontos da superfície da terra e os objetos presentes a partir de medições da distância entre o sensor e a superfície dos objetos. Um sistema laser scanner é composto por um instrumento laser, um receptor GPS (*Global Position System*) e um sistema inercial, HUISING (1998).

Este sistema é acoplado em uma plataforma aérea ou orbital, desta forma um sistema de feixes é disparado em direção ao solo, calcula-se a altimetria dos objetos utilizando-se do tempo decorrido entre a emissão e o registro do retorno do sinal. (LOHR e EIBERT, 1995). A figura 2 exemplifica o funcionamento do sistema laser scanner.

FIGURA 2 – VARREDURA DO SISTEMA LASER AEROTRANSPORTADO FONTE (SWANSEA GEOGRAPHER⁶, 2007).



Laser scanner aerotransportado é um rápido processo para adquirir a altitude dos pontos da superfície visível, com alta precisão e boa resolução espacial. Estes dados podem ser utilizados para gerar um modelo digital de superfície, o DSM, (MCINTOSH et al. 2000). A resolução espacial do sistema

⁶ THE GEOGRAPHICAL JOURNAL OF THE UNIVERSITY OF WALES, SWANSEA. ISSN 0087-9980. [Http://geography.swan.ac.uk/glaciology/projects/slices/Lidar/index.htm](http://geography.swan.ac.uk/glaciology/projects/slices/Lidar/index.htm), acessado em 23/07/2007.

laser é dependente da taxa de repetição do pulso laser e da altitude de vôo. Podendo variar de 1 ponto a cada 20 m² para até 20 pontos por metro quadrado, em um vôo de 1000 m. de altitude (ACKERMANN, 1999).

Segundo Kiema e Bähr (2000), os dados altimétricos LIDAR fornecem uma ferramenta importante na classificação de feições que apresentem uma resposta espectral semelhante, mas com diferenças significativas de altitude. Como exemplo destas feições os autores citam a discriminação entre árvores e gramados e entre telhados de edificações e ruas pavimentadas.

Dados LIDAR também podem ser usados para o registro e ortorretificação de fotografias aéreas. Para este procedimento pode-se utilizar de feições lineares homólogas nos dois conjuntos de dados, como em Habib et al. (2005).

No presente trabalho os dados laser serão utilizados para o registro das imagens aéreas, como apoio a monorrestituição das edificações e como uma banda extra de informação para a classificação de imagens.

5.5 INTEGRAÇÃO DOS DADOS

Embora o aumento da resolução espacial dos sensores orbitais tenha trazido um avanço aos processos automáticos e semi-automáticos de classificação, o uso de apenas esta fonte de informação não é suficiente para a discriminação de algumas feições no ambiente urbano. Neste contexto o uso integrado de informações auxiliares pode ser necessário.

Lemp e Weidner (2004) utilizaram este princípio para caracterizar superfícies urbanas utilizando dados LIDAR integrado a imagens de um sensor hiperespectral HYMAP. Eles verificaram uma melhora no resultado da classificação com o uso da informação altimétrica, em relação à classificação alcançada utilizando os dados do poderoso sensor hiperespectral que captura imagens em 128 bandas diferentes.

Botelho e Centeno (2005) avaliaram a inclusão de informações altimétricas derivadas de um sensor laser scanner, na classificação semi-

automática de imagens Quickbird. Os autores concluíram que a utilização dos dados LIDAR melhora a qualidade da classificação quando comparada ao resultado da classificação puramente espectral.

A integração dos dados será utilizada no processo de classificação das imagens para separar feições com respostas espectrais próximas e com diferentes níveis de altitudes. Assim as feições poderão ser classificadas com base nos seus valores espectrais e na sua respectiva elevação em relação ao terreno.

6 MATERIAL E MÉTODOS

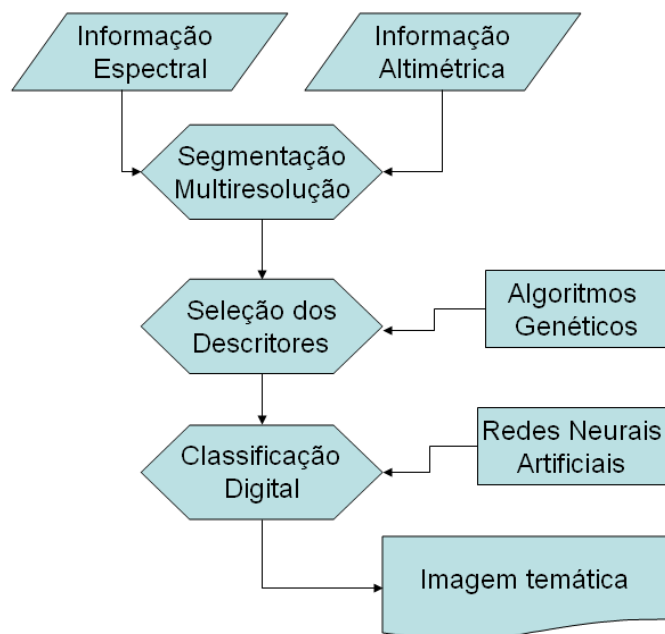
A proposta deste trabalho é avaliar o potencial da utilização de dados de sensoriamento remoto para realizar a discriminação dos diferentes materiais presentes em uma cena urbana, como ferramenta para a estimativa do potencial poluidor, em termos hídricos, dos telhados numa área urbana. A metodologia propõe a integração de imagens altimétricas do sensor laser scanner com imagens multispectrais de alta resolução espacial, tais como, fotografias aéreas e imagens orbitais, tais como as imagens do sensor QUICKBIRD II.

O primeiro passo consiste na segmentação multiresolução, utilizando o algoritmo FNEA, no software eCognition. A segmentação consiste no processo de agrupar em regiões pixels com valores semelhantes e espacialmente contíguos. Para cada segmento produzido o software calcula uma série de atributos relativos ao segmento, estes atributos são conhecidos como descritores. O resultado da segmentação FNEA produz um grande número de descritores para cada segmento produzido. Assim se faz necessária uma seleção, para evitar o problema de multidimensionalidade, conhecido como fenômeno Hughes (ZORTEA et al. 2005). A seleção dos descritores utilizados para realizar a classificação hierárquica é baseada em algoritmos genéticos, estes algoritmos selecionam os descritores espaciais, espectrais e de textura, mais aptos em cada nível de segmentação.

Na seqüência o grupo de descritores, mais aptos, selecionados pelos algoritmos genéticos serve como entrada para uma classificação digital baseada em redes neurais artificiais (RNA), produzindo uma imagem temática com os respectivos materiais presentes na cena urbana. Além dos dados brutos, transformações espectrais da imagem foram também avaliadas dentro do processo de classificação digital, com o objetivo de discretizar diferentes feições de uma cena urbana. Esta classificação poderá ser utilizada, em estudos futuros, como mecanismo de tomada de decisão para definição do potencial poluidor em uma determinada área da superfície urbana.

A figura 3 sintetiza os passos descritos nesta metodologia em um organograma.

FIGURA 3 – ESTRUTURA DA METODOLOGIA PROPOSTA.



6.1 ÁREAS DE ESTUDO

Foram selecionadas duas áreas de estudo no município de Curitiba, estado do Paraná, para a realização desta pesquisa. A área 1 localiza-se no bairro Parolim desta capital. A empresa Esteio Engenharia e Aerolevantamentos S.A disponibilizou um levantamento laser scanner do equipamento ALS 50 e uma fotografia aérea com a câmera DS-40, ambos do ano de 2002.

Uma segunda área de estudo foi selecionada no bairro Jardim das Américas, próxima ao centro politécnico da Universidade Federal do Paraná. foram disponibilizados pelo LACTEC (Instituto de Tecnologia para o Desenvolvimento) um levantamento LIDAR realizado com o sensor ALTM 2050 em 2006, e uma fotografia métrica obtida com uma câmera da marca WILD modelo RC-10, vôo realizado no ano 2002, além de uma imagem do satélite QuickBird II. A tabela 2 apresenta um quadro resumo sobre os dados disponíveis em cada uma das regiões utilizadas neste trabalho.

TABELA 2 - DADOS DISPONÍVEIS.

Área	Região	Dados disponíveis
1	Bairro Jardim das Américas	<ul style="list-style-type: none"> • Levantamento Laser Scanner LACTEC. • Fotografia Aérea RGB. • Imagem QuickBird II.
2	Bairro Parolin	<ul style="list-style-type: none"> • Levantamento Laser Scanner Esteio S.A. • Ortofoto CIR;

6.2 PREPARAÇÃO DOS DADOS

Para a integração de dados de diferentes sensores, no caso, imagens de satélite e fotografias aéreas com dados laser scanner se faz necessária uma etapa prévia de preparação dos dados.

6.2.1 PRÉ-PROCESSAMENTO DOS DADOS LASER SCANNER

Os dados recebidos do levantamento laser scanner constam de um arquivo em formato ASCII que contém as coordenadas tridimensionais X, Y e Z dos pontos coletados. A integração destes elementos altimétricos com as imagens e fotografias multiespectrais prevê a transformação destes dados em um arquivo raster.

Para gerar o MDS (Modelo Digital de Superfície), foi utilizada a metodologia utilizada por Araki⁷ 2005. Tal procedimento é dividido nas seguintes etapas:

- i. Projeção dos pontos em uma Grade Regular com espaçamento de 50 centímetros;
- ii. Preenchimento dos locais da grade que ficaram vazios a partir dos vizinhos, se existirem, e se os mesmos satisfizerem um critério de homogeneidade;
- iii. Aplicação do operador morfológico fechamento para preencher regiões de bordas entre áreas não homogêneas;

⁷ Fusão de Informações espectrais, altimétricas e de dados auxiliares na classificação de imagens de alta resolução espacial. Araki, Hideo 2005. Tese de Doutorado.

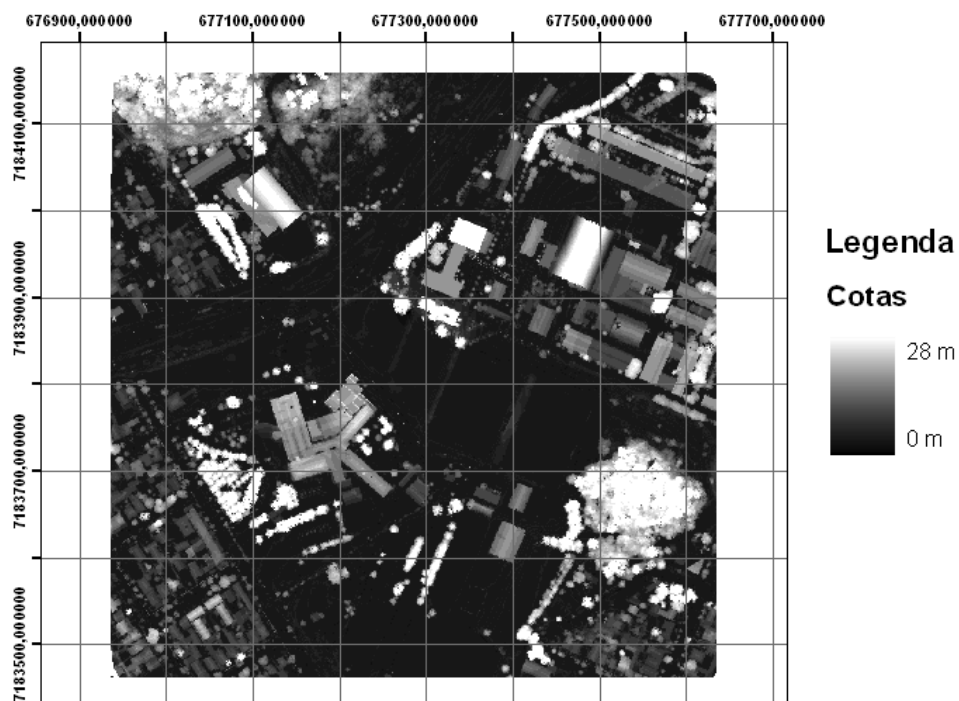
- iv. Tratamento das regiões sem informação devido a oclusão ou que não retornaram o sinal laser , como superfícies de água.

Uma segunda grade regular apresenta a informação altimétrica do nível do terreno, sem a informação de superfícies elevadas como edificações ou árvores, a esta grade é dado a nomenclatura MDT (Modelo Digital do Terreno).

Neste trabalho para a região do bairro Parolin foi utilizado o MDT gerado e cedido pela empresa Esteio Engenharia e Aerolevantamentos S.A. gerado no através do aplicativo *Terra Scan* do *software Microstation*. No caso do bairro Jardim das Américas, foi utilizado um MDT, cedido pelo LACTEC.

A diferença entre o MDS e o MDT é o MDSn (Modelo Digital de Superfície Normalizado), que contém somente as altitudes das feições acima do solo. A figura 4 apresenta o MDSn de um recorte na região do centro politécnico. Nesta imagem percebem-se com destaque, altos níveis de cinza, as edificações e vegetação arbórea. Da mesma forma as feições ao nível do solo, como ruas e solo exposto, aparecem com valores digitais muito próximo de zero, cor preta.

FIGURA 4 – EXEMPLO DE UM MDSN



A resolução espacial das grades altimétricas geradas, depende das imagens com a quais esta informação será combinada. No caso da utilização da imagem

do satélite Quickbird as grades (MDS e MDT) terão setenta centímetros de resolução espacial. No caso da combinação com as fotografias aéreas esta resolução será de cinquenta centímetros.

6.2.2 CORREÇÃO GEÔMETRICA DA IMAGEM DE SATÉLITE

Segundo Sonka et al (1999), quando existe a necessidade de analisar diferentes imagens de um mesmo objeto, uma transformação geométrica se faz necessária. Esta transformação permite eliminar distorções geométricas que ocorrem quando cada imagem é capturada. Para o processo de correção das distorções, foi realizada uma re-amostragem da matriz de *pixels* da imagem de satélite através da utilização de pontos de controle com coordenadas conhecidas no espaço da imagem e no espaço objeto.

As coordenadas dos pontos de controle no espaço objeto foram lidas do levantamento laser, referenciado ao sistema SAD-69. Os pontos, nos dados laser scanner, contém informação tridimensional. Isto permite levar em conta as variações altimétricas que ocorrem no terreno, no processo de georreferenciamento.

O modelo utilizado para se efetuar a correção geométrica das imagens neste trabalho foi o modelo de polinômios racionais, definido de acordo com a metodologia usada por ARAKI (2005), que obedecem a seguintes equações:

$$L_n = \frac{P_1}{P_2} \quad (1)$$

$$C_n = \frac{P_3}{P_4} \quad (2)$$

Onde L_n e C_n são, respectivamente, as coordenadas da imagem; ou seja linha e coluna, normalizadas são X_n , Y_n , e Z_n . Para o caso de 3º grau, os polinômios são expressos como:

$$P_1 = (1 \quad Z_n \quad Y_n \quad X_n \quad Z_n * Y_n \dots Y_n^3 \quad X_n^3) * (a_0 \quad a_1 \dots a_{19})^T \quad (3)$$

$$P_2 = (1 \quad Z_n \quad Y_n \quad X_n \quad Z_n * Y_n \dots Y_n^3 \quad X_n^3) * (1 \quad b_1 \dots b_{19})^T \quad (4)$$

$$P_3 = (1 \quad Zn \quad Yn \quad Xn \quad Zn * Yn \dots Yn^3 \quad Xn^3) * (c_0 \quad c_1 \dots c_{19})^T \quad (5)$$

$$P_4 = (1 \quad Zn \quad Yn \quad Xn \quad Zn * Yn \dots Yn^3 \quad Xn^3) * (1 \quad d_1 \dots d_{19})^T \quad (6)$$

Os termos ai, bi, ci e di são os coeficientes a serem determinados.

O resultado obtido é utilizado para criar uma imagem nova com as coordenadas dos pontos corrigidos. Este processo é executado através da reamostragem da imagem nova através do processo da convolução cúbica. Neste processo os valores dos *pixels* na nova imagem são obtidos através da interpolação dos 16 *pixels* mais próximos na imagem original.

6.2.3 FUSÃO DAS IMAGENS

Para solucionar o problema das diferentes resoluções espectrais entre as imagens multispectrais e a imagem pancromática do sensor orbital é necessário a produção de uma imagem híbrida que contenha ambas as informações. A este processo denomina-se de fusão de imagens.

Segundo Chaves e Bowel (1988), o objetivo da fusão de imagens é manter a informação espectral e incluir, na medida do possível, a informação espacial derivada da imagem com pixel menor – melhor resolução espacial.

Existem na literatura vários métodos que realizam a fusão entre imagens, entre eles estão os que utilizam de uma transformação no espaço de cores. Embora sejam eficientes, estes métodos só permitem a fusão de 3 bandas espectrais de cada vez.

O método das componentes principais (CP) permite a geração de uma imagem híbrida a partir de um número qualquer de bandas. A transformação por componentes principais (equação 1) procura minimizar a correlação entre variáveis, neste caso bandas espectrais, através de uma transformação de rotação espectral. Com isto, as novas variáveis conseguem explicar a estrutura da matriz de variância-covariância dos dados de entrada com um novo conjunto de bandas, que são uma combinação linear não correlacionada destas entradas.

Para determinação das componentes principais, o vetor aleatório é formado concatenando a matriz que contém o valor de cada banda espectral para cada pixel na imagem. O primeiro passo é o cálculo da matriz de covariância (Σ) dos dados do vetor aleatório. Na seqüência os pares de autovalores e autovetores são determinados pela equação a seguir:

$$(\Sigma - \lambda_i * I) e_{\sim i} \quad (7)$$

Onde:

Σ - Matriz de Covariância;

λ_i - Autovalores;

I - Matriz identidade;

$e_{\sim i}$ - Autovetores;

O Conjunto de componentes principais de ordem n, igual as n bandas que compõe a imagem de entrada é definida pela equação 8, com variância igual a λ_i .

$$Y_i = e_{\sim i} * X_{\sim} \quad (8)$$

Onde:

Y_i - i-ésima componente principal;

$e_{\sim i}$ - autovetores associados a i-ésima componente principal;

X_{\sim} vetor das variáveis aleatórias;

Gonzales e Woods (2000) apontam que a primeira componente esta orientada segundo a direção de maior variância dos dados originais, apresentando um maior contraste do que as demais componentes. A primeira componente então contém teoricamente a informação que é comum a todas as bandas originais, enquanto outras componentes conterão informações espectrais específicas. Assim, a primeira componente é substituída pela banda pancromática e é efetuada a operação inversa para levar os dados combinados de volta ao espaço da imagem, (ARAKI, 2005).

A fusão por componentes principais das bandas espectrais e pancromática do satélite Quickbird foi realizada em ambiente ENVI 4.2. O resultado obtido foi uma imagem híbrida com 4 bandas espectrais e resolução espacial da mesma grandeza da banda pancromática.

6.3 ROTAÇÃO DO ESPAÇO RGB

Ohta et al (1980) realizaram uma série de experimentos com rotações do espaço RGB para melhorar o processo de segmentação de feições coloridas. Eles fizeram experimentos sistemáticos de regiões segmentadas em vários sistemas de cores, entre eles IHS (*Intensity, Hue e Saturation*), componentes principais, YIQ (*Luminance-Inphase Quadrature*), Lab (*Cube root color system L-a-b*, CIE).

Após a realização dos experimentos Ohta et al (1980) verificaram que geralmente as três componentes principais de imagens reais tendem a ser paralelas. Assim, definiram um conjunto de três componentes (equações (9), (10) e (11)) que são efetivas para a segmentação de imagens coloridas. Esta transformação das bandas vermelha, verde e azul é simples e se comporta bem quando dados digitalizados são utilizados.

$$I_1 = \frac{red + green + blue}{3} \quad (9)$$

$$I_2 = \frac{red - blue}{2} \quad (10)$$

$$I_3 = \frac{(2 * green) - red - blue}{2} \quad (11)$$

O objetivo da utilização da rotação do espaço de cores RGB neste trabalho é verificar se esta etapa traz benefício ao processo de segmentação e posterior classificação dos segmentos.

6.4 INTEGRAÇÃO DOS DADOS

Após o processo de homogeneização dos dados, correção das imagens de satélite, ortorretificação da fotografia aéreas, e criação das grades regulares dos dados laser, os

dados dos diferentes sensores podem ser integrados para utilização nas etapas seguintes da execução desta metodologia. A integração é efetuada adicionando a informação altimétrica como uma banda complementar as já existentes nos dados multispectrais. No caso de o sensor multispectral conter informação do comprimento de onda da região do infravermelho próximo, será adicionada ainda uma banda contendo o NDVI (Índice de Vegetação por Diferença Normalizada). A tabela 3 apresenta o resultado desta combinação conforme o sensor utilizado. Devido ao fato da ortofo recebida, conter a combinação vermelho falsa cor (Vermelho, Verde e Infravermelho), esta combinação será também utilizada nos experimentos que utilizaram a imagem de satélite do sensor *Quickbird II*.

TABELA 3 – CONFIGURAÇÃO DAS BANDAS APÓS A INTEGRAÇÃO DOS DADOS.

SENSORES		
CÂMARA RGB	CÂMARA CIR	<i>QUICKBIRD</i>
Azul	Infravermelho	Infravermelho
Verde	Vermelho	Vermelho
Vermelho	Verde	Verde
MDSn	NDVI	NDVI
	MDSn	MDSn

6.5 SEGMENTAÇÃO E CLASSIFICAÇÃO

A classificação digital de imagens pode ser dividida quanto à interferência do operador e quanto ao menor elemento na imagem. Em relação ao primeiro item existem basicamente dois métodos de classificação de imagens digitais, a classificação supervisionada e a não-supervisionada. A diferença entre os métodos consiste na interferência ou não do usuário no processo. Devido ao uso de dados integrados de sensores diferentes, optou-se por trabalhar com uma classificação supervisionada neste estudo.

Quanto ao menor elemento na imagem, as classificações podem ser baseadas no pixel ou com base em segmentos homogêneos. A classificação pixel

a pixel utiliza a resposta espectral do pixel, o vetor de médias e a estrutura da variância e covariância de cada classe para rotular o pixel. Esta é uma classificação puramente espectral. No segundo caso, a imagem é inicialmente segmentada. A segmentação gera regiões homogêneas que podem ser descritas por, além da resposta espectral, descritores espaciais como de forma, área, entre outros.

6.5.1 SEGMENTAÇÃO MULTI-RESOLUÇÃO

Com o avanço da resolução espacial das imagens de satélite e das fotografias aéreas, novos procedimentos têm sido desenvolvidos para aperfeiçoar o processo de classificação digital de imagens. Uma das técnicas mais difundidas na literatura é a segmentação de imagens.

Baatz e Shäpe (2000) apontam que uma eficiente segmentação é um pré-requisito para o processamento de imagens orientado ao objeto. A segmentação realizada pelo *eCognition* é um processo de crescimento de regiões, onde a partir de um pixel semente, são agregados pixels vizinhos que guardem um grau de similaridade, formando assim objetos maiores, denominados segmentos.

Segundo PRATT (1991) a divisão da imagem em segmentos com atributos similares é condicionada ao problema a que se pretende resolver. Assim o tamanho e a forma como os segmentos produzidos irão depender das características da imagem digital utilizada, suas diferentes resoluções espaciais e espectrais, assim com das características intrínsecas da região estudada.

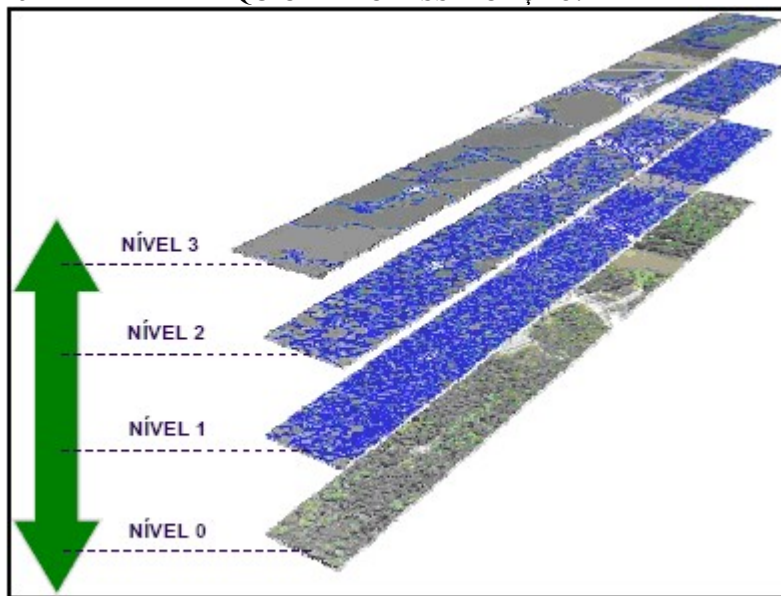
O conceito de evolução de rede fractal (FNEA: fractal net evolution approach), apresentado por Blaschke e Hay (2002), considera uma seqüência de segmentação das imagens de sensoriamento remoto, variando a escala de segmentação. Este processo de segmentação permite uma hierarquização da classificação, criando diferentes níveis, que contém super-objetos e sub-objetos, conforme exemplificado na figura 5.

Como entrada para a fase de segmentação da fotografia aérea, além da informação espectral das bandas do visível e infravermelho, e sua respectiva

rotação do espaço, serão incluídas duas novas bandas, uma contendo um índice de vegetação e outra com o MDSn, derivado dos dados laser scanner

São citadas na literatura várias abordagens para se efetuar a segmentação de imagens, dentre eles os mais citados são: Limiarização e Segmentação orientada a região.

FIGURA 5 – REDE HIERÁRQUICA DE CLASSIFICAÇÃO.



FONTE: Adaptado de KERSTING 2006.

6.5.1.1 SEGMENTAÇÃO ORIENTADA A REGIÕES

Este é um processo de crescimento de regiões. Também é um processo baseado na similaridade dos níveis de cinza, como a limiarização. Seu objetivo é agrupar *pixels* ou sub-regiões em regiões maiores. Assim, a partir de um *pixel* semente, novos *pixels* são agregados formando regiões que possuam propriedades similares como forma, nível de cinza, cor ou textura. Para Gonzáles & Woods (2000) este processo pode ser resumido através da seguinte seqüência:

$$i. \quad \bigcup_{i=1}^n R_i = R \quad ; \quad (12)$$

$$ii. \quad R_i \text{ É uma região conexa, (a) } i=1,2,\dots, n; \quad (13)$$

$$iii. \quad R_i \cap R_j = \emptyset \text{ Para todo } i \text{ e } j, i \neq j; \quad (14)$$

$$iv. \quad P(R_i) = \text{Verdadeiro para } i=1,2,\dots, n; \quad (15)$$

$$v. \quad P(R_i \cap R_j) = \text{Falso para } i \neq j; \quad (16)$$

6.5.1.2 NÍVEIS DE SEGMENTAÇÃO

A integração de dados altimétricos e espectrais permite uma maior diferenciação dos objetos nas imagens digitais. A representação semântica das feições presentes na imagem é melhor caracterizada em diferentes escalas. Nem sempre é possível representar todas as feições em uma mesma escala, uma vez que os segmentos criados ultrapassam as bordas de algumas das feições.

O critério para formação dos segmentos no *software Ecognition* é condicionada a alguns elementos definidos pelo usuário. O primeiro é a escala, fator este que define o tamanho dos objetos criados. Além disso, o usuário também controla os critérios de homogeneidade dos segmentos através dos fatores de forma, compacidade e suavidade. O balanceamento destes critérios dependerá da natureza dos objetos a serem extraídos.

Assim os níveis de segmentação foram determinados conforme os objetos que se pretendia discretizar. Foram definidos três níveis de segmentação que estão sintetizados na tabela 4. Os valores dos parâmetros utilizados foram determinados de tal forma que os segmentos gerados não ultrapassassem os limites dos objetos nas imagens.

TABELA 4 – PARÂMETROS UTILIZADOS NA SEGMENTAÇÃO.

NÍVEL	BANDAS	FATORES			
		Escala	Forma	Suavidade	Compacidade
3	NDVI	50	0.1	0.5	0.5
2	MDSn	50			
1	Todas	10			

O nível mais grosseiro, denominado: Nível 3, é utilizado para separar a vegetação das demais feições. Para isso é utilizado o NDVI (Normalized Difference Vegetation Index). A variação da reflectância na banda do infravermelho é comparada com a banda do vermelho, seguindo a equação 17 para ressaltar a vegetação na cena.

$$NDVI = \frac{iv - v}{iv + v} \quad (17)$$

Onde:

I_V : É o valor do *pixel* na região do infravermelho próximo;

V : É o valor do *pixel* na região do vermelho

A utilização do NDVI permite uma boa separação entre as feições vegetação e não vegetação. Esta classificação é levada para o próximo nível onde se pretende incluir a informação altimétrica .

O nível 2 tem a função de separar as feições ao nível do solo das feições acima do solo. Neste nível somente a banda altimétrica (MDSn) é utilizada. As demais informações, como NDVI e bandas espectrais, têm peso zero neste processo. Como este nível recebe a herança do primeiro, são produzidas quatro classes: Vegetação acima do solo, Vegetação ao nível do solo, Não vegetação acima do solo e Não vegetação ao nível do solo.

Por último o nível 1, que caracteriza uma segmentação mais refinada, utiliza as informações integradas dos dados espectrais, altimétricos e NDVI, juntamente com a herança da segmentação dos outros níveis, para classificar as regiões.

Todas as etapas de segmentação multiresolução são realizadas no software eCognition, este programa utiliza um algoritmo de segmentação FNEA. Após o processo de segmentação os segmentos e seus descritores são exportados em formato vetorial.

6.5.2 SELEÇÃO DOS ATRIBUTOS

O software eCognition permite retirar uma grande quantidade de informações espectrais e espaciais dos segmentos produzidos na etapa de segmentação. Selecionando-se apenas informações espectrais, forma e textura dos segmentos, o eCognition permite trabalhar com um total de 446 descritores. Esta grande quantidade de variáveis pode criar um problema de dimensionalidade, conhecido como o fenômeno Hughes (ZORTEA et al. 2005). O fenômeno Hughes aponta que a acurácia da classificação aumenta até certo

ponto enquanto novas variáveis são incluídas no processo, após isto, se novas variáveis são adicionadas a eficiência do processo de classificação se reduz.

Para selecionar as variáveis (descritores) que são incorporadas a cada etapa do processo de classificação, nesta pesquisa é utilizada a técnica dos algoritmos genéticos. Esta técnica segue a linha da teoria da evolução de Darwin, onde os indivíduos mais aptos proliferam, enquanto os menos aptos perecem. Para esta etapa um código fonte foi elaborado em ambiente Matlab.

6.5.2.1 CODIFICAÇÃO E DEFINIÇÃO DA POPULAÇÃO

O passo inicial para se trabalhar com algoritmos genéticos é a codificação dos indivíduos e definição da população. A codificação utilizada é binária, onde cada elemento (gene) poderá assumir dois valores: 0 (zero) indicando a ausência do respectivo descritor e 1 (um) informando que o descritor será utilizado no processo. O tamanho de cada indivíduo é função do número de descritores importados do programa de segmentação. Por população entende-se um conjunto de n indivíduos. A população inicial é criada de forma aleatória, o operador do programa determina o número de descritores presentes em cada indivíduo e o tamanho da população. Como inicialmente não se conhece a verdadeira resposta ou solução ao problema, o software implementado preenche cada indivíduo de forma randômica, respeitando os números de presenças (genes com valor 1) definido pelo usuário. Este processo é repetido até que a população total seja criada.

6.5.2.2 FUNÇÃO OBJETIVO

O passo seguinte é a determinação da aptidão (*fitness*) de cada indivíduo. Este valor, geralmente normalizado entre 0 e 1 representa a capacidade do indivíduo em resolver o problema em questão. Para se determinar a aptidão é necessária uma função objetivo que determine o quão apto é cada indivíduo.

No contexto deste trabalho foram testadas duas funções objetivo. A análise Discriminante de Fischer e o classificador estatístico baseado no princípio da mínima distância.

A análise discriminante de Fischer, foi inicialmente definida para separar populações, contudo no caso de vários grupos (classes) ela pode ser usada para classificar. Não é necessário que as diversas populações apresentem distribuição normal, entretanto é assumido que as matrizes das diversas classes apresentam a mesma variância (Σ). Assim através da equação 18 podemos calcular o vetor médio para as diversas populações $\bar{\mu}$.

$$\bar{\mu} = \frac{1}{g} \sum_{i=1}^g \mu_i \quad (18)$$

Sendo:

g – número de grupos (classes);

μ_i - média do i -ésimo grupo.

Também é possível calcular a matriz “Soma dos produtos cruzados:

$$B_0 = \sum_{i=1}^g (\underline{\mu}_i - \underline{\bar{\mu}}) \cdot (\underline{\mu}_i - \underline{\bar{\mu}})' \quad (19)$$

O último passo é a determinação do otimizante “ c ” maximizando a expressão:

$$\frac{c' \cdot B_0 \cdot c}{c' \cdot \Sigma \cdot c} \quad (20)$$

Determinando assim os discriminantes amostrais para cada classe. Este processo define a classe mais provável a qual cada segmento na imagem deve pertencer.

6.5.2.3 ELITISMO, CRUZAMENTO E MUTAÇÃO

Após a determinação da aptidão o conjunto população é ordenado com base na função aptidão. Caso o maior valor da aptidão seja inferior a um limite

especificado pelo usuário, os indivíduos mais aptos (maior *fitness*) são selecionados através da técnica de elitismo para continuar na próxima geração, assegurando que o padrão genético não diminua. Assim fica definido que os indivíduos com os 10 % melhores *fitness* passarão para a próxima geração. Da mesma forma os indivíduos menos aptos serão descartados em igual quantidade, ou seja os indivíduos com os 10 % piores *fitness* são eliminados do processo.

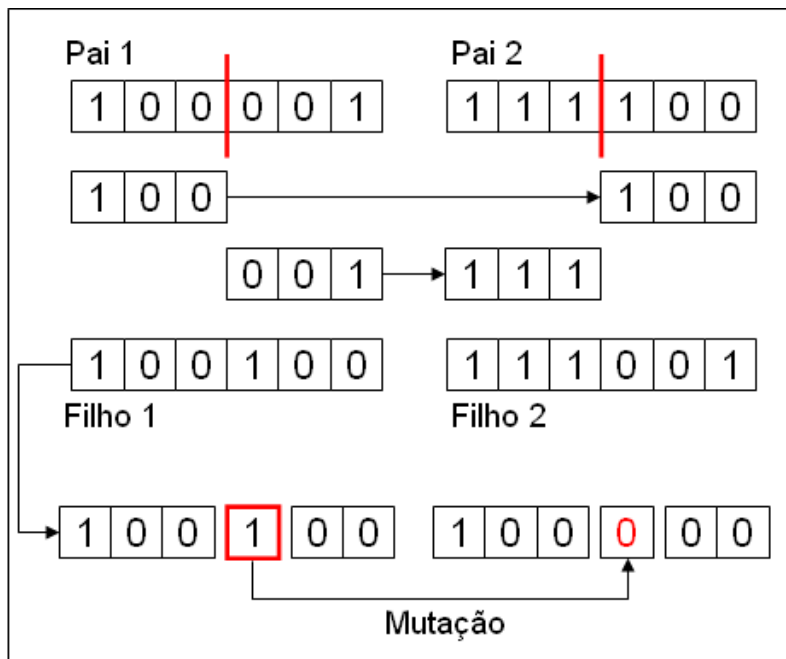
O restante (incluindo a elite) serve de banco de material genético para a produção da nova geração pelo operador genético denominado de cruzamento. Para o cruzamento se utiliza a técnica de roleta, onde dois indivíduos escolhidos aleatoriamente, sofrem intercâmbio de seu material genético para a produção de dois novos indivíduos. O Cruzamento é repetido até que a nova população esteja completa, de mesmo tamanho da população anterior.

Para garantir que novos descritores sejam utilizados, a técnica de mutação é utilizada em 5 % dos indivíduos em cada interação. Este processo determina um gene de um indivíduo da nova geração, escolhido aleatoriamente, seja invertido. A figura 6 exemplifica o processo de cruzamento e mutação.

Para cada geração nova, a função objetivo é calculada para cada indivíduo e o processo de avaliação e reprodução é repetido até que o *fitness* do indivíduo mais apto alcance um limiar pré-estabelecido pelo usuário do sistema

O resultado do processo evolutivo é um indivíduo mais apto para o problema proposto. Neste caso, a solução é um vetor de zeros e uns, apontando a ausência ou presença de cada variável. Com isto se atinge uma redução do número de descritores que servem de entrada nos modelos de classificação, sem perder a eficiência

FIGURA 6 – CRUZAMENTO E MUTAÇÃO DOS ALGORITMOS GENÉTICOS.



6.5.3 MÉTODOS DE CLASSIFICAÇÃO

Os processos de classificação estatísticos (Distância mínima, Máxima verossimilhança) ou as redes neurais, necessitam de uma fase preliminar onde são coletadas amostras de treinamento. Após esta etapa a classificação propriamente dita é efetuada, e os resultados são comparados com novas amostras, denominadas de amostras de verificação. Após a seleção dos descritores dois conjuntos de amostras são coletados, um será utilizado para treinamento dos métodos de classificação e o segundo que contém todos os segmentos da cena utilizada será utilizado na etapa de classificação.

6.5.3.1 MÉTODO DA DISTÂNCIA MÍNIMA

O primeiro passo deste método é calcular a média de cada classe através das amostras coletadas. Em seguida é calculada a distância espectral entre um segmento a ser classificado e as médias conhecidas a priori derivadas do conjunto das amostras de treinamento. O segmento será então atribuído à classe que possuir a menor distância. A equação 21 demonstra este procedimento. A equação 22 é usada como teste para executar a classificação do segmento.

$$d(x, w_j) = \sqrt{\sum_{i=1}^M (x_i - m_{i,j})^2} \quad (21)$$

Onde:

x_i – valor do segmento no descritor i ;

$m_{i,j}$ - média da classe j no descritor i ;

$$d^2(x, w_j) < d^2(x, w_k) \forall k \neq j \quad (22)$$

Para Lillesand e Kiefer (1994) este método é matematicamente simples e computacionalmente eficiente, mas existem certas limitações para o seu uso. A mais importante diz respeito à falta de sensibilidade com as diferenças de graus de variância espectral dos dados.

6.5.3.2 MÉTODO DA MÁXIMA VEROSSIMILHANÇA

O princípio deste método diz respeito a avaliar quantitativamente a variância e covariância dos padrões de resposta espectral de cada classe, ao se classificar um pixel desconhecido, (LILLESAND e KIEFER, 1994). Para se fazer isso, é assumido que a distribuição dos membros de uma classe é normalmente distribuída. O cálculo é executado segundo a equação 23:

$$g_k(X) = \ln(p(\theta_k)) - \frac{1}{2} \cdot \ln|\Sigma_k| - \left[\frac{1}{2} \cdot (X - m_k)^t \cdot \Sigma_k^{-1} \cdot (X - m_k) \right] \quad (23)$$

Onde:

$g_k(X)$ é a função discriminante;

$p(\theta_k)$ é a probabilidade da classe k ;

m_k vetor da média da classe;

Σ_k é a matriz de variância;

A decisão sobre a classificação é baseada na probabilidade condicional de um pixel pertencer a determinada classe, definida pela equação 24:

$$X \in \theta_j, \text{ caso... } g_j(X) > g_k(X) \quad (24)$$

para todo $j \neq k$

Para execução da classificação pelo método da máxima verossimilhança é utilizado o software ENVI 4.2, usando como entrada a imagem multiespectral e a banda contendo a informação altimétrica. Este classificador se baseia no pixel e não em segmentos, então os membros de uma classe são pixels, com um vetor espectral-altimétrico. Para descrever as classes, são escolhidas regiões de treinamento. Por se baseiar no pixel e não em segmentos, o resultado desta classificação será utilizado como comparação à classificação por redes neurais.

6.5.3.3 REDES NEURAIS ARTIFICIAIS

As redes neurais artificiais (RNA) pertencem ao campo da inteligência artificial e é uma técnica que tenta simular, numa forma simples, a estrutura do cérebro humano. A RNA é uma técnica de processamento de dados capaz de detectar, aprender e prever complexas relações entre quantidades numéricas, (BEULE et al. 2007).

Haykin⁸(1999) apud Castro (2007), aponta que as RNA's apresentam algumas feições e características de performance em comum com o sistema nervoso dos seres humanos:

- O processo de informação básico acontece em muitos elementos simples, denominados neurônios, nós ou unidades;
- Estes neurônios podem receber e enviar estímulos de, e para outros neurônios e o ambiente;
- Neurônios podem ser conectados a outros neurônios, formando a rede neural;

⁸ HAYKIN S.; **Neural Networks: a comprehensive foundation. 2nd ed. , Prentice-Hall, 1999.**

- Informações (sinais) são transmitidas entre neurônios via ligações chamadas sinapses;
- A eficiência da sinapse, representada por um valor de peso, corresponde a informação armazenada no neurônio dentro da rede.

O conhecimento é adquirido do ambiente através de um processo de aprendizado, que é basicamente responsável pela definição dos pesos para o estímulo do ambiente.

Na RNA, a idéia é simular o funcionamento de um neurônio usando equações matemáticas e compor uma rede de neurônios artificiais, na qual informações lógicas ou valores numéricos possam ser processados para gerar uma saída. No neurônio artificial as entradas são valores numéricos (x_1, x_2, \dots, x_n) , os quais são ponderados e somados para compor um único sinal de entrada, (RIBEIRO E CENTENO, 2005). A equação 25 demonstra este funcionamento.

$$S = b + \sum x_j * w_j \quad (25)$$

Onde:

- b é o termo “bias”, que representa uma influência externa ao neurônio;
- \sum é a função de transferência;
- w_j representa o fator de ponderação.

Segundo Botelho (2004) quem controla as saídas da RNA é a função de transferência do neurônio, ou seja, gera a informação que será repassada a outro neurônio. A função não linear – sigmóide é a mais utilizada para a classificação de imagens digitais.

A RNA pode ser treinada para resolver problemas de classificação multiespectral. Treinar uma rede significa ajustar a sua matriz de pesos (W) de forma que o vetor de saída (s) coincida com um certo valor desejado para cada

vetor de entrada (x). Também se pode fazer um paralelo com o neurônio biológico e dizer que o aprendizado é um ajuste sináptico (RIBEIRO, 2003).

6.5.3.3.1 Funcionamento da Rede Neural Artificial

A rede neural será alimentada pela classe de arquitetura com alimentação adiante (feed-forward), portanto as entradas serão propagadas pela rede até alcançarem a camada de saída. O aprendizado da rede ocorre em sentido contrário ocorrendo, uma retro-propagação (back-propagation), assim o erro calculado é propagado de volta através da rede para ajustar os pesos sinápticos (W_{ij}).

A ativação de um neurônio é controlada pela função de ativação. Neste trabalho a função de ativação será a função sigmóide (equação 26), que é uma função não-linear, tendo variação entre os valores zero e um.

$$\alpha_i = \frac{1}{1 + e^{-s_i}} \quad (26)$$

A correção dos pesos (ΔW_{ij}) é controlada pelas taxas de aprendizado η e de momento μ . Estas taxas, denominadas de bias, tem a função de manter a estabilidade da rede, evitando que a mesma se torne oscilatória. Desta forma a correção dos pesos é realizada segundo a seguinte equação 27:

$$\Delta W_{ij}(t+1) = \eta \cdot \delta_j \theta_j \mu \cdot \Delta W_{ij}(t) \quad (27)$$

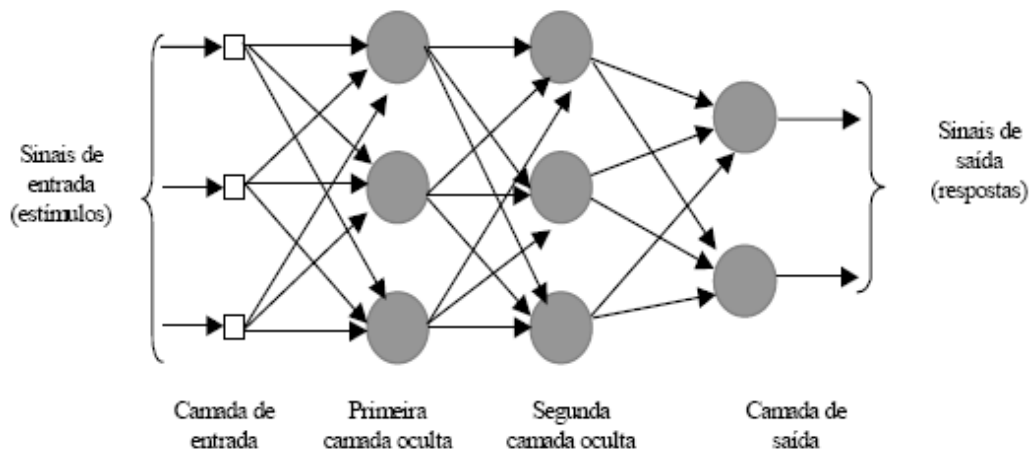
Onde:

δ_j - diferença entre a saída esperada e a saída da rede;

θ_j - saída da rede.

Na figura 7 pode ser visualizada a arquitetura da rede neural utilizada neste trabalho.

FIGURA 7 – ARQUITETURA DE UMA REDE NEURAL ARTIFICIAL)



Seguindo esta arquitetura, um algoritmo foi implementado no ambiente MATLAB para proceder a classificação pela técnica das redes neurais artificiais. Foi utilizada as funções “newff” e “trainrp” disponibilizadas na biblioteca do programa. A função “newff” reproduz a arquitetura feed-foward enquanto a “trainrp” a atualização back-propagation, assim a rotina implementada apresenta estas fases:

I) Inicialização: Informa-se ao programa o número de neurônios que se deseja na primeira e segunda camada escondida. Assim como os valores das taxas de momento e aprendizado. A rede inicializa os pesos randômicamente.

II) Entrada do arquivo de treinamento: apresenta-se a rede o arquivo de treinamento, que contém os segmentos classificados e os respectivos descritores selecionados.

III) Processamento na rede: o algoritmo computa a rede com os pesos determinados, até gerar uma saída.

IV) Atualização dos Pesos: Compara-se a saída da rede com o resultado esperado do arquivo de treinamento. O erro encontrado é propagado de volta a rede (back-propagation), atualizando-se os pesos.

V) Épocas de treinamento: Os passo III e IV são repetidos enquanto a rede não alcança um erro menor do que o pré-determinado ou não alcançar o número máximo de épocas de treinamento permitida.

VI) Verificação: Os pesos corrigidos após o passo V são guardados e utilizados em um novo grupo de amostras, gerando assim uma avaliação da rede neural. Caso o resultado alcançado seja admissível parte-se para a classificação. Caso contrario modifica-se a arquitetura da rede (número de neurônios, taxa de aprendizagem e momento) e volta-se para o passo II.


6.5.4 AVALIAÇÃO DA CLASSIFICAÇÃO

Para se conhecer a eficiência de um processo de classificação é necessário realizar uma avaliação dos resultados encontrados. Uma avaliação completa e perfeita é inviável, uma vez que não se pode conhecer o valor real de todos os pixels no terreno. Uma forma eficiente de se avaliar uma classificação é pela matriz de confusão.

A matriz de confusão é uma forma de representar as contradições entre a verdade de campo e o resultado do processo de classificação. Nesta matriz são confrontadas duas situações: as linhas correspondem à classe correta e as colunas à classe estimada no processo de classificação. Cada Célula armazena o valor dos elementos que deveriam ser classificados como a classe especificada na linha e que foram classificados segundo a classe especificada na coluna. Numa situação ideal, onde todos os elementos são classificados corretamente a matriz apresentará valores apenas na diagonal. No entanto, na maioria dos casos isto não ocorre e a quantidade de elementos incorretos é o total de elementos que aparecem fora da diagonal principal, (CENTENO, 2001).

O resultado das classificações será avaliado pelo método da matriz de confusão. Para tanto serão separadas áreas que serão investigadas in situ para servir como verdade de campo. A figura 8 apresenta o arquivo verdade de campo utilizado para validar os experimentos.

FIGURA 8 – VERDADE DE CAMPO.



O resultado obtido é confrontado com o mapa “ideal”, derivado da verdade de campo e a acurácia global é calculada a partir da matriz de confusão, como mostra a equação 28.

$$Ac.Gl = \frac{Nc}{Ntot} \tag{28}$$

Onde:

Nc - Total de elementos corretamente classificados.

$Ntot$ - total de elementos de verificação.

Uma outra avaliação dos resultados é realizada através da estatística Kappa, ou comumente conhecido Índice Kappa. Landis & Loch (1977), definem este índice como uma medida de concordância usada em escalas nominais que nos fornece uma idéia do quanto as observações se afastam daquelas esperadas, fruto do acaso, indicando-nos assim o quão legítimas as interpretações são. As equações 29 a 31 são utilizadas para definir o índice Kappa.

$$\hat{k} = \frac{\theta_1 - \theta_2}{1 - \theta_2} \quad (29)$$

Sendo:

- Concordância observada:

$$\theta_1 = \frac{\sum_{i=1}^c x_{ii}}{n} \quad (30)$$

- Concordância esperada:

$$\theta_2 = \frac{\sum_{i=1}^c x_{i+} x_{+i}}{n^2} \quad (31)$$

A interpretação do índice Kappa é sempre subjetiva, a tabela a seguir pode ser usada como parâmetro para diminuir esta subjetividade, embora alguns autores a considerem otimista.

TABELA 5 – MAGNITUDE DO ÍNDICE KAPPA. ADAPTADO DE LANDIS & LOCH (1977)

Valor de Kappa	Concordância
< 0	Péssima
0 – 0,2	Ruim
0,21 – 0,40	Razoável
0,41 – 0,60	Boa
0,61 – 0,800	Muito Boa
0,80 - 1	Excelente

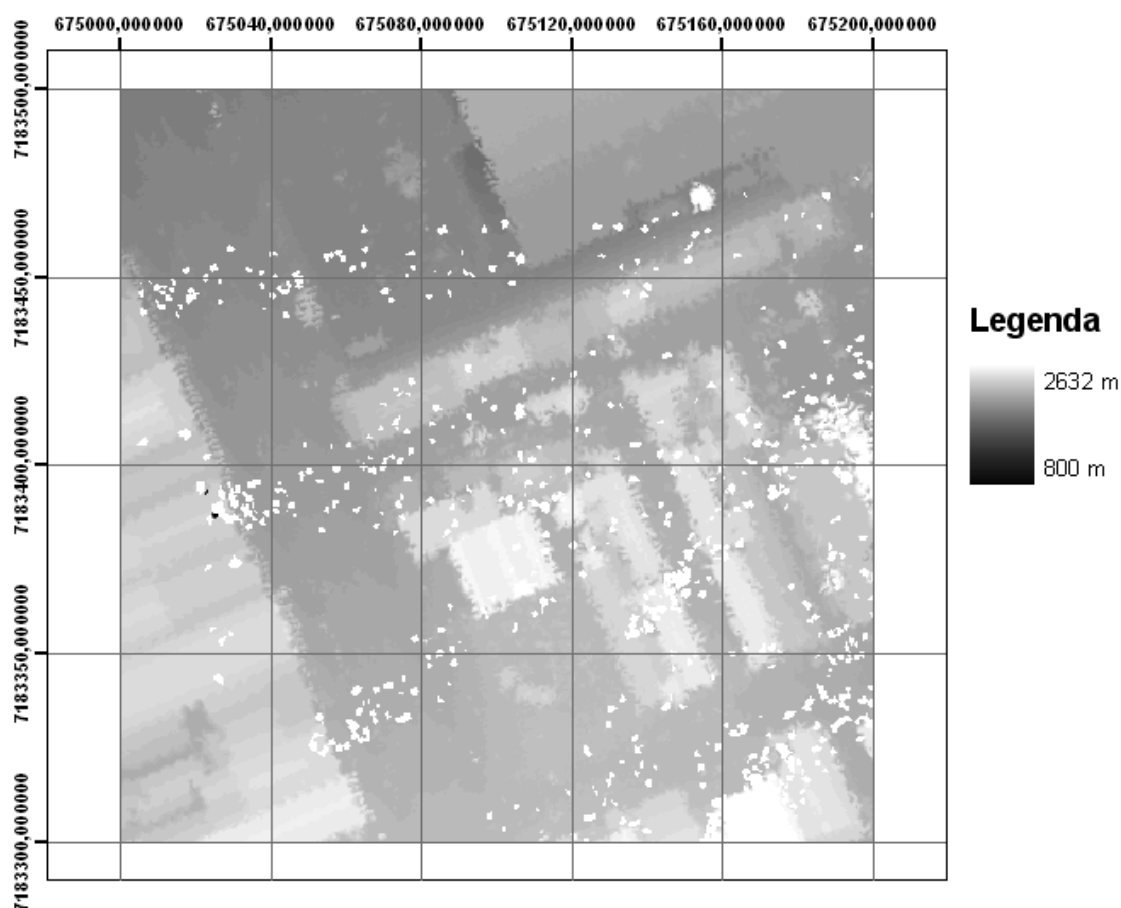
7 RESULTADOS E DISCUSSÕES

7.1 PREPARAÇÃO DOS DADOS

Inicialmente desenvolveu-se uma rotina, em ambiente MATLAB que lê o arquivo ascii, que contém os dados do levantamento do laser scanner aerotransportado. Este algoritmo atribui sobre uma grade regular, com espaçamento de cinquenta centímetros, o valor da altitude h observado durante o levantamento.

Durante o processo pode-se perceber que o levantamento apresentava alguns pontos discrepantes, com altitudes muito elevadas ou muito, figura 9.


FIGURA 9 – MDS ORIGINAL.



Pode-se perceber na figura 9 alguns pontos brancos, estes pontos apresentam cotas exageradas que não condizem com a realidade do local. Para eliminar estes pontos e executar a geração do modelo digital de superfície, MDS

e modelo digital do terreno MDT; foi utilizada a metodologia proposta por ARAKI⁹ (2005). A figura 10 apresenta o MDS sem os pontos discrepantes.

FIGURA 10 – MDS CORRIGIDO.



Os dados brutos do levantamento laser scanner foram utilizados para preencher uma grade vazia com células de 1 metro quadrado. Assim pode se verificar a real densidade do levantamento. A tabela 6, apresenta a densidade dos dados laser scanner. Pode-se perceber que mais de 83 % do levantamento apresenta menos de 3 pontos por metro quadrado. Pode-se concluir que os dados estão muito aquém do esperado para uma resolução de 0.5 m, que deveria apresentar cerca de 4 pontos por metro quadrado.

⁹ Fusão de Informações espectrais, altimétricas e de dados auxiliares na classificação de imagens de alta resolução espacial. Araki, Hideo 2005. Tese de Doutorado.


TABELA 6 – DENSIDADE DOS DADOS LASER SCANNER.

Pontos / m ²	%
0	29,7
1	33
2	21
3	9,7
4	6,5
> que 4	0,1

Outro problema encontrado nos dados laser scanner foi a falta de homogeneidade entres as diferentes faixas de vôo (figura 11). A faixa número 3 apresenta uma densidade muito inferior as demais, assim optou-se por definir a área de estudo sobre as faixas 4 e 5, que apresentam densidade na faixa de 2 a 3 pontos por metro quadrado e contém as feições de interesse desta pesquisa na superfície do terreno.

Tendo a área de interesse definida, recortaram-se as grades regulares MDS e MDT, e procedendo a subtração do MDS pelo MDT, obteve-se o MDSn ou Modelo Digital de Superfície Normalizado.

FIGURA 11 – DENSIDADE DAS DIFERENTES FAIXAS DE VÔO



Na seqüência, também em ambiente ENVI, gerou-se o NDVI (índice de vegetação por diferença normalizada), utilizando as bandas infravermelho e vermelho da ortofoto. Com base nos limites das faixas de vôo 4 e 5 recortou-se a ortofoto, o NDVI e a grade MDSn, obtendo-se assim 3 imagens da mesma área, que foram unidas em um único arquivo contendo 5 bandas, a saber:

infravermelho, vermelho, verde, NDVI e MDSn. A figura 12 apresenta as 3 imagens que formam o arquivo de dados desta pesquisa.

FIGURA 12 – EXEMPLO DOS DADOS DE ENTRADA: A. ORTOFOTO B. NDVI C. MDSN



A.)

B)

C)

7.2 ROTAÇÃO DO ESPAÇO DE CORES

7.2.1 IMAGEM QUICKIBIRD II

A imagem do satélite QuickBird II, foi utilizada para se testar o comportamento da rotação do espaço de cores, proposta por Otha et al. (1980) na classificação das feições de telhados. O procedimento adotado neste experimento foi de efetuar a rotação do espaço de cores seguindo as equações do item 5.3 nas duas combinações de bandas mais utilizadas na literatura: A combinação RGB (vermelho, verde e Azul) e IRG (infravermelho, verde e azul) ou vermelho falsa cor. Na seqüência efetua-se uma classificação pelo método da distância mínima e máxima verossimilhança. A figura 13 apresenta cada uma das combinações e suas respectivas rotações do espaço de cores.

Todas as classificações foram executadas no software ENVI, e a avaliação e matriz de confusão foram executadas em ambiente MATLAB com o auxílio do arquivo verdade de campo.

FIGURA 13 – EXEMPLO DA ROTAÇÃO DO ESPAÇO DE CORES. A) RGB B) RGB ROTACIONADO C) IRB D) IRB ROTACIONADO



TABELA 7 – CLASSIFICAÇÕES BASEADAS NO PIXEL: ACURÁCIA GLOBAL.

Combinações	Classificações	
	Mínima Distância	Máxima Verossimilhança
RGB	72.76 %	81.14 %
RGB Rotacionada	81.57 %	
IRG	79.28 %	67.52 %
IRG Rotacionada	68.67 %	

A utilização da rotação do espaço de cores trouxe um incremento ao resultado da classificação pelo método da distância mínima, alcançando resultado semelhante a classificação sem rotação pelo método da máxima verossimilhança. Por sua vez a rotação sobre a banda do infravermelho não melhorou resultando, acabando por trazer mais confusão espectral ao processo nos dois métodos utilizados.

Ao analisar-se a matriz de confusão através do índice kappa, percebe-se que a classificação com a combinação RGB é mais consistente alcançando kappa igual a 0,76 contra 0,72 da combinação RGB rotacionada.

7.2.2 ORTOFOTO

Este experimento foi realizado com o objetivo de verificar o comportamento da rotação do espaço RGB na discretização de feições, quando comparado ao espaço normal, sem a rotação.

A área de estudo é a mesma do experimento anterior, apenas o sensor foi modificado, para esta análise foi utilizada uma ortofoto da mesma área (figura 14), que foi corrigida geometricamente com base nos dados laser scanner. Um arquivo binário, denominado de máscara foi utilizado para restringir as feições de análise sobre as coberturas das edificações. A máscara foi rotulada e cada rótulo recebeu uma classificação baseada nas coberturas reais das edificações. Então este arquivo foi assumido como verdade de campo, para avaliar qualitativamente e quantitativamente a classificação.

FIGURA 14 – RECORTE DA ORTOFOTO.



Foram coletadas amostras referentes a quatro classes de coberturas de edificações encontradas na quadra de estudo. São as classes: telhado metálico, telhas de fibro cimento, telhas cerâmicas novas e telhas cerâmicas antigas.

7.2.2.1 DISTÂNCIA MÍNIMA

A figura 16 apresenta o resultado das classificações pelo método da distância mínima nos dois espaços de cores. Sendo que a figura 15a representa a classificação pelo espaço RGB, e a figura 15b a classificação com a rotação do espaço.

FIGURA 15 – CLASSIFICAÇÃO PELA DISTÂNCIA MÍNIMA. A) SEM ROTAÇÃO B) COM ROTAÇÃO



A utilização da rotação do espaço de cores melhora aproximadamente 12% na separação da feição cerâmica nova. Nas outras feições a classificação atinge os mesmos patamares alcançados com o espaço RGB sem a rotação. Os resultados podem ser vistos na tabela 8.

TABELA 8 – COMPARAÇÃO ENTRE AS CLASSIFICAÇÕES, USANDO O CLASSIFICADOR DA DISTÂNCIA MÍNIMA.

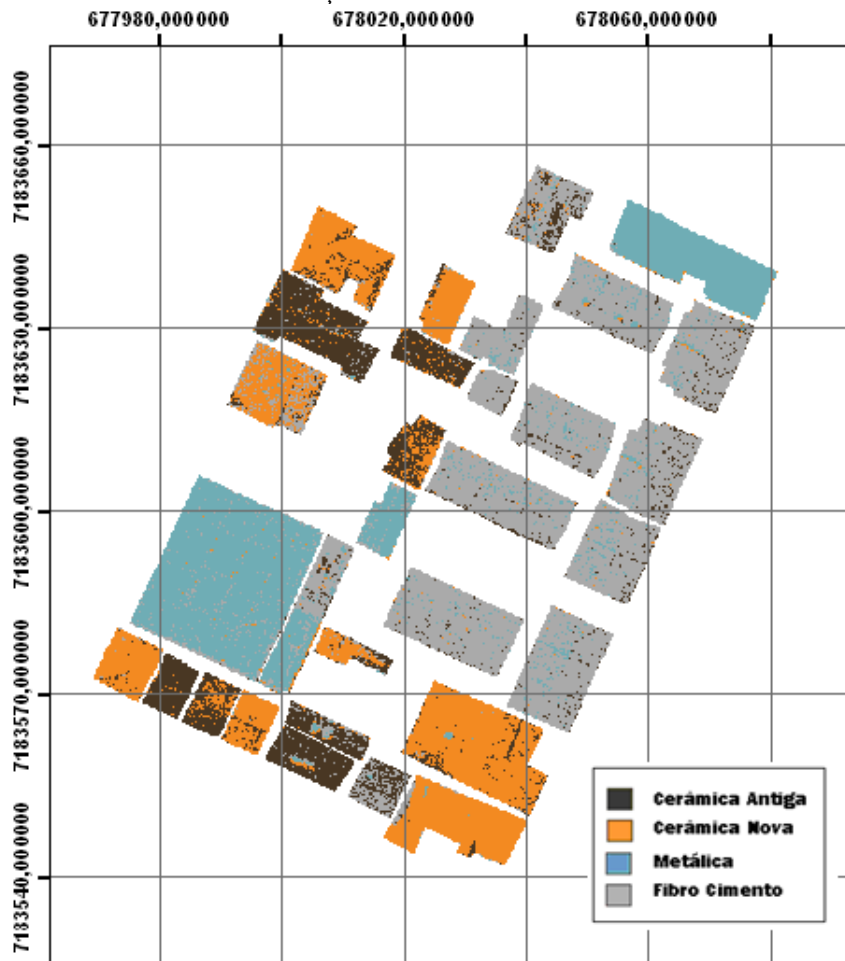
	% porcentagem de acerto
--	-------------------------

Combinação	Metálica	Fibro cimento	Cerâmica nova	Cerâmica antiga	Global
RGB	97,16	82,49	67,53	64,53	77,92
RGB rotacionado	95,53	83,50	78,67	66,47	81,04

7.2.2.2 MÉTODO DA MÁXIMA VEROSSIMILHANÇA.

A classificação pelo método da máxima verossimilhança utilizou das mesmas amostras utilizadas pelo método anterior, a figura 16 apresenta o resultado da classificação.

FIGURA 16 – CLASSIFICAÇÃO PELO MÉTODO DA MÁXIMA VEROSSIMILHANÇA



A tabela 9 mostra a comparação entre os resultados alcançados com o espaço de cores RGB e sua rotação.

TABELA 9 – CLASSIFICAÇÃO PELA MÁXIMA VEROSSIMILHANÇA..

% porcentagem de acerto

Combinação	Metálica	Fibro cimento	Cerâmica nova	Cerâmica antiga	Global
RGB	93,77	83,09	86,68	66,95	82,62

Comparando o resultado das duas classificações, percebe-se que o ganho obtido com a utilização da rotação do espaço RGB na classificação pela distância mínima é menor que a acurácia da classificação pelo método da máxima verossimilhança. Assim deve-se avaliar o comportamento da rotação do espaço RGB na segmentação multiresolução, uma vez que, em classificações baseada no pixel ela não traz melhora nos resultados.

Os resultados são semelhantes ao do experimento anterior, com isso verifica-se que a simples melhora na resolução espacial, passando de 70 centímetros na imagem de satélite para 20 centímetros da fotografia aérea não trouxe melhora no processo de classificação. Comparando-se o índice Kappa pode se comprovar este resultado, uma vez que a classificação pelo método da máxima verossimilhança, alcançou o kappa de 0,76.

7.3 INTEGRAÇÃO ESPECTRAL E ALTIMÉTRICA

7.3.1.1 CLASSIFICAÇÃO BASEADA NO ELEMENTO PIXEL

Os experimentos de classificação digital de imagens baseada no menor elemento dentro da imagem sendo o pixel, foi realizado em ambiente ENVI. As classificações foram executadas pelos métodos da distância mínima e máxima verossimilhança.

Foram extraídos dois conjuntos amostrais, através da seleção de ROI's (Regiões de interesse na imagem). As classes que foram selecionadas na imagem são: Telha de Fibro Cimento, Telhas Metálicas, Telhas Cerâmicas, Vegetação Arbórea, Vegetação rasteira, Ruas e Estacionamentos, Solo exposto e Sombra. O Resultado da classificação está sintetizado na tabela 10.

TABELA 10 – RESUMO DA CLASSIFICAÇÃO BASEADA NO PIXEL.

	MÉTODO DE CLASSIFICAÇÃO
--	-------------------------

IMAGEM	Distância Mínima	Máxima Verossimilhança
RGB	50.41 %	80.60 %
RGB+MDSn	71.50 %	86.11 %
RGB ROTACIONADA	62.85 %	81.72 %
RGB ROTACIONADA + MDSn	73.73 %	86.39 %
INFRA	62.59 %	86.72 %
INFRA + NDVI + MDSn	70.11 %	90.90 %
INFRA ROTACIONADA	56.11 %	12.50 %
INFRA ROTACIONADA + NDVI + MDSn	70.93 %	12.50 %

Deste experimento pode-se perceber uma sensível melhora da acurácia da classificação com a inclusão no processo da informação da região do infravermelho do espectro da luz visível e também com a informação altimétrica, atingindo os 90% de acerto na classificação com a inclusão destas fontes de dados.

Pôde-se concluir também que a rotação do espaço de cores efetuada por Otha ET al. (1980), só é eficiente na combinação RGB, tornando-se ineficiente quando realizada sobre a banda do infravermelho.

Restringindo a análise para as feições de telhados, utilizando para isso uma máscara e a matriz de confusão pode-se perceber que as combinações mais eficientes foram RGB+MDSn e IRG+MDSn+NDVI rotacionado, atingindo um índice kappa de 0.91 e 0.89 respectivamente, como pode ser visto na figura 17.

FIGURA 17– MATRIZ DE CONFUSÃO DA COMBINAÇÃO RGB+MDSN.

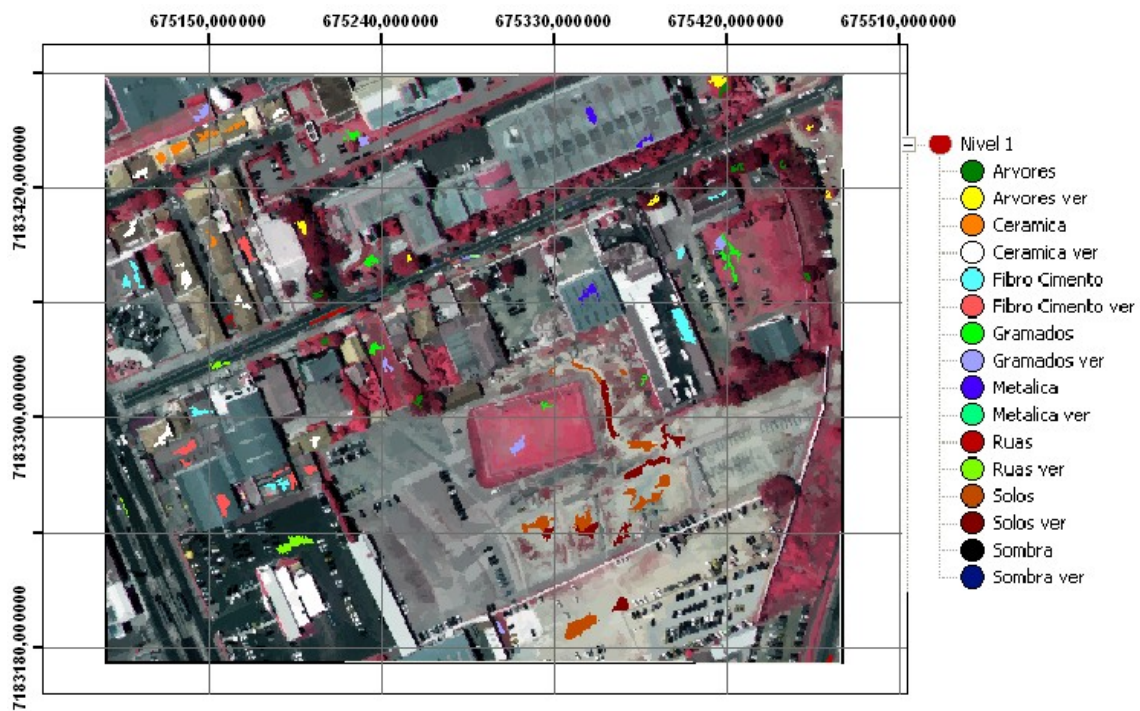


7.4 SEGMENTAÇÃO MULTIRESOLUÇÃO

O objetivo deste experimento é segmentar a fotografia aérea, produzindo assim uma série de descritores para serem utilizados nas etapas seguintes da metodologia deste trabalho. Foram definidos 3 níveis de segmentação, o primeiro utiliza apenas a banda NDVI, e gera segmentos de não vegetação e vegetação. O segundo nível tem um fator de escala menor e utiliza apenas a banda MDSn. O último nível foi realizado utilizando todas as bandas disponíveis.

Em cada nível de segmentação foram coletados dois conjuntos de amostras. O primeiro para treinamento da metodologia e o segundo para sua validação. As amostras foram definidas conforme as classes que se pretende classificar em cada nível de segmentação. A figura 18 apresenta as amostras de cada classe, coletadas em cada nível de segmentação.

FIGURA 18 – EXEMPLO DAS AMOSTRAS COLETADAS.



O software *ecognition* gera uma série de informações acerca dos segmentos produzidos, os quais chamados de descritores. Neste trabalho optou-se por trabalhar com descritores espectrais, de forma e de textura. São gerados mais de 440 descritores destes três tipos, a tabela 11 demonstra a forma como estes descritores são exportados.

TABELA 11 – EXEMPLO DOS DESCRITORES EXPORTADOS PELO ECOGNITION.

	ID	Descritores				
		MeanIRB_nd	StddevIRB	RatioIRB_n	StdDev.ton	Min.pixelv
Segmentos	0	100,69	6,95	0,22	27,55	88,00
	1	23,83	21,63	0,09	NaN	6,00
	2	81,12	26,50	0,18	49,33	19,00
	3	0,00	0,00	0,00	0,00	0,00
	4	7,50	0,50	0,03	NaN	7,00

Na tabela de descritores pode se perceber que alguns segmentos foram criados com os descritores com os valores zerados. Como no processo de seleção dos descritores e classificação dos segmentos, estes segmentos causam uma instabilidade no processo de cálculo, optou-se por retirar estes segmentos do processo. Da mesma forma alguns descritores apresentam valores “NaN” que

representam que o resultado não convergiu, por simplificação optou-se por adotar valor zero para estes descritores.

O número de descritores varia conforme a configuração do arquivo de dados no qual se processa a segmentação. No caso do nível 3, onde apenas a banda NDVI entra no processo, são produzidos 486 descritores válidos (com valores diferentes de zero). O mesmo número de descritores são gerados no nível 2, que utiliza apenas a banda MDSn. Enquanto que no nível 1, onde todas as bandas são computadas no processo, são produzidos 504 descritores.

7.5 SELEÇÃO DOS DESCRITORES

7.5.1 – FUNÇÃO OBJETIVO E NÚMERO DE DESCRITORES

Para se determinar a função mais eficiente para determinar a aptidão dos descritores no contexto desta pesquisa, um experimento foi realizado fixando o número de descritores selecionados em 15 e arbitrando-se a arquitetura da Rede Neural Artificial desta forma:

Arquitetura da RNA:

- Primeira Camada: 45 neurônios;
- Segunda Camada: 15 neurônios;
- Taxa de Momento: 0.9;
- Taxa de Aprendizado:0.2.

Neste experimento foi utilizada a imagem QuickBird II da área 2, região do centro politécnico. O teste consiste em selecionar os descritores com os Algoritmos genéticos e em seguida classificar pelas Redes Neurais Artificiais um segundo conjunto de amostras com os descritores selecionados. Os resultados estão apontados na tabela 12.

TABELA 12 – ANÁLISE DA FUNÇÃO OBJETIVO.

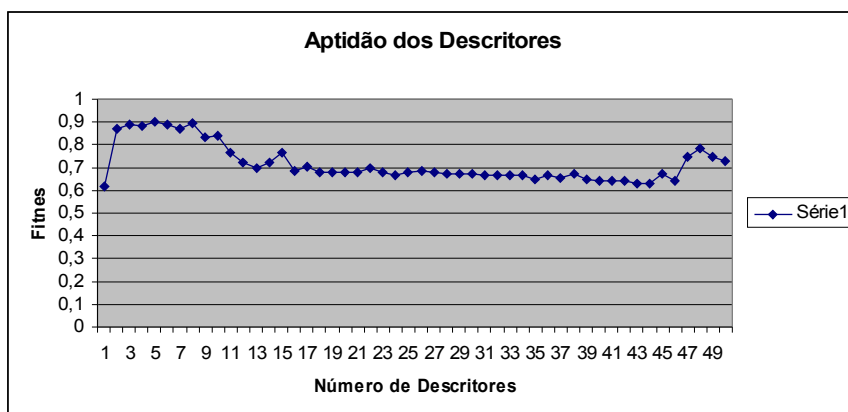
Função Objetivo	Aptidão	RNA
Discriminante de Fischer	0.976 %	0.596 %
Distância Mínima	0.888 %	0.616 %

Pode-se perceber na tabela 12 que, a função discriminante de Fischer atinge uma aptidão para os descritores selecionados maior que o método da distância mínima. No entanto este desempenho não se reflete na classificação pelas Redes Neurais. Isto acontece devido ao fato que a função discriminante é um classificador, com regras diferentes das utilizadas pela RNA, enquanto que o método da distância mínima, atua separando os descritores através da distância euclidiana o que se mostrou mais eficiente para a classificação por RNA. Nos experimentos posteriores adota-se o método da distância mínima como a função objetivo dos algoritmos genéticos.

Na seqüência uma rotina em ambiente MATLAB foi implementada para determinar o número ideal de descritores a serem selecionados pelos Algoritmos Genéticos. Para este experimento variou-se o número de descritores extraídos de 1, até 50 e com base no valor da função objetivo, determinou-se o número de descritores ideal. O tamanho da população foi arbitrado em 50 indivíduos por geração. A figura 19 apresenta o resultado deste experimento para o arquivo com a combinação IRG (Infravermelho, Vermelho e Verde) + NDVI + MDSn.

O maior valor de fitness, alcançado foi de 0.904, para um conjunto de 7 descritores selecionados. Analogamente repetiu-se o experimento para os arquivos que contém a rotação do espaço de cores. O teste com o arquivo de entrada contendo a combinação infravermelho, vermelho e verde rotacionados mais o NDVI e MDSn, alcançou fitness de 0.8136 com 7 descritores. Por sua vez o arquivo de combinação vermelho, verde e azul rotacionados mais o MDSn resultou no maior fitness com 0.863 com 10 descritores.

FIGURA 19 – GRÁFICO APTIDÃO X NÚMERO DE DESCRITORES.



7.5.2 ALGORITMOS GENÉTICOS

Após a definição do número de descritores que serão selecionados pelos algoritmos genéticos, partiu-se para a seleção dos descritores propriamente dita. Foram realizados três experimentos com cada um dos arquivos de entrada; variando o tamanho da população em 100, 500 e 1000 indivíduos.

Tendo como entrada o arquivo com 3 bandas espectrais (Infravermelho, Vermelho e Verde), mais o MDSn e o NDVI, executou-se o programa desenvolvido em ambiente MATLAB para selecionar os descritores mais aptos com os algoritmos genéticos. Para uma população de 100 indivíduos o fitness alcançado foi de 0.88%, já para as populações de 500 e 1000 indivíduos o valor de 0.904 foi encontrado para o fitness.

Pode-se perceber que mesmo utilizando uma população extremamente grande, 1000 indivíduos, quando comparada ao experimento que visava definir o número de descritores a ser selecionados que utilizou 50 indivíduos, não houve melhora no fitness encontrado no processo. A tabela 13 apresenta os descritores selecionados pelos algoritmos genéticos.

TABELA 13 – DESCRITORES SELECIONADOS: ARQUIVO 5BANDAS;

Descritor	Tipo de Dado	Banda
Rel. border to brighter neighbors	Espectral	Vermelho
Mean diff. to scene		MDSN
Mean		Vermelho
Entropy (45°)	Textura	infravermelho
Mean (135°)		Verde
Mean (135°)		NDVI
Entropy (0°)'		...

De forma análoga substituiu-se o arquivo de entrada por um contendo 4 bandas, sendo a combinação vermelho, verde e azul rotacionada mais o MDSn. O processo de seleção por Algoritmos Genéticos foi executado prevendo a seleção de 10 descritores. A população de 500 e 1000 indivíduos alcançou o maior fitness, com 0.865, melhorando a acurácia do processo em relação ao experimento de definição do número de descritores.

TABELA 14 – DESCRITORES SELECIONADOS: ARQUIVO RGB ROTACIONADO

Descritor	Tipo de Dado	Banda
Mean diff. to neighbors	Espectral	MDSn
StdDev Ratio to super-object		Verde
Homogeneity (0°)	Textura	Vermelho
Mean (90°)		MDSn
Entropy (0°)		MDSn
StdDev (90°)		Verde
Homogeneity (0°)		Azul
Contrast (0°)		Vermelho
Curvature/length (line so)	Forma	Vermelho
Elliptic Fit		-----

Da mesma forma executou-se o experimento variando o tamanho da população para o arquivo de entrada contendo a combinação infravermelho, vermelho e verde rotacionada, mais o NDVI e o MDSn. Como nos experimentos anteriores o maior valor de fitness foi alcançado com as populações de 500 e 1000 indivíduos, sendo 0.835 a maior aptidão encontrada. Este valor é maior do que a aptidão do experimento para determinação do número de descritores.

TABELA 15 – DESCRITORES SELECIONADOS: ARQUIVO INFRAVERMELHO ROTACIONADO.

Descritor	Tipo de Dado	Banda
Mean diff. to scene	Espectral	MDSn
Min. pixel value		Vermelho
Mean (45°)	Textura	NDVI
Correlation (0°)		NDVI
Contrast (135°)		Verde
Contrast (135°)		MDSn
Ang. 2nd moment (135°)		Verde

7.6 CLASSIFICAÇÃO COM REDES NEURAIAS ARTIFICIAS

7.6.1.1 DEFINIÇÃO DA ARQUITETURA DA RNA

De cada segmento criado na etapa da segmentação multiresolução são extraídos os descritores selecionados pelos algoritmos genéticos compondo assim a tabela de entrada para classificação por Redes Neurais Artificiais. Em cada uma das combinações de imagens são selecionados amostras de dois conjuntos, um para treinamento da RNA e outro para verificação do treinamento.

Seguindo a mesma seqüência utilizada nos experimentos com algoritmos genéticos, foi elaborada uma rotina em ambiente matlab que visava variar a

arquitetura da RNA, procurando um resultado ótimo para a classificação de cada imagem utilizada no processo. As melhores arquiteturas para cada combinação são apresentadas na seguinte tabela.

TABELA 16 – ARQUITETURA E ACURÁCIA DA RNA.

Arquivo	Camadas		Taxas		RNA
	1ª	2ª	momento	aprendizado	
IRG+NDVI+MDSn	30	10	0.9	0.3	76.8
RGB rotacionado	40	13	0.91	0.3	56.25
IRG+NDVI+MDSn rotacionado	85	28	0.91	0.21	63.75

Diante destes resultados ficou mais uma vez claro que a rotação do espaço de cores, seja ela no espaço RGB como no espaço IRG; não trouxe uma melhora para o processo de classificação. Portanto a combinação IRG + NDVI + MDSn será utilizada para a classificação digital desejada neste estudo, uma vez que apresentou melhores resultados, tanto na classificação baseada no pixel como nos segmentos.

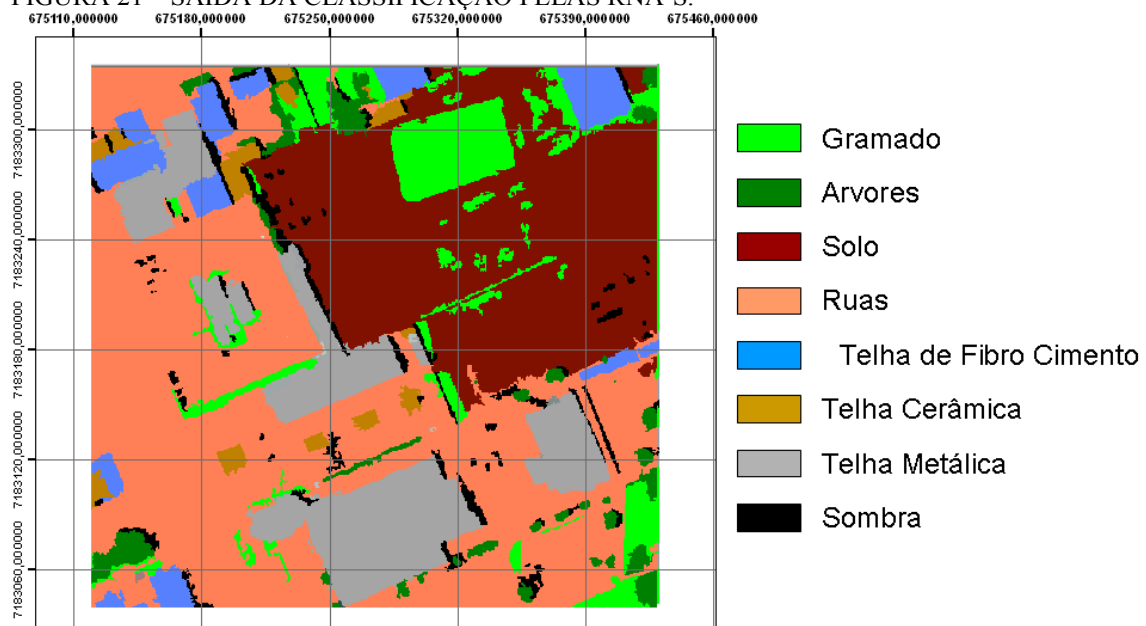
Uma região do bairro Parolin foi recortada para este experimento. Amostras de cada uma das classes esperadas foram extraídas, em dois conjuntos: treinamento e verificação. A figura 20 apresenta a área de estudo, sendo utilizada uma ortofoto, com a combinação vermelho falsa cor.

Partiu-se então para a segmentação nos 3 níveis previsto na metodologia. Na seqüência cada nível de segmentação passa por uma seleção de descritores por algoritmos genéticos e posterior classificação com redes neurais artificiais. Este procedimento foi realizado para aproveitar a herança de um nível para outro. Desta forma os descritores do nível 2 tiveram a classificação do nível 3 incorporada a sua base de dados como um novo descritor. Analogamente a classificação do nível 3 e nível 2 foi adicionada ao nível 1. A classificação por RNA resultou em uma taxa de acerto de 0.928% com índice kappa de 0.917. Na imagem 21, esta apresentado o resultado desta classificação.

FIGURA 20 – ÁREA RECORTADA PARA CLASSIFICAÇÃO.

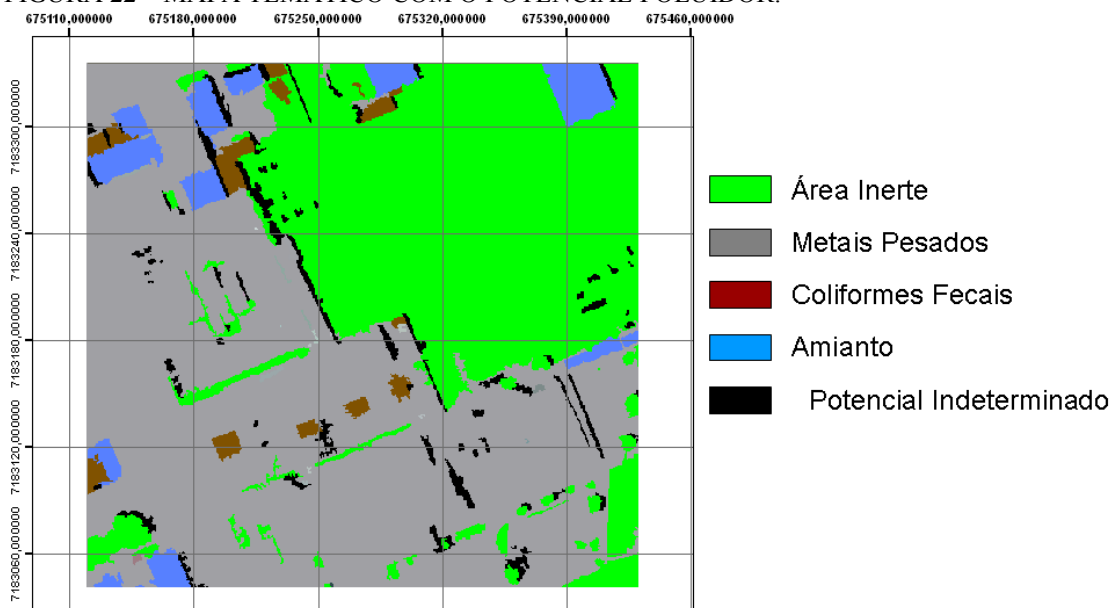


FIGURA 21 – SAÍDA DA CLASSIFICAÇÃO PELAS RNA'S.



Combinando o resultado da classificação com a associação dos poluentes com cada material sintético encontrado na literatura, pode-se produzir um mapa temático que apresente o potencial poluidor de cada região presente na superfície física estudada. Assim temos a figura 22:

FIGURA 22 – MAPA TEMÁTICO COM O POTENCIAL POLUIDOR.



Tendo como base esta classificação pode-se quantificar a área de cada poluente presente na região estudada:

TABELA 17 – ÁREA POTENCIALMENTE POLUIDORA.

Poluente	Área	%
Potencial Inerte	30.404,06	33,08
Amianto	4.114,83	4,48
Metais Pesados	50.774,12	55,25
Coliformes Fecais	1.802,24	1,96
Pontencial Indeterminado	4.805,70	5,23

8 CONCLUSÕES E RECOMENDAÇÕES

A metodologia desenvolvida neste trabalho possibilitou a discretização dos diferentes telhados presentes em uma cena urbana. Sabendo quais materiais estão presentes em uma determinada região, se torna possível prever a quais tipos de riscos de poluição os corpos de água da mesma região estão expostos. Esta informação é útil para auxiliar os profissionais de recursos hídricos à tomada de decisão no gerenciamento de uma bacia hidrográfica. Durante a elaboração e execução deste trabalho, algumas conclusões puderam ser tomadas.

A integração de diferentes fontes de informações como imagens espectrais e dados altimétricos foi decisiva para melhorar o processo de classificação digital das imagens da região estudada. A inclusão da informação da região do infravermelho do espectro da luz visível se torna melhor aproveitada na forma de índice de vegetação (NDVI) do que como informação isolada.

A comparação entre os experimentos com a imagem do satélite QuickBird II e a fotografia aérea do centro politécnico, mostrou que na combinação RGB as diferenças de resolução espacial entre os sensores não foi um diferencial para a melhoria da classificação. No caso da melhor resolução espectral da imagem QuickBird o incremento na qualidade da classificação foi sentido.

Foi possível perceber também a grande contribuição da inclusão da informação altimétrica para separar as feições de telhado. Isto ocorreu principalmente na diminuição da confusão espectral entre as classes telhados de fibro cimento e ruas. Embora os dados altimétricos disponíveis apresentassem uma série de problemas, ficou claro a sua importância como diferencial para classificação e redes neurais artificiais. Outro ponto a salientar é a ineficiência da rotação para a banda do infravermelho próximo, sua utilização aumentou a confusão espectral entre as classes estudadas.

O processo de seleção de descritores mostrou o peso dos descritores de textura e espectrais no processo de classificação de feições. Estes dois tipos de descritores foram selecionados em mais de 95% dos experimentos, destacando a ineficiência dos descritores de forma, para as feições estudadas neste trabalho. A

seleção de descritores por algoritmos genéticos não alcançou os resultados esperados para a classificação final por RNA, em uma segmentação direta. Embora o resultado com a herança dos níveis hierárquicos mais grosseiros se mostrou bastante promissora.

Nos experimentos realizados a classificação por RNA se mostrou mais robusta que os outros métodos, apresentando índices kappa muito elevados. A RNA também se mostrou mais eficiente para separar as feições de telhados das demais feições encontradas na imagem. Já entre as classes de telhado, as maiores dificuldades de separação ocorreu entre as classes de fibro cimento e cerâmica antiga, devido ao fato de com o envelhecimento das telhas as duas apresentam coloração escura.

Recomenda-se em trabalhos futuros a integração com informações hidrológicas e de qualidade da água de escoamento superficial, tanto de edificações como de ruas.

O processo de seleção de atributos por algoritmos genéticos pode ser melhorado com a inclusão de uma função objetivo que prepara melhor os dados para a classificação posterior.

Em trabalhos futuros recomenda-se também a utilização de levantamentos laser scanner sincronizados com a informação espectral com a qual se pretende fazer a integração. das feições estudadas.

A avaliação da densidade dos dados laser scanner aerotransportados se mostrou importante, uma vez que este item reflete na qualidade dos modelos digitais de superfície executados e teve reflexos na segmentação das imagens.

A rotação do espaço de cores se mostrou eficiente para a classificação com o método da mínima distância, muito embora os resultados ficassem inferiores aos alcançados com métodos mais robustos de cálculo com máxima verossimilhança

REFERÊNCIAS

ACKERMANN, F.; **Airborne laser scanning – present status and future expectations**. In ISPRS Journal of Photogrammetry & Remote Sensing 54; 64-67 p.; 1999.

AKAN, A. O.; HOUGHTALEN R. J. **Urban hydrology, hydraulics, and stormwater quality**. 373 p. New Jersey, USA. 2003.

ARAKI, H. **Fusão de informações espectrais, altimétrica e de dados auxiliares na classificação de imagens de alta resolução espacial**. Tese de Doutorado, UFPR, 2005.

BAATZ, M.; SCHÄPE, A. **Object-oriented and multi-scale image analysis in semantic networks**. Munique, 1999.

BASSANI, C.; CAVALLI, R. M.; CAVALCANTE, F.; CUOMO, V.; PALOMBO, A.; PASCUCCI, S.; PIGNATTI, S. **Deterioration status of asbestos-cement roofing sheets assessed by analyzing hyperspectral data**. In Remote Sensing of Environment, 2007.

BEULE M. de; MAES, E., WINTER, O. de; VANLAERE, W.; IMPE, R. V.; **Artificial neural networks and risk stratification: A promising combination**, In Mathematical and Computer Modeling 46, 88-94 p. 2007.

BLASCHKE, T.; HAY G. J. **Object-Oriented Image analysis and scale-space: Theory and methods for modeling and evaluating multiscale landscape structures**. 2001.

BOTELHO, M. F.; **Aplicação de redes neurais na classificação de imagens de alta resolução espacial e dados do laser scanner, usando uma abordagem orientada a regiões**, dissertação de mestrado, apresentada na Universidade Federal do Paraná, 2004.

BOTELHO, M. F.; CENTENO, J. A. S.; **Uso integrado de imagem de alta resolução espacial e altura derivada do laser scanner na escolha do classificador orientado a região**. No boletim de Ciências Geodésicas; vol 11, nº 1, (2005).

BRAGA, B.; HESPANHOL, I.; CONEJO, J. G. L.; MIERZWA, J. C.; BARROS, M. T. L, de; SPENCER, M.; PORTO, M.; NUCCI, N.; JULIANO, N.; EIGER, S. **Introdução a engenharia ambiental. O desafio do desenvolvimento sustentável.** 2 Ed. 318 p., São Paulo, 2005.

BUTZ, J., & FUCHS, S. **Estimation of sealed surfaces in Urban areas and the impact on calculated annual pollution load due to combined sewer overflows.** Symposium Remote Sensing of Urban areas, 35-40 p. Resenburg, 2003.

CASTRO, L. N.; **Fundamentals of natural computing: an overview.** In Physics of Life Reviews 4, 1-36 p. 2007.

CENTENO, J. A. S; **Sensoriamento remoto e processamento de imagens digitais,** Universidade Federal do Paraná, 2001.

CHANG, M.; McBROOM, M. W.; BEASLEY, R. S.; **Roofing as a source of nonpoint water pollution,** in Journal of Environmental Management 73, 307-315 p. (2004).

Chaves e Bowek, **Comparasion of Spectral information content of Landsat thematic mapper and SPOT for three different sites in Phoenix,** Photogrammetric Engineering and Remote Sensing 54(12):1699-1708 p. (1988).

CURRAN, P. J. **Principles of remote sensing.** New York, 1985.

EKSTRAND, S.; ÖSTLUND, P; HANSEN, C; **Digital air photo processing for mapping of copper roof distribution and estimation of related copper pollution,** in Water, Air and Soil Pollution: Focus 1, 267-278 p. 2001.

EUROPEAN UNION, 2000. **Directive 2000/60/EC of the European Parliament and of the Council of 23 October 2000 establishing a framework for Community action in the field of water policy.** Official Journal of the European Communities, L327, 22.12.2000, pp 1-72

FIGUEROA, D. M.; O-VILLANUEVA, M. de; PARRA, M. L. de la; **Heavy metal distribution in dust from elementary schools in Hermosillo, Sonora, México,** in Atmospheric Environment 41, 276-288 p.; 2007.

GARCEZ, L. N.; ALVAREZ, G. A.; **Hidrologia.** 2 Ed. 291 p. São Paulo, 1988.

GNECCO, I.; BERRETTA, C.; LANZA, L. G.; BARBERA, P. La; **Storm water pollution in the urban environment of Genoa, Italy.** In Atmospheric Reserch 77, 60-73 p.; 2005.

GONZALEZ, R. C.; WOODS, R. E. **Processamento de imagens digitais**, Ed. Edgar Blucher Ltda. São Paulo 2000.

HUISING E. J. PEREIRA L. M. **Errors and accuracy estimates of laser data acquired by various laser scanning systems for topographic applications.** ISPRS Journaul of Photogrammetry & Remote sensing 53, 245-261 p. 1998.

KIEMA, J. B. K.; BÄHR, H. -P.; **Fusion of colour infrared imagery and airborne laser scanning data in the automatic classification of urban environments.** Na revista Brasileira de cartografia 52, 29-36 p. 2000.

LANDIS, J.R. e KOCH, G.G. **The measurement of observer agreement for categorical data.** *Biometrics*, v.33, n.1, p. 159-174, 1977.

LEITÃO, T. E.; **Impact of road runoff in soil and groundwater. Synthesis of Portuguese and other European case-studies.** In The Fourth Inter-Celtic Colloquium on Hydrology and Management of Water Resources, Portugal, 2005.

LEMP, D.; WEIDNER, U.; **Use of hyperspectral and laser scanning data for the characterization of surfaces in urban areas,** in XXth ISPRS Congress, Istambul, Turquia, 2004.

LILLESAND, T. M.; KIEFFER, R. W.. **Remote sensing and image interpretation.** John Wiley & Sons. 3a Ed. New York, EUA. 750p, 1994.

LOHR, U.; EIBERT, M. **The topSys laser scanner – system,** in Photogrammetric week' 95, Heidelberg, 1995.

MCINTOSH, K.; KRUPNIK, A.; SCHENK, T.; **Improvement of automatic DSM generation over urban áreas using airborne laser scanner data.** In Internation archives of photogrammetry and remote sensing, 563-570 p, 2000.

METRE P. C. V.; MAHLER, B. J.; **The contribution of particles washed from rooftops to contaminant loading to urban streams,** in Chemosphere 53, 2003.

OHTA, Y.; KANADE, T.; SAKAI, T.; **Color information for Region Segmentation**, in Computer Graphics and image processing 13, 222-241 p. (1980).

PARK, MI-H.; STENSTROM, M. K.; **Using satellite imagery for stormwater pollution management with Bayesian networks**. In Water Reserch, 40, 3429-3438 p. 2006.

QUEK, U.; FÖRSTER, J.; **Trace metals in roof runoff**. in Water, Air and Soil pollution, 68, 373-389 p., 1993).

RIBEIRO, S. R. A.; **Integração de imagens Landsat TM e dados auxiliares para a delimitação automática de unidades fisionômicas (paisagem) e geológicas usando redes neurais artificiais**. Tese de doutorado apresentada na Universidade Federal do Paraná, 2003.

RIBEIRO, S. R.; CENTENO, J. A. S.; **Utilização de redes neurais artificiais na separação de unidades fisionômicas (paisagens) mediante imagens orbitais e dados complementares**, no IV Colóquio Brasileiro de Ciências Geodésicas, 2005.

SONKA, M; HLAVAC, V.; BOYLE, R. **Image processing, analysis, and machine vision**. Ed. PWS Publishing, Pacific Grove, CA 1999.

TUTTI, C. E. M., **Hidrologia ciência e aplicação**. 943 p. São Paulo, 1993.

YAZIZ, M. I.; GUNTING, H.; SAPARI, N.; GUAZALI, A. W. **Variations in rainwater quality from roof catchments**, IN Water Reserch, 23. 761-765 p. 1989.

YIN, Z. Y.; WALCOTT, S.; KAPLAN, B.; CAO, J.; LIN, W.; CHEN, M.; LIU, D.; NING, Y.; **An analysis of the relationship between spatial patterns of water quality and urban development in Shangai, China**. In Computers, Environmental and Urban Systems 29, 197-221p. 2005.

ZORTEA, M.; HAERTEL, V.; CLARKE, R. T. **Investigação sobre métodos para redução da dimensionalidade dos dados em imagens hiperspectais**. Revista brasileira de cartografia n°57/01, p. 36-42, 2005.

Livros Grátis

(<http://www.livrosgratis.com.br>)

Milhares de Livros para Download:

[Baixar livros de Administração](#)

[Baixar livros de Agronomia](#)

[Baixar livros de Arquitetura](#)

[Baixar livros de Artes](#)

[Baixar livros de Astronomia](#)

[Baixar livros de Biologia Geral](#)

[Baixar livros de Ciência da Computação](#)

[Baixar livros de Ciência da Informação](#)

[Baixar livros de Ciência Política](#)

[Baixar livros de Ciências da Saúde](#)

[Baixar livros de Comunicação](#)

[Baixar livros do Conselho Nacional de Educação - CNE](#)

[Baixar livros de Defesa civil](#)

[Baixar livros de Direito](#)

[Baixar livros de Direitos humanos](#)

[Baixar livros de Economia](#)

[Baixar livros de Economia Doméstica](#)

[Baixar livros de Educação](#)

[Baixar livros de Educação - Trânsito](#)

[Baixar livros de Educação Física](#)

[Baixar livros de Engenharia Aeroespacial](#)

[Baixar livros de Farmácia](#)

[Baixar livros de Filosofia](#)

[Baixar livros de Física](#)

[Baixar livros de Geociências](#)

[Baixar livros de Geografia](#)

[Baixar livros de História](#)

[Baixar livros de Línguas](#)

[Baixar livros de Literatura](#)
[Baixar livros de Literatura de Cordel](#)
[Baixar livros de Literatura Infantil](#)
[Baixar livros de Matemática](#)
[Baixar livros de Medicina](#)
[Baixar livros de Medicina Veterinária](#)
[Baixar livros de Meio Ambiente](#)
[Baixar livros de Meteorologia](#)
[Baixar Monografias e TCC](#)
[Baixar livros Multidisciplinar](#)
[Baixar livros de Música](#)
[Baixar livros de Psicologia](#)
[Baixar livros de Química](#)
[Baixar livros de Saúde Coletiva](#)
[Baixar livros de Serviço Social](#)
[Baixar livros de Sociologia](#)
[Baixar livros de Teologia](#)
[Baixar livros de Trabalho](#)
[Baixar livros de Turismo](#)