



UNESP – UNIVERSIDADE ESTADUAL PAULISTA
CAMPUS DE PRESIDENTE PRUDENTE
FACULDADE DE CIÊNCIAS E TECNOLOGIA
PROGRAMA DE PÓS GRADUAÇÃO EM CIÊNCIAS CARTOGRÁFICAS

FRANCIELE MARQUES TOLENTINO



**ANÁLISE DO DESEMPENHO DE REDES NEURAIS ARTIFICIAIS NO
MONITORAMENTO SAZONAL DE MACRÓFITAS NO RESERVATÓRIO DE SALTO
GRANDE E NAS MUDANÇAS NO USO E COBERTURA DA TERRA DO ENTORNO**

PRESIDENTE PRUDENTE
2019



UNESP – UNIVERSIDADE ESTADUAL PAULISTA
CAMPUS DE PRESIDENTE PRUDENTE
FACULDADE DE CIÊNCIAS E TECNOLOGIA
PROGRAMA DE PÓS GRADUAÇÃO EM CIÊNCIAS CARTOGRÁFICAS

FRANCIELE MARQUES TOLENTINO

ANÁLISE DO DESEMPENHO DE REDES NEURAIS ARTIFICIAIS NO
MONITORAMENTO SAZONAL DE MACRÓFITAS NO RESERVATÓRIO DE SALTO
GRANDE E NAS MUDANÇAS NO USO E COBERTURA DA TERRA DO ENTORNO

Dissertação apresentada ao Programa de Pós-
Graduação em Ciências Cartográficas da
FCT/Unesp – Campus de Presidente Prudente.

Orientador: Profa. Dra. Maria de Lourdes
Bueno Trindade Galo

PRESIDENTE PRUDENTE
2019

FICHA CATALOGRÁFICA

T649a

Tolentino, Franciele Marques

Análise do desempenho de redes neurais artificiais no monitoramento sazonal de macrófitas no reservatório de Salto Grande e nas mudanças no uso e cobertura da terra do entorno. / Franciele Marques Tolentino. -- Presidente Prudente, 2019

94 f.

Dissertação (mestrado) - Universidade Estadual Paulista (Unesp), Faculdade de Ciências e Tecnologia, Presidente Prudente

Orientadora: Maria de Lourdes Bueno Trindade Galo

1. Redes neurais artificiais. 2. Reservatório de Salto Grande. 3. Uso e cobertura da terra. 4. Galo, Maria de Lourdes Bueno Trindade. 5. Universidade Estadual Paulista. Faculdade de Ciências e Tecnologia. I. Título.



UNIVERSIDADE ESTADUAL PAULISTA

Câmpus de Presidente Prudente


CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: ANÁLISE DO DESEMPENHO DE REDES NEURAIS ARTIFICIAIS NO MONITORAMENTO SAZONAL DE MACRÓFITAS NO RESERVATÓRIO DE SALTO GRANDE E NAS MUDANÇAS NO USO E COBERTURA DA TERRA DO ENTORNO

AUTORA: FRANCIELE MARQUES TOLENTINO

ORIENTADORA: MARIA DE LOURDES BUENO TRINDADE GALO

Aprovada como parte das exigências para obtenção do Título de Mestra em CIÊNCIAS CARTOGRÁFICAS, área: Aquisição, Análise e Representação de Informações Espaciais pela Comissão Examinadora:


Profa. Dra. MARIA DE LOURDES BUENO TRINDADE GALO
Departamento de Cartografia / Faculdade de Ciências e Tecnologia de Presidente Prudente


Prof. Dr. MILTON HIGOKAZU SHIMABUKURO
Departamento de Matemática e Computação / Faculdade de Ciências e Tecnologia de Presidente Prudente


Profa. Dra. LETÍCIA SABO BOSCHI
Campus Experimental de Rosana / Campus Experimental de Rosana

Presidente Prudente, 01 de março de 2019

*Aos meus pais, Aparício e
Geralda, e meus irmãos, Venício,
Fabricio e Daniele, por todo o amor
e dedicação.*

AGRADECIMENTOS

Ao meu pai, que se doa por inteiro e renuncia dos seus sonhos para que muitas vezes realize os meus, não bastaria um muito obrigada. A minha mãe, pelo amor, incentivo e apoio incondicional. E aos meus irmãos que sempre se fizeram presentes.

À minha orientadora Prof.^a Dra. Maria de Lourdes pela paciência, conhecimento compartilhado, confiança e por todo o tempo dedicado. Sempre solícita me auxiliou e minimizou as minhas dúvidas.

Aos amigos que a UNESP me trouxe e hoje são minha segunda família: Carol Campos, Guil, Gabi, Vivi, Renato, Gui Cardim, Mari Campos, Gabriel e Ana pelas conversas, discussões e apoio.

Com muito amor, ao Guilherme pelo companheirismo, incentivo, amizade e dedicação. Obrigada por sempre me apoiar e me dar forças para continuar.

Ao meu grande amigo Luís, companheiro nos momentos mais difíceis, obrigada pela amizade.

À Cida e Zilda por sempre zelarem por nosso ambiente de trabalho.

Ao Programa de Pós-Graduação em Ciências Cartográficas (PPGCC), à Universidade Estadual Paulista (UNESP) pela infraestrutura fornecida.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

RESUMO

As formas de uso e cobertura da terra no entorno de corpos d'água é um dos fatores que mais impactam águas continentais. Diante disso, é que ambientes aquáticos se tornam cada vez mais susceptíveis a processos de eutrofização, o que favorece a proliferação de macrófitas. Uma maneira de monitorar a proliferação de macrófitas, assim como alterações nas formas de uso e cobertura da terra no entorno de reservatórios é a partir de dados de sensoriamento remoto. Sensores remotos surgem como uma alternativa com grande potencial para a análise da variabilidade espaço-temporal de macrófitas aquáticas. Classificadores baseados em aprendizado máquina são cada vez mais utilizados em alternativa às técnicas tradicionais, uma vez que alguns desses algoritmos não requerem a distribuição estatística dos dados permitindo assim a inclusão de atributos não espectrais no processo de classificação. Este estudo teve por objetivo avaliar o potencial de redes neurais artificiais (RNAs) no monitoramento sazonal da dispersão de macrófitas aquáticas no reservatório de Salto Grande, Americana (SP), simultaneamente às alterações no uso e cobertura da terra do seu entorno. No processo de classificação, foram realizados diversos experimentos a fim de selecionar os atributos e arquiteturas de RNA mais adequados para discriminar tanto as macrófitas no corpo hídrico, quanto os tipos de uso e cobertura da terra no seu entorno. Os dados de entrada constituíram-se de bandas espectrais do sistema OLI/Landsat-8, imagens de textura derivadas das imagens OLI, índices espectrais normalizados para realce da vegetação (NDVI), teor de umidade (MNDWI) e áreas construídas (NDBI), imagens resultantes da transformação RGB - IHS (componente matiz (H) e saturação (S)), além de um Modelo Digital de Elevação (MDE). Foram avaliadas as arquiteturas [21-27-14-6], [13-19-10-6] e [11-17-9-6], sendo observado que uma arquitetura mais enxuta pode apresentar melhor desempenho. O método proposto se mostrou adequado na detecção de macrófitas, com acurácia de 0,9829. No entanto, o mapeamento das classes de uso e cobertura da terra foi prejudicado por significativas variações sazonais e espectrais presentes nas cenas. Diante disso, é necessário analisar cuidadosamente os dados de entrada, para que grandes variações espectrais e/ou sazonais não camuflam informações importantes no processo de classificação. Por fim, os resultados obtidos mostraram que o MDE foi determinante na identificação das áreas com presença de macrófitas, visto que não foram identificadas grandes áreas classificadas como macrófitas fora do contexto do reservatório. Além disso, a estratégia de generalização temporal da RNA apresentou resultados adequados, e pode ser utilizada como uma alternativa à análise multitemporal de alvos.

Palavras chave: Redes neurais artificiais; macrófitas; OLI/Landsat-8.

ABSTRACT

The land use/cover surrounding water bodies is one of the factors that most impact continental waters. Thus, aquatic environments become increasingly susceptible to eutrophication processes, which favors the growth of macrophytes. One way to monitor the growth of macrophytes as well as changes in the forms of land use/cover surrounding reservoirs, is from remote sensing data. Remote sensors emerge as an alternative with great potential for the analysis of spatio-temporal variability of aquatic macrophytes. Classifiers based on machine learning are alternatives increasingly used in detriment to traditional techniques. Those algorithms do not require the statistical distribution of the data, thus allowing the inclusion of non-spectral attributes in the classification process. In this sense, this work aims to evaluate the potential of artificial neural network (ANN) in the seasonal monitoring of aquatic macrophytes dispersion in Salto Grande, Americana (SP), simultaneously with the changes monitoring in the land use/cover of the surrounding areas. In the classification process, several experiments were performed to select the most appropriate attributes, as well as the best ANN architecture to discriminate the macrophytes in the water body and the types of land use/cover of the surrounding. The input data consisted of OLI / Landsat-8 system spectral bands, texture images derived from OLI images, normalized spectral indices for vegetation enhancement (NDVI), moisture content (MNDWI) and built-up areas (NDBI), images resulting from the RGB - IHS transformation (hue and saturation component), as well as a Digital Elevation Model (DEM). The architectures evaluated were [21-27-14-6], [13-19-10-6] and [11-17-9-6], and it was observed that a lean architecture may perform better. The proposed method was adequate for detecting macrophytes, with an accuracy of 0.9829, but the mapping of the land use/cover categories was affected by significant seasonal and spectral variations present in the scenes. Thus, it is necessary to carefully analyze the input data, so that large spectral and/or seasonal variations do not camouflage important information in the classification process. Finally, the results showed that the DEM was relevant in the identification of areas with presence of macrophytes, since no large areas classified as macrophytes outside the context of the reservoir were identified. In addition, the ANN temporal generalization presented adequate results, and can be used as an alternative to the multitemporal analysis of targets.

Keywords: Artificial neural networks; macrophytes; OLI / Landsat-8.

SUMÁRIO

1 INTRODUÇÃO	12
1.1 Considerações Iniciais	12
1.2 Justificativa	13
1.3 Objetivos	15
1.4 Estado da Arte	15
2 EXTRAÇÃO DE INFORMAÇÃO A PARTIR DE DADOS DE SENSORIAMENTO REMOTO	18
2.1 Comportamento Espectral de Alvos	19
2.2 Índices Espectrais	21
2.3 Transformação de imagens no espaço de cores	22
2.4 Classificação de imagens multiespectrais	24
2.5 Análise da qualidade de classificações	29
3 MAPEAMENTO DO USO E COBERTURA DA TERRA	33
4 MATERIAIS E MÉTODOS	36
4.1 Área de estudo	36
4.2 Materiais	37
4.2.1 Dados espectrais e não espectrais	37
4.2.2 Ferramentas computacionais	39
4.3 Método de classificação proposto	40
4.3.1 Aquisição dos dados multiespectrais OLI/Landsat 8	40
4.3.2 Recorte das imagens para a área de estudo	42
4.3.3 Geração de índices espectrais, imagens de textura e componentes IHS	43
4.3.4 Aplicação de RNAs na classificação dos dados	44
4.3.4.1 <i>Definição das classes de saída da RNA</i>	46
4.3.4.2 <i>Definição e aquisição das amostras para treinamento da RNA</i>	47
4.3.4.3 <i>Caracterização espectral e textural dos dados de treinamento por classe</i>	49
4.3.4.4 <i>Geração dos arquivos de treinamento no formato ARFF</i>	55
4.3.4.5 <i>Treinamento e simulações das arquiteturas de RNA</i>	56
4.3.4.6 <i>Aplicação da rede treinada para classificação das imagens sazonais</i>	58
4.3.4.7 <i>Geração das imagens resultantes da classificação</i>	58
4.4 Estimativa da exatidão das cenas classificadas e análise da incerteza do processo de classificação	59
5 RESULTADOS	61
5.1 Arquitetura de redes neurais artificiais utilizadas	61

5.2 Desempenho das redes neurais utilizadas na classificação da cena de Jun/2015	62
5.3 Imagens sazonais classificadas com a arquitetura definida para Jun/2015	65
6 CONCLUSÕES E RECOMENDAÇÕES	84
REFERÊNCIAS	86

LISTA DE FIGURAS

Figura 1 - Interação da radiação eletromagnética com os alvos	19
Figura 2 – Comportamento espectral da vegetação	20
Figura 3 - Modelo de cores IHS	23
Figura 4 – Modelo de um neurônio artificial	26
Figura 5 - Modelo de rede neural com uma camada escondida	26
Figura 6 – Representação de uma matriz de confusão	30
Figura 7 - Diferença entre uso e cobertura da terra	33
Figura 8 - Esquema teórico de construção da nomenclatura da cobertura terrestre	34
Figura 9 - Localização do Reservatório de Salto Grande – SP.	36
Figura 10 - Atividades realizadas visando a constituição da base de dados de entrada para a classificação	40
Figura 11 – Órbitas-ponto que recobrem a área de estudo.	41
Figura 12 - Hietograma para o período de 1985 – 2016 para o município de Americana-SP. As setas vermelhas indicam períodos representativos da área de estudo, sendo considerados para aquisição de imagens	42
Figura 13 - Recorte Espacial da área de estudo – entorno do reservatório de Salto Grande (SP).	43
Figura 14 - Atividades desenvolvidas no processo de classificação das imagens	45
Figura 15 - Representação da definição do arquivo ASCII	47
Figura 16 - Amostras de treinamento obtidas através do Envi	48
Figura 17 - Variabilidade espectral das classes nas bandas OLI2 (azul), OLI3 (verde), OLI4 (vermelho), OLI5(infravermelho próximo), OLI6 (infravermelho de ondas curtas 1), OLI6 (infravermelho de ondas curtas 2) do sensor OLI/Landsat 8. AC é Águas Continentais, AU = Áreas Urbanizadas, AAA = Áreas Antrópicas Agrícolas, M = Macrófitas, AVN = Áreas de Vegetação natural e AD = Áreas Descobertas.	50
Figura 18 - Variabilidade textural das classes indicada pelo Índice de Fragmentação (IF) extraídos das bandas espectrais do sensor OLI/Landsat 8. AC é Águas Continentais, AU = Áreas Urbanizadas, AAA = Áreas Antrópicas Agrícolas, M = Macrófitas, AVN = Áreas de Vegetação natural e AD = Áreas Descobertas.	52

-
- Figura 19** - Variabilidade média das classes obtida a partir dos índices espectrais. AC é Águas Continentais, AU = Áreas Urbanizadas, AAA = Áreas Antrópicas Agrícolas, M = Macrófitas, AVN = Áreas de Vegetação natural e AD = Áreas Descobertas. 53
- Figura 20** - Variabilidade dos valores de H (matiz) e S (saturação) para as classes. AC é Águas Continentais, AU = Áreas Urbanizadas, AAA = Áreas Antrópicas Agrícolas, M = Macrófitas, AVN = Áreas de Vegetação natural e AD = Áreas Descobertas. 54
- Figura 21** - Variabilidade dos valores de altitude para as classes. AC é Águas Continentais, AU = Áreas Urbanizadas, AAA = Áreas Antrópicas Agrícolas, M = Macrófitas, AVN = Áreas de Vegetação natural e AD = Áreas Descobertas. 55
- Figura 22** - Arquivo ARFF 55
- Figura 23** - Arquivo de saída WEKA 3.8 59
- Figura 24** - Classificação resultante da aplicação da RNA à imagem de Jun/2015 (a); Composição colorida (OLI4/OLI3/OLI2) com imagens de Jun/2015 (b); Imagem de incerteza da classificação de Jun/2015 (c). Em que: AAA = áreas antrópicas agrícolas, AC = água continental, M =Macrófitas, AD = áreas descobertas, AU = áreas urbanizadas, AVN = áreas de vegetação natural. 67
- Figura 25** - Classificação resultante da aplicação da RNA à imagem de Out/2015 (a); Composição colorida (OLI4/OLI3/OLI2) com imagens de Out/2015 (b); Imagem de incerteza da classificação de Out/2015 (c). Em que: AAA = áreas antrópicas agrícolas, AC = água continental, M =Macrófitas, AD = áreas descobertas, AU = áreas urbanizadas, AVN = áreas de vegetação natural. 68
- Figura 26** - a) Composição com bandas do visível: OLI4/OLI3/OLI2 da época out/2015; b) Imagem de textura gerada a partir da banda OLI6; c) Imagem de textura gerada a partir da banda OLI5 69
- Figura 27** - Classificação resultante da aplicação da RNA à imagem de Fev/2016 (a); Composição colorida (OLI4/OLI3/OLI2) com imagens de Fev/2016 (b); Imagem de incerteza da classificação de Fev/2016 (c). Em que: AAA = áreas antrópicas agrícolas, AC = água continental, M =Macrófitas, AD = áreas descobertas, AU = áreas urbanizadas, AVN = áreas de vegetação natural. 70
- Figura 28** - a) Composição com bandas do visível: OLI4/OLI3/OLI2 da época Fev/2016; b) Imagem de textura gerada a partir da banda OLI6; c) Imagem de textura gerada a partir da banda OLI5; d) imagem matiz geradas a partir das bandas OLI4/OLI3/OLI2. 71

-
- Figura 29** - Classificação resultante da aplicação da RNA à imagem de Abr/2016 (a); Composição colorida (OLI4/OLI3/OLI2) com imagens de Abr/2016 (b); Imagem de incerteza da classificação de Abr/2016 (c). Em que: AAA = áreas antrópicas agrícolas, AC = água continental, M =Macrófitas, AD = áreas descobertas, AU = áreas urbanizadas, AVN = áreas de vegetação natural. 72
- Figura 30** - Classificação resultante da aplicação da RNA à imagem de Jul/2016 (a); Composição colorida (OLI4/OLI3/OLI2) com imagens de Jul/2016 (b); Imagem de incerteza da classificação de Jul/2016 (c). Em que: AAA = áreas antrópicas agrícolas, AC = água continental, M =Macrófitas, AD = áreas descobertas, AU = áreas urbanizadas, AVN = áreas de vegetação natural. 73
- Figura 31** - a) Banda espectral do vermelho (OLI4); c) Componente matiz gerada a partir das bandas OLI4/OLI3/OLI2. 74
- Figura 32** - Classificação resultante da aplicação da RNA à imagem de Out/2016 (a); Composição colorida (OLI4/OLI3/OLI2) com imagens de Out/2016 (b); Imagem de incerteza da classificação de Out/2016 (c). Em que: AAA = áreas antrópicas agrícolas, AC = água continental, M =Macrófitas, AD = áreas descobertas, AU = áreas urbanizadas, AVN = áreas de vegetação natural. 75
- Figura 33** - a) Imagem de textura gerada a partir da bandas OLI6; b) Imagem de textura gerada a partir da banda OLI5. 76
- Figura 34** - Componente matiz gerada a partir das bandas OLI4/OLI3/OLI2. 76
- Figura 35** - Classificação resultante da aplicação da RNA à imagem de Fev/2017 (a); Composição colorida (OLI4/OLI3/OLI2) com imagens de Fev/2017 (b); Imagem de incerteza da classificação de Fev/2017 (c). Em que: AAA = áreas antrópicas agrícolas, AC = água continental, M =Macrófitas, AD = áreas descobertas, AU = áreas urbanizadas, AVN = áreas de vegetação natural. 77
- Figura 36** - Classificação resultante da aplicação da RNA à imagem de Abr/2017 (a); Imagem de incerteza da classificação de Abr/2017 (b). Em que: AAA = áreas antrópicas agrícolas, AVN = áreas de vegetação natural, M =Macrófitas, AC = água continental, AD = áreas descobertas, AU = áreas urbanizadas. 78
- Figura 37** - a) Imagem de textura gerada a partir da bandas OLI6; b) Imagem de textura gerada a partir da banda OLI5, c) Componente matiz gerada a partir das bandas OLI4/OLI3/OLI2; d) Componente saturação gerada a partir das bandas OLI4/OLI3/OLI2. 79
- Figura 38** - Classificação resultante da aplicação da RNA à imagem de Ago/2017 (a); Imagem de incerteza da classificação de Ago/2017 (b). Em que: AAA = áreas antrópicas agrícolas, AVN = áreas de vegetação natural, M =Macrófitas, AC = água continental, AD = áreas descobertas, AU = áreas urbanizadas. 80

Figura 39 - Imagem de textura obtida a partir da banda OLI6 para a época Ago/2017. 81

Figura 40 - a) Imagem de textura obtida a partir da banda OLI6; b) Imagem de textura obtida a partir da banda OLI5. 81

Figura 41 - Classificação resultante da aplicação da RNA à imagem de Out/2017 (a); Imagem de incerteza da classificação de Out/2017 (b). Em que: AAA = áreas antrópicas agrícolas, AVN = áreas de vegetação natural, M =Macrófitas, AC = água continental, AD = áreas descobertas, AU = áreas urbanizadas. 82

LISTA DE QUADROS

Quadro 1 - Legenda aplicada no Mapa de Uso e Cobertura da Terra.	46
Quadro 2 - Composição de dados de entrada para a RNA	57

LISTA DE TABELAS

Tabela 1 - Índices Espectrais	22
Tabela 2 - Parâmetros quantitativos do reservatório de Salto Grande	37
Tabela 3 - Características das imagens Landsat 8/OLI	38
Tabela 4 - Especificação das datas de aquisição das imagens multiespectrais, de modo a possibilitar a cobertura sazonal da área de estudos.	41
Tabela 5 - Números de pixels em cada amostra de treinamento	48
Tabela 6 - Arquiteturas de RNA avaliadas nos experimentos realizados com base na cena de Jun/2015. Cada arquitetura é especificada da seguinte forma: número de variáveis de entrada – número de nós da primeira camada escondida – número de nós da segunda camada escondida – número de classes de saída. EQM é o Erro Médio Quadrático obtido usando dados de treinamento ou validação.	61
Tabela 7 - Indicadores estatísticos da validação para a classificação da cena de Jun/2015, considerando os três experimentos realizados. EG é a exatidão global da classificação.	62
Tabela 8 - Matriz de confusão computada para os Experimento 1 (arquitetura 21-27-14-6) (a). Em que: AAA significa áreas antrópicas agrícolas; AVN, áreas de vegetação natural; M, Macrófitas; AC, água continental; AD, áreas descobertas e; AU, áreas urbanizadas. AU, áreas urbanizadas. AUs é a acurácia do usuário e APr é a acurácia do produtor.	63
Tabela 9 - Matriz de confusão computada para os Experimento 2 (arquitetura 13-19-10-6). Em que: AAA significa áreas antrópicas agrícolas; AVN, áreas de vegetação natural; M, Macrófitas; AC, água continental; AD, áreas descobertas e; AU, áreas urbanizadas. AUs é AUs é a acurácia do usuário e APr é a acurácia do produtor.	64
Tabela 10	-
Matriz de confusão computada para o Experimento 3 (11-17-9-6). Em que: AAA significa áreas antrópicas agrícolas; AVN, áreas de vegetação natural; M, Macrófitas; AC, água continental; AD, áreas descobertas e; AU, áreas urbanizadas. AUs é a acurácia do usuário e APr é a acurácia do produtor.	64

1 INTRODUÇÃO

1.1 Considerações Iniciais

O represamento de rios com potencial hidrelétrico tem importante papel no desenvolvimento socioeconômico, além de promover recursos para múltiplos usos da água. Contudo, a sensibilidade desses corpos hídricos às formas de uso e cobertura da terra no seu entorno, bem como as mudanças climáticas, são os fatores que mais impactam águas continentais (PALMER et al., 2015). Em consequência disso, esses ambientes estão cada vez mais eutrofizados, favorecendo inclusive a proliferação excessiva de vegetação aquática, as chamadas macrófitas.

Ecossistemas aquáticos são sistemas particularmente sensíveis às atividades antrópicas e a necessidade de sua conservação vem sendo enfatizada a décadas. Diversos estudos indicam que a forma de uso e cobertura da terra no entorno dos corpos d'água tem forte correlação com a ocorrência de macrófitas (EGERTSON et al., 2004; ALAHUHTA et al., 2012). Nos estudos citados anteriormente são utilizadas abordagens baseadas em mensurações *in situ*, as quais são consideradas de maior precisão, uma vez que permitem o direcionamento das práticas de manejo específicas para cada ambiente (MARTINS et al., 2008). Porém, tais abordagens de aquisição de dados não permitem representar e verificar a dispersão espacial e temporal de comunidades de macrófitas. Diante disso, procedimentos adequados de controle da dispersão de macrófitas tornam-se cada vez mais essenciais.

O sensoriamento remoto, associado com as tecnologias da geoinformação, têm mostrado grande potencial para o conhecimento e análise espaço-temporal da dinâmica de crescimento e proliferação de macrófitas, além de permitir a obtenção de informações do ambiente em locais de difícil acesso (ADAM et al., 2010; MIRANDA; COSTA, 2015; VALTA-HULKKONEN et al., 2003).

Sensores remotos podem fornecer dados relevantes para mapeamento e análise da variabilidade espacial de macrófitas aquáticas e da cobertura e uso da terra no entorno de corpos hídricos. Além disso, algoritmos baseados em aprendizado de máquina (*Machine Learning*) têm se mostrado eficazes em aplicações com dados de sensoriamento remoto (TUIA, 2011). Dentre esses algoritmos, as Redes Neurais Artificiais (RNAs) são alternativas cada vez mais utilizadas em alternativa aos métodos estatísticos tradicionais de sensoriamento remoto. As RNAs não exigem nenhuma suposição sobre a distribuição estatística dos dados, além disso, não requerem grandes conjuntos de dados de treinamento e são mais tolerantes a ruídos.

Contudo, a performance de uma RNA é dependente da arquitetura de rede, bem como do treinamento realizado. Song et al., (2012), afirmam que RNAs com configuração e treinamento inadequado podem produzir uma classificação com precisão significativamente menor do que a produzida por classificadores paramétricos.

O desenvolvimento de estudos com o propósito de analisar o desempenho dos métodos baseados em aprendizagem de máquina, na classificação do uso e cobertura da terra, com vistas ao monitoramento simultâneo nas mudanças tanto no cenário terrestre como na dispersão da vegetação aquática, tornam-se essenciais em regiões ambientalmente degradadas como é o caso do reservatório de Salto Grande, no qual há recorrente e maciça presença de macrófitas, primariamente associadas ao despejo de cargas poluidoras ao longo do rio Atibaia, SP. Somando-se a isso, a intensa atividade agrícola, representada pelo cultivo da cana-de-açúcar, também tem sido considerada um importante fator no aumento da concentração de nutrientes no reservatório.

1.2 Justificativa

Apesar de a construção de reservatórios suprir as necessidades de fornecimento de energia elétrica e de abastecimento d'água, é notório as interferências que tais empreendimentos acarretam no funcionamento natural de rios, tais como: alteração na capacidade natural de depuração ao longo do seu curso e intensificação do processo de eutrofização (PRADO, 2004). Em um ambiente eutrofizado, frequentemente, ocorre a proliferação de macrófitas aquáticas. Apesar das plantas aquáticas terem uma grande importância junto aos ecossistemas aquáticos, muito por serem fontes de oxigênio, sua proliferação obstrui o fluxo da água (BARBOZA et al., 2008).

Alguns estudos mostram que fatores que geram variação na quantidade e distribuição de macrófitas, podem ser compreendidos por mudanças na paisagem, uma vez que esses processos podem estar relacionados com às variações nas condições ambientais do espaço, de atividades antrópicas e fatores espaciais (HWANG et al., 2007; CHERUVELIL; SORANNO, 2008; ALEXANDER et al., 2008; MIKULYUK et al., 2011). Nesse sentido, é evidente que variações sazonais no uso e cobertura da terra exercem influência na dispersão espacial de macrófitas emersas e, conseqüentemente, no desenvolvimento e proliferação dessas plantas influenciando, portanto, a eutrofização de reservatórios.

O Sensoriamento Remoto tem se mostrado eficiente tanto no mapeamento do uso e cobertura do solo quanto das áreas com ocorrência de macrófitas em reservatórios (VILLA et al., 2017; LUO et al., 2016). No entanto, o mapeamento de mudanças no uso e cobertura da

terra e vegetação aquática simultaneamente não é trivial, devido à confusão espectral entre os tipos de vegetação em uma única cena e a variabilidade temporal dos alvos dos tipos de cobertura da terra. Além disso, poucos estudos têm avaliado a generalização temporal de algoritmos de aprendizado de máquina, em que amostras coletadas em uma época são utilizadas para classificar cenas distantes no tempo. Essa abordagem multitemporal possui capacidade em auxiliar no mapeamento de mudanças de uso e cobertura da terra, além de entender a forma de dispersão de macrófitas em corpos d'água.

A classificação de imagens baseada em algoritmos de aprendizado de máquina constitui uma alternativa promissora para o mapeamento de tipos de uso e cobertura da terra. Devido a estratégias avançadas de aprendizado, esses algoritmos podem aprender e até mesmo realizar mapeamentos complexos, explorando as informações contidas em um conjunto de amostras de referência. Outra vantagem é o fato de que nenhuma suposição é exigida sobre a distribuição estatística dos dados. Devido a essa propriedade, o treinamento do algoritmo pode integrar dados provenientes de diferentes fontes com funções de densidade de probabilidade desconhecidas (ALI et al., 2015).

Dentre os algoritmos de aprendizado de máquina, as RNAs têm sido amplamente utilizadas na classificação de imagens em diferentes campos de aplicação. Contudo, a utilização eficiente de uma RNA exige a definição de sua arquitetura adequada, prevendo a utilização de dados de entrada que efetivamente discriminem as classes de saída e o monitoramento do treinamento do algoritmo, que é uma etapa trabalhosa e, por vezes, demorada. Com esse estudo, espera-se, verificar se uma arquitetura de RNA treinada para um cenário temporal é adequada para o monitoramento simultâneo do uso e cobertura da terra e áreas infestadas por macrófitas, fornecer um resultado compatível com classes observadas em cada época mapeada.

Além disso, o uso combinado de imagens multiespectrais e de atributos não espectrais, como aqueles derivados de Modelo Digital de Elevação (MDE), em algoritmos baseados em aprendizagem de máquina, podem fornecer melhor resultado quando comparado com classificadores paramétricos que utilizam somente atributos espectrais. Com a incorporação de dados adequados, acredita-se na possibilidade de discriminar e diminuir a ambiguidade entre macrófitas aquáticas e outros tipos de vegetação que ocorrem nas margens do corpo d'água, por meio do mapeamento simultâneo desses dois ambientes (terrestre e aquático).

1.3 Objetivos

O objetivo geral deste estudo é avaliar o potencial de redes neurais artificiais no monitoramento sazonal da dispersão de macrófitas aquáticas simultaneamente às alterações no uso e cobertura da terra do seu entorno, por meio da classificação de imagens multitemporais OLI/Landsat 8 e atributos não espectrais. Os objetivos específicos são:

- Integrar dados de diferentes fontes (imagens multiespectrais OLI/Landsat 8 e MDE) em um processo de extração de informações baseado em abordagem de aprendizado de máquina (RNA);
- Verificar a capacidade de uma rede neural artificial discriminar simultaneamente áreas ocupadas por macrófitas das diversas formas de vegetação presentes no ambiente terrestre (culturas agrícolas, florestas, etc.);
- Avaliar o desempenho e capacidade de generalização de uma rede neural artificial na classificação sazonal da área de estudos.

1.4 Estado da Arte

Zhang; Xie (2012) combinaram medidas texturais baseadas em objeto e redes neurais artificiais para o mapeamento de vegetação a partir de imagens hiperespectrais. Nesse estudo, os autores verificaram que a combinação das técnicas de análise de imagens baseada em objeto, informações texturais, redes neurais artificiais e imagens hiperespectrais são poderosas para o mapeamento de vegetação e podem melhorar a acurácia da classificação.

Rodriguez-Galiano; Chica-Olmo (2012) analisaram e mapearam mudanças na cobertura na terra usando diferentes tipos de dados: imagens Landsat, temperatura da superfície do solo, modelo digital de terreno (MDT) e textura. Para isso, foi utilizado o classificador Floresta Randômica (*Random Forest*). Os resultados desse estudo mostram que a combinação das imagens Landsat e dados auxiliares, como informações de temperatura, MDT e textura, geraram mapas acurados e que têm potencial para serem usados no gerenciamento do território.

Taghizadeh-Mehrjardi et al., (2015), investigaram o potencial de 6 classificadores de aprendizagem de máquina (redes neurais artificiais, máquina de vetor de suporte, K vizinho mais próximos (*K-nearest neighbour*), floresta randômica, árvore de decisão e regressão logística) no mapeamento digital de solos. Os dados auxiliares utilizados pelos autores foram bandas e índices espectrais (*Normalized Difference Vegetation Index* (NDVI), *Soil Adjusted Vegetation Index* (SAVI), *Ratio Vegetation Index* (RVI)) provenientes do satélite Landsat 8,

MDE, bem como mapas temáticos de geomorfologia. Os resultados alcançados demonstraram que os dados espectrais Landsat e os parâmetros do terreno provenientes do MDE foram úteis no mapeamento das classes de solo, e que os algoritmos de redes neurais artificiais e árvores de decisão foram os algoritmos que apresentaram maior desempenho para prever as famílias de solos.

Minaei; Kainz (2016) realizaram a detecção de mudanças no uso e cobertura da terra a partir de imagens multiespectrais (Landsat MSS, TM, ETM + e OLI/TIRS) referentes aos anos 1972, 1986, 2000 e 2014. O conjunto de dados desse estudo foi composto por imagens multiespectrais, imagens aéreas, MDE, mapas topográficos e mapas temáticos. Os mapas de uso e cobertura da terra dos anos de 1972, 1986 e 2000 foram produzidos usando métodos de classificação baseados em pixel. Para geração do mapa de 1972, foi utilizado redes neurais artificiais e para 1986 e 2000 foi utilizado o classificador de máxima verossimilhança. Já o mapa de uso e cobertura da terra de 2014 foi realizado por classificação baseada em objeto, em combinação com o algoritmo de árvore de decisão J48. Os resultados apresentados pelos autores indicam que o algoritmo que apresentou melhor desempenho foi redes neurais artificiais para classificação baseada por pixel, com 95,9% de acurácia global. Por sua vez, ao se utilizar classificação baseada em objeto através do algoritmo J48, a acurácia global foi na ordem de 94,05%.

Tran et al., (2017) analisaram a relação entre as mudanças no uso e cobertura da terra e temperatura de superfície, no contexto da urbanização. Para isso, os autores exploraram a relação entre a temperatura da superfície e vegetação, feições urbanas e áreas cultivadas, utilizando imagens Landsat 5 TM, Landsat ETM+ e Landsat 8 OLI, além dos índices NDVI e NDBI. Como algoritmo de classificação foi utilizado o *Multilayer Perceptron* (MLP). Os autores observaram que o crescimento urbano influenciou severamente nos padrões das ilhas de calor urbanas, contudo essa correlação nem sempre é linear, uma vez que pode variar entre cada tipo de uso e cobertura da terra, além de estar sujeita à localização geográfica e à estação do ano.

Stratoulas et al., (2018) apresentam uma avaliação de diferentes conjuntos de dados para classificar vegetação nas margens do lago Balaton, Hungria. Nesse estudo, os autores utilizaram os classificadores de máxima verossimilhança e máquina de vetores de suporte (SVM). O banco de dados foi composto por imagens hiperespectrais, MDE e índices espectrais. De modo geral, os autores concluíram que o classificador SVM fornece maior acurácia global, na ordem de 89%. A acurácia dos resultados foi atribuída a utilização de imagens hiperespectrais na região do visível e do infravermelho próximo entre 400 e 1000 nm.

De Alban et al., (2018) combinaram imagens Landsat-5 TM, Landsat-8 OLI, JERS-1 SAR, ALOS/PALSAR-2, índices espectrais e medidas de textura para detecção de mudanças no uso e cobertura da terra em paisagens tropicais dinâmicas. De acordo com os objetivos propostos no estudo, foi utilizado o classificador floresta randômica. Os resultados alcançados demonstraram que a combinação de imagens de radar de abertura sintética (SAR) e imagens Landsat apresentaram resultados melhores que se utilizados dados de apenas um sensor. Além disso, os índices espectrais e medidas de textura foram preditores proeminentes de vários tipos de cobertura da área de estudo, além de discriminar determinados tipos de plantações agrícolas.

De maneira geral, as metodologias dos trabalhos citados são distintas, contudo a utilização de aprendizagem de máquina para classificação e análise de dados de sensoriamento remoto se mostrou em evidência em todos os trabalhos. Além disso, a incorporação de dados multifonte no processo de classificação de imagens vem sendo amplamente difundida. O propósito disso é otimizar o desempenho de classificadores e, conseqüentemente, a geração de produtos mais acurados.

2 EXTRAÇÃO DE INFORMAÇÃO A PARTIR DE DADOS DE SENSORIAMENTO REMOTO

Os procedimentos para extração e análise de dados de sensoriamento remoto, frequentemente implementados de modo sistemático, são conhecidos por *processo de sensoriamento remoto*. Os procedimentos desse processo, basicamente, são: definição do problema, coleta de dados, conversão de dados em informação e apresentação da informação.

Inicialmente, ao estabelecer o problema de estudo definem-se as hipóteses a serem testadas e o modelo adequado de processamento (determinístico, estocástico). A partir disso, é realizada a coleta de dados, a qual consiste em medições *in situ* e dados auxiliares (MDE, mapas temáticos, entre outros). Posteriormente, os dados coletados devem ser convertidos em informação, nesta fase inclui-se as etapas de interpretação visual de imagens, processamento digital de imagens e os testes de hipóteses a priori definidas. Por fim, as informações extraídas devem ser apresentadas ao usuário, isso normalmente é realizado em forma de mapas, estatísticas e gráficos (JENSEN, 2000).

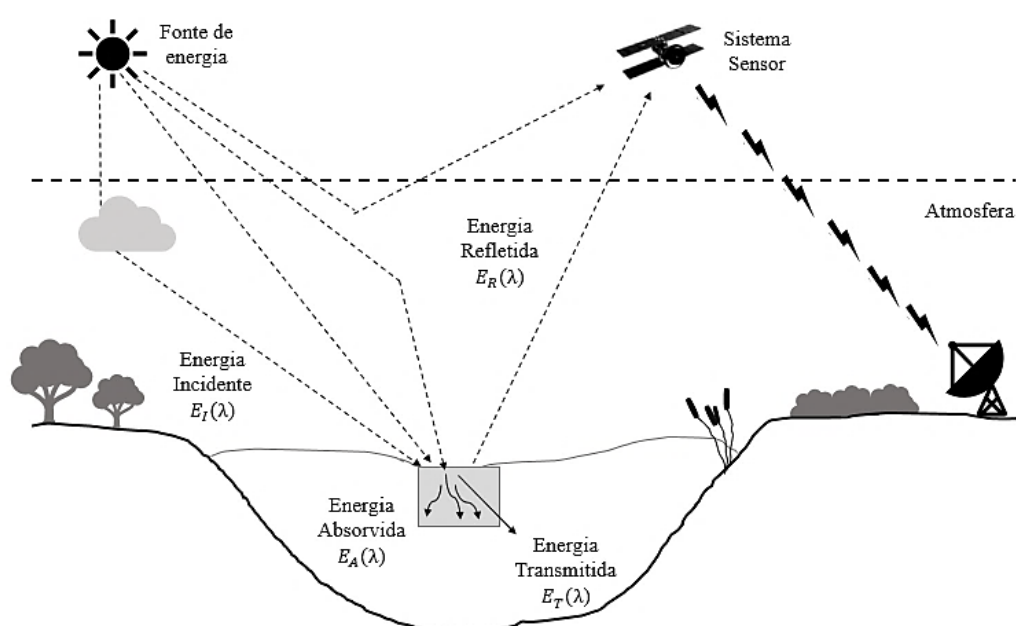
A extração de informações é um dos objetivos fundamentais do sensoriamento remoto. Para isso é fundamental o conhecimento do comportamento espectral dos alvos, visto que muitas feições da superfície terrestre podem ser identificadas e mapeadas com base nas suas características espectrais (LILLESAND et al., 2014). Uma alternativa para facilitar a extração de informações, bem como para melhorar a diferenciação de alvos em dados de sensoriamento remoto é a utilização de alguns métodos de transformações de imagens multiespectrais. Dentre esses métodos se incluem transformações em espaços de cores e índices espectrais.

Buscando melhorar a visualização e discriminação entre determinados alvos, uma abordagem de transformação no espaço de cores IHS foi utilizada. A transformação IHS é uma alternativa bastante utilizada no processamento de imagens de satélite. Dentre as vantagens de sua utilização destaca-se a redução da correlação entre bandas. Por sua vez, os índices espectrais foram empregados por serem capazes de representar condições reais de alvos específicos. Além disso, devido a eficiência e simplicidade conceitual, os índices espectrais possuem vantagens claras sobre outras metodologias de realce e identificação de alvos, além de apresentarem a possibilidade de simplificar o processo de mapeamento automático de uso e cobertura da terra.

2.1 Comportamento Espectral de Alvos

A radiação eletromagnética (REM) interage de modo diferente em cada tipo de alvo. Ao interagir com alvos da superfície terrestre, a energia incidente pode ser refletida, absorvida e/ou mesmo transmitida (Figura 1). Cabe destacar, que as proporções da energia refletida, absorvida e transmitida pelos alvos variam de acordo com as suas propriedades físico – químicas, estrutura e posição em relação a fonte de radiação, bem como pelo comprimento de onda da energia incidente (LILLESAND et al., 2014; NOVO, 2002).

Figura 1 - Interação da radiação eletromagnética com os alvos




Fonte: Adaptado de Lillesand et al., (2014) e Florenzano (2007).

A partir da reflectância de um alvo, medida em diferentes faixas do espectro eletromagnético, pode-se conhecer o seu comportamento espectral. Contudo, as características de reflectância de objetos adjacentes ao alvo de interesse podem interferir nas medidas de sua reflectância. Assim, a energia espalhada por alvos vizinhos pode ter uma resposta espectral diferente daquele alvo de interesse e camuflar sua resposta (NOVO, 2002).

Os principais alvos tratados em Sensoriamento Remoto são: água, vegetação, solos e paisagem urbana. De acordo com Novo (2002), o comportamento espectral da vegetação pode ser definido de acordo com três regiões básicas (**Erro! Fonte de referência não encontrada.**), estando essas relacionadas com fatores que condicionam seu comportamento. Jensen (2000) e Novo (2002) afirmam que em uma vegetação sadia, a reflectância no infravermelho próximo é maior na região entre 700 μm e 1200 μm , devido a estrutura celular. A vegetação sadia absorve

mais energia radiante na região do azul e do vermelho, sendo essas regiões espectrais fundamentais para realização da fotossíntese. Regiões até 0,7 μm , a reflectância é baixa, sendo caracterizada pela absorção da radiação incidente pelos pigmentos da planta em 0,48 μm (*carotenoides*) e em 0,62 μm (*clorofila*). Na região entre 1,3 μm e 2,5 μm , a reflectância da vegetação é dominada pelo conteúdo de água das folhas. Nessa região, encontram-se dois máximos de absorção pela água: em 1,4 μm e 1,95 μm , correspondes também as bandas de absorção atmosféricas.

Figura 2 – Comportamento espectral da vegetação



Fonte: Jensen (2000).

O comportamento espectral da água é determinado por diversos fatores, incluindo a radiação incidente na superfície do corpo d'água, propriedades ópticas da água, rugosidade da superfície e o ângulo de observação e iluminação (CAMPBELL; WYNNE, 2011). Além disso, a energia incidente pode ser influenciada por diversos fatores, dentre eles: absorção e espalhamento pela água pura, além de espalhamento, refração e difração por partículas suspensas na água.

A água em seu estado líquido, apresenta mínima absorção e espalhamento da luz na região do comprimento de onda do azul (400 a 500 nm), tendo como mínimo a região entre, aproximadamente, 460 – 480 nm. A luz incidente na região do verde e amarelo, de 520 a 580 nm, é bem absorvida na coluna d'água e pouco espalhamento ocorre. Quase todo fluxo radiante

incidente na região do infravermelho próximo e médio (740 – 3000 nm) que penetra no corpo d'água é absorvido (NOVO, 2002). De modo geral, a água apresenta baixa reflectância entre 380 – 700 nm, absorvendo toda a radiação de 700 nm (JENSEN, 2000).

Em relação a paisagem urbana, sabe-se que grande parte das edificações são compostas pelos materiais concreto e asfalto. Quanto as características espectrais do asfalto, esse alvo apresenta baixa e decrescente reflectância entre 0,3 μm e 0,4 μm , reflectância crescente entre 0,4 μm e 0,6 μm e entre 1 – 1,3 μm . Por outro lado, o comportamento espectral do concreto, de acordo com Novo (2002), é mais complexo. É caracterizado por um aumento da reflectância com o comprimento de onda, porém apresenta feições de absorção em 0,38 μm , entre 0,6 μm e 0,8 μm e em 1,1 μm . Jensen (2000) acrescenta que os limites de construções, a área, e informações de altura são melhores extraídas em imagens pancromáticas preto e branco (0,5 – 0,7 μm) ou coloridas (0,4 – 0,7 μm). Já a região do infravermelho termal (3 – 12 μm) pode ser usada para estimar medidas de temperatura da superfície urbana.

2.2 Índices Espectrais

Os índices espectrais são utilizados com o objetivo de realçar alvos específicos, de acordo com as suas respostas espectrais. Esses índices são obtidos a partir de operações aritméticas entre bandas espectrais, envolvendo faixas de reflectância específicas que possibilitam a diferenciação dos alvos. Diversos índices são propostos na literatura, dentre eles: índices de vegetação (*Normalized Difference Vegetation Index* (NDVI)), Razão Simples (RS), *Soil Adjusted Vegetation Index* (SAVI), *Enhanced Vegetation Index* (EVI), de água (*Modified Normalized Difference Water Index* (MNDWI)), de áreas construídas (*Normalized Difference Built-up Index* (NDBI)), de queimadas (*Normalized Burn Ratio* (NBR)), de identificação de sombras (*Normalized Saturation Value Difference Index* (NSVDI)), entre outros. Buscando melhorar o realce dos principais tipos de uso e cobertura da terra presentes na área de estudo, optou-se pela utilização dos índices RS e NDVI para mapeamento da vegetação, o índice MNDWI para realce de áreas úmidas e o NDBI para o mapeamento de áreas construídas (Tabela 1).

Tabela 1- Índices Espectrais

Índices	Equações	Referência
NDVI	$NDVI = \frac{\rho_{nir} - \rho_{red}}{\rho_{nir} + \rho_{red}}$	Rouse et al., (1974)
RS	$RS = \frac{\rho_{red}}{\rho_{nir}}$	Birth; McVey, 1968
MNDWI	$MNDWI = \frac{\rho_{green} - \rho_{MidIR}}{\rho_{green} + \rho_{MidIR}}$	Xu (2006)
NDBI	$B_u = \frac{\rho_{nir} - \rho_{MidIR}}{\rho_{nir} + \rho_{MidIR}}$	Zha et al., (2003)
	$NDBI = B_u - NDVI$	

Fonte: Jensen (2000).

Índices de vegetação, baseados em valores digitais de brilho (NDs), têm por objetivo estimar o conteúdo de biomassa e o vigor vegetativo. Esses índices são definidos a partir de combinações de vários valores espectrais que são adicionados, divididos, ou multiplicados de maneira que cada pixel da imagem indique a quantidade ou vigor da vegetação. Altos valores dos índices de vegetação indicam pixels com presença de vegetação sadia (CAMPBELL; WYNNE 2011).

O MNDWI foi proposto por Xu (2006). Esse índice é uma forma modificada do *Normalized Difference Water Index* (NDWI), proposto inicialmente por Gao (1996). Esse índice foi proposto com o objetivo de melhorar o realce de corpos d'água, uma vez que ele auxilia na minimização de ruídos decorrentes de áreas construídas, vegetação e solo que estão próximos ao corpo d'água.


Zha (2003) propôs um novo método para se mapear áreas urbanas, baseado no NDBI. O método proposto é capaz de mapear áreas construídas com uma acurácia de 92,6%. Entretanto, possui algumas limitações, dentre elas a dificuldade em diferenciar áreas urbanas e terrenos arenosos, uma vez que ambos possuem respostas espectralmente similares.

2.3 Transformação de imagens no espaço de cores

O objetivo de um espaço de cores é facilitar a especificação das cores em uma forma padronizada, amplamente aceita (GONZALEZ; WOODS, 2010). Os espaços de cores mais utilizados são o modelo RGB (*red, green, blue* – vermelho, verde, azul), CMY (*cyan, magenta, yellow* – ciano, magenta, amarelo), CMYK (*cyan, magenta, yellow, black* – ciano, magenta, amarelo, preto), IHS ou HSI (*hue, saturation, intensity* – matiz, saturação, intensidade).

No modelo IHS, a matiz é um atributo que descreve uma cor pura, sendo esta uma das propriedades que permite distinguir uma cor de outra. A saturação está relacionada com o grau de pureza de uma cor. Por sua vez, a intensidade é a componente responsável pela sensação de brilho de uma cor (GONZALEZ; WOODS, 2010). A matiz (H) de um ponto (P) é o ângulo formado entre seu vetor e o eixo do vermelho (0°). A saturação (S) é o comprimento do vetor a partir da origem até o ponto de referência (P). A intensidade (I) é dada pela posição em que o hexágono corta perpendicularmente o eixo da intensidade (Figura 3). A intensidade e a saturação de um ponto estão contidas no intervalo $[0,1]$, já os valores de matiz são dados por ângulos que variam desde 0° a 360° .

Figura 3 - Modelo de cores IHS



Fonte: Adaptado de Gonzalez; Woods (2010).

Gonzalez; Woods (2010) afirmam que uma imagem colorida pode ser facilmente transformada entre os modelos RGB e IHS, por meio de modelos matemáticos que ao final do processo produzem três novas imagens representando a intensidade, matiz e saturação da composição de bandas originais. O sistema de cores IHS é frequentemente utilizado no processamento de imagens para produzir composições coloridas com reduzida correlação interbanda, além de possibilitar a combinação de diferentes tipos de imagens ou imagens de diferentes sensores. Dessa forma, dada uma imagem em formato de cores RGB, a componente H de cada pixel é obtida conforme a Equação 1.

$$H = \begin{cases} \Theta & \text{se } B \leq G \\ 360 - \Theta & \text{se } B > G \end{cases} \quad (1)$$

onde

$$\Theta = \cos^{-1} \left\{ \frac{1/2 [(R - G) + (R - B)]}{[(R - G)^2 + (R - B)(G - B)]^{1/2}} \right\}$$

A componente saturação é dada utilizando Equação 2.

$$S = 1 - \frac{3}{(R + G + B)} - [\min (R, G, B)] \quad (2)$$

Por fim, a componente I pode ser obtida segundo a Equação 3.

$$I = \frac{1}{3} (R + G + B) \quad (3)$$

2.4 Classificação de imagens multiespectrais

Classificar uma imagem consiste em extrair informações, determinar e delimitar objetos, separando-os em grupos semelhantes/homogêneos, de acordo com seus comportamentos espectrais. Os processos de classificação de imagens são comumente divididos em supervisionados e não-supervisionados.

Em uma classificação supervisionada, são utilizadas amostras de treinamento representativas com identidade conhecida para classificar pixels de identidade desconhecida (CAMPBELL; WYNNE, 2011). Basicamente, as propriedades espectrais de cada pixel na imagem são comparadas com as das amostras de treinamento, então cada pixel é rotulado em um tipo de classe de acordo com as regras de decisão do classificador (LI et al., 2014). O processo de classificação supervisionada apresenta algumas vantagens, quando comparado com a classificação não-supervisionada, dentre elas, o analista ter o controle sobre as classes de interesse, configuradas para um propósito e região geográfica específica.

Os algoritmos de classificação de imagem podem ainda ser categorizados em paramétricos e não paramétricos. Os algoritmos paramétricos são baseados na suposição de que as classes podem ser modeladas por distribuições de probabilidade e, como consequência, são descritos pelos parâmetros dessas distribuições. Por outro lado, os modelos não paramétricos não requerem a natureza paramétrica dos dados, ou seja, os dados não se aproximam de modelos de distribuição de uma curva normal (RICHARDS; JIA, 2006).

Dentro da abordagem paramétrica, o classificador Máxima Verossimilhança (MAXVER) é um dos métodos mais utilizados em sensoriamento remoto. Esse classificador supõe que os pixels que compõem os dados de treinamento se aproximam de uma distribuição normal, sendo assim um vetor de médias e uma matriz de covariância descrevem os padrões de classificação da imagem. Por sua vez, os algoritmos não paramétricos são bastante promissores para classificação de imagens. Esses algoritmos são baseados em aprendizagem de máquina e possuem a capacidade de extrair informação a partir de amostras de treinamento e, posteriormente generaliza-lo para toda a imagem (LARY et al., 2016). Além disso, esses algoritmos possibilitam maior separação entre as classes, bem como a inclusão de dados não espectrais no processo de classificação.

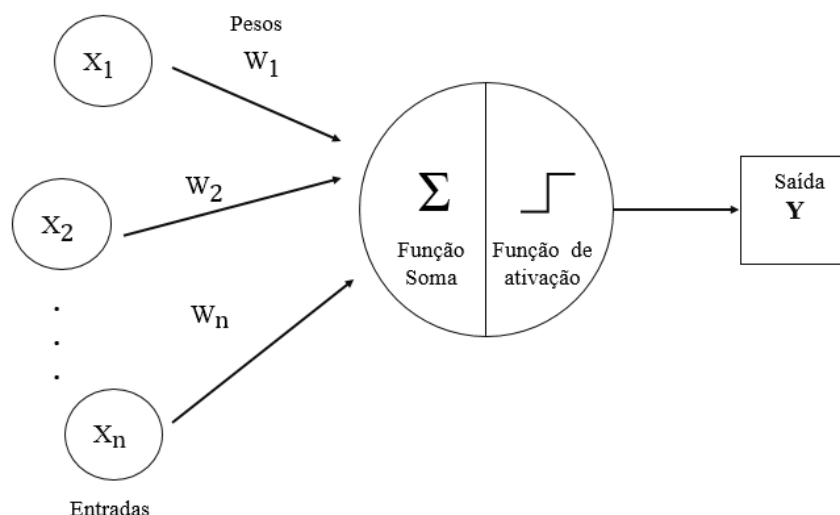
Aprendizagem de máquina é o processo de descobrir padrões, automaticamente ou semiautomaticamente a partir de grandes quantidades de dados (WITTEN; FRANK, 2005). Os algoritmos de aprendizagem de máquina comumente utilizados são Rede Neural Artificial, Máquina de vetores de suporte (*Support Vector Machine*), Floresta Aleatória (*Random Forest*), entre outros.

Dentre os algoritmos de aprendizagem de máquina, as redes neurais artificiais se destacam por sua capacidade de classificar dados complexos (BENEDIKTSSON et al., 1990). Além disso, as RNAs são classificadores supervisionados e, dessa forma, necessitam de amostras de treinamento e validação. A classificação supervisionada de imagens multiespectrais utilizando uma RNA envolve duas etapas: primeiro é feito o treinamento e em seguida a etapa de classificação. O treinamento de uma RNA é semelhante ao realizado em um classificador estatístico. A rede é treinada, de modo a minimizar a soma do quadrado do erro (erro médio quadrático) entre a saída calculada pela rede e a saída desejada (SCHOWENGERDT; PAOLA, 1995).

O elemento fundamental de uma RNA é o neurônio artificial ou elemento de processamento (Figura 4). Esse neurônio recebe múltiplas entradas, transformando-as em saída. O processo de aprendizagem em um neurônio é dado da seguinte forma: Pesos (W) são inicializados com valores randômicos. O primeiro atributo de entrada (X_1) é apresentado a rede e então multiplicado por esses pesos, os quais indicam sua influência na saída do neurônio. Em seguida, é feita uma soma ponderada do atributo que produz um nível de atividade, se esse nível de atividade for maior que um limiar, o neurônio produz uma determinada resposta de saída (Y). Se a resposta de saída for considerada errada, o algoritmo de aprendizagem ajusta os pesos para mapear os dados de entrada corretamente para as classes pré-definidas. Então, o próximo

padrão de entrada é apresentado a rede e o processo é repetido para todos os padrões de entrada até que o aprendizado seja concluído (SAMARASINGHE, 2016).

Figura 4 – Modelo de um neurônio artificial



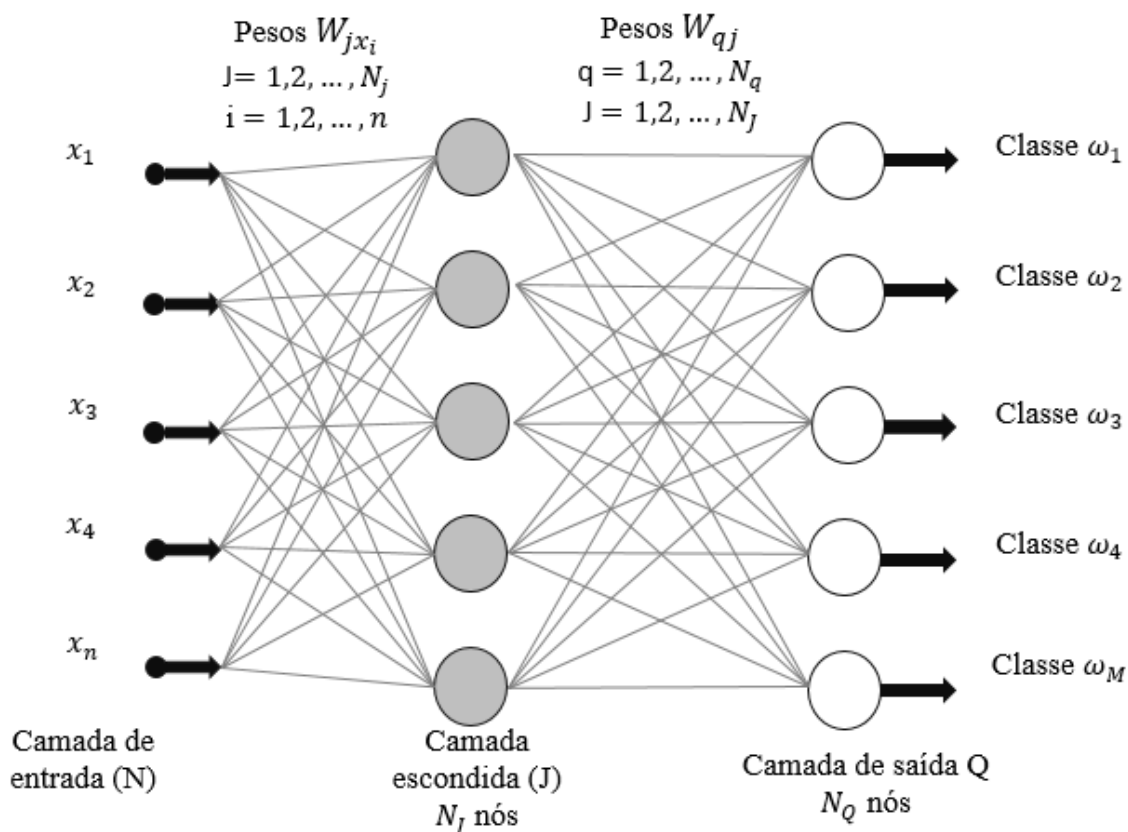
Fonte: Adaptado de Samarasinghe (2016)

Em uma RNA, os neurônios são dispostos por meio de camadas. A disposição dos neurônios nas camadas e o padrão de conexão entre estas definem a arquitetura da RNA. Dessa forma, uma arquitetura de RNA é composta, basicamente, por três elementos. A camada de entrada, na qual os dados são apresentados à rede. As camadas intermediárias, também chamadas de camadas escondidas, onde é realizado o processo de aprendizado. E por fim, a camada de saída na qual o resultado é concluído e apresentado. (CAMPBELL; WYNNE, 2011).

O número de neurônios da camada de entrada é correspondente a quantidade de atributos de entrada. A camada de saída contém a quantidade de neurônios de acordo com o número de classes pré-definidas. Já, a quantidade de neurônios nas camadas intermediárias é normalmente definida por tentativa e erro.

Na Figura 5 é apresentado um modelo de RNA com duas camadas: a camada intermediária J e a camada de saída Q . Os atributos x_1, x_2, \dots, x_n são os conjunto de dados de entrada; W_{jx_i} e W_{qj} representam os pesos que são ajustados durante o treinamento; e $\omega_1, \omega_2, \dots, \omega_M$ são as classes de saída da rede.

Figura 5 - Modelo de rede neural com uma camada escondida



Fonte: Adaptado de Campbell; Wynne (2011); Gonzalez; Woods (2010)

O funcionamento de uma rede neural, conforme a apresentada na Figura 5, é simples e pode ser resumido nas seguintes etapas: inicialmente atributos (X_n) são apresentados à camada de entrada (N). A entrada de cada neurônio, em qualquer camada, é dada pela soma ponderada da saída da camada anterior. Logo, tem-se que a entrada I_q de cada neurônio na camada Q , é:

$$I_q = \sum_{j=1}^{N_j} W_{qj} O_j \quad (4)$$

para $j=1,2,\dots,N_j$, onde N_j é o número de neurônios da camada J e W_{qj} são os pesos que modificam as saídas O_j . As saídas da camada J serão definidas através da expressão:

$$O_j = h_j(I_j) \quad (5)$$

Para $j = 1, 2, \dots, N_j$.

Quando a função de ativação de uma rede neural é definida como sendo sigmóide, cada elemento de processamento da rede neural passa a ser definido pela Equação 6.

$$h_q(I_q) = \frac{1}{1 + \exp \left[- \left(\sum_{j=1}^{N_j} W_{qj} O_j + \Theta_q \right) / \Theta_0 \right]} \quad (6)$$

onde $h_q(I_q)$ é a forma da função de ativação sigmoideal e Θ_q é um ganho adicional acrescentado ao somatório dos coeficientes.

Uma RNA pode ser treinada pelo algoritmo *backpropagation*, sendo esse um dos algoritmos mais conhecidos para aprendizagem supervisionada (GALO, 2000). Segundo Campbell; Wynne (2011), um dos objetivos desse algoritmo é o ajuste de pesos em cada uma das camadas da rede, além minimizar a soma do quadrado do erro entre a saída calculada por uma RNA multicamadas e a saída desejada.

De acordo com Galo (2000), o treinamento do *backpropagation* inicia com a definição de um conjunto arbitrário de pesos para as conexões da rede e envolve duas fases distintas. Na primeira, um vetor de treinamento com a saída desejada é apresentado à rede e propagado através de suas camadas para computar uma saída para cada elemento de processamento. As saídas dos nós da última camada são comparadas com as saídas desejadas e a partir disso, calculados os termos de erros. A segunda fase envolve um retrocesso, ou seja, uma passagem de volta através da rede a partir da última camada, durante a qual, o erro é repassado para cada elemento de processamento e os pesos correspondentes são alterados.

Diante do exposto, o erro quadrático total (E_Q) entre as saídas desejadas, r_q , e as saídas obtidas, O_q , nos neurônios na camada de saída Q , é dada por:

$$E_Q = \frac{1}{2} \sum_{q=1}^{N_Q} (r_q - O_q)^2 \quad (7)$$

onde N_Q é o número de neurônios na camada de saída Q .

Considerando que os pesos (W_{qj}) são ajustados na proporção da derivada parcial do erro, tem-se:

$$\Delta W_{qj} = -\alpha \frac{\partial E_Q}{\partial W_{qj}} \quad (8)$$

em que α é uma constante positiva, denominada de taxa de aprendizado, e que determina qual a proporção de mudança nos pesos calculados será utilizada para correção desses pesos.

O erro E_Q é função da saída O_q , as quais dependem das entradas I_q . Utilizando a regra da cadeia para desenvolver a derivada parcial de E_Q , têm-se:

$$\Delta W_{qj} = -\alpha \frac{\partial E_Q}{\partial I_q} O_j \quad (9)$$

ou

$$\Delta W_{qj} = -\alpha \delta_q O_j$$

onde δ_q é o termo de erro que expressa a taxa de mudança de E_Q em relação a O_q e a taxa de variação de O_q em relação a I_q

Para a camada de saída Q , o termo de erro δ_q é dado por:

$$\delta_q = (r_q - O_q) h'_q(I_q) \quad (10)$$

sendo h'_q a função de ativação, definida para cada elemento de processamento da rede.

Considerando a propagação do erro de volta para o ajuste dos pesos dos nós da camada escondida J , a partir da camada de saída Q , tem-se a seguinte expressão para o valor esperado de δ_j .

$$\delta_j = h'_j(I_j) \sum_{q=1}^{N_Q} \delta_q W_{jq} \quad (11)$$

Portanto, em uma sessão de treinamento bem-sucedida, o erro da rede diminui com o número de iterações e o procedimento converge para um conjunto estável de pesos. Tão logo, o procedimento para determinar se um padrão foi classificado corretamente durante o treinamento baseia-se em determinar se a resposta do nó na camada de saída, é alta, enquanto todos os outros nós apresentam resposta baixa (GONZALEZ; WOODS, 2010).

Os procedimentos, anteriormente descritos, para o desenvolvimento matemático do algoritmo *backpropagation*, estão apresentados em (GONZALEZ; WOODS, 2010).

2.5 Análise da qualidade de classificações

Vários fatores podem afetar a qualidade da classificação de imagens. Em classificações visuais, as principais fontes de erros estão relacionadas com erros de identificação de classes, excessiva generalização, erros de registro e variação nos detalhes de interpretação. Por outro

lado, em classificações digitais os principais erros são referentes aos tamanhos das amostras coletadas, número de classes de interesse e número de amostras por classes (CAMPBELL; WYNNE, 2011).

Campbell; Wynne (2011) afirmam que os erros em classificações são susceptíveis as seguintes características:

- Erros não são distribuídos sobre a imagem de forma aleatória, mas apresentam um certo grau de ocorrência ordenada e sistemática no espaço. Da mesma forma, os erros não são atribuídos randomicamente em várias categorias na imagem, sendo mais provável que estejam associados com determinadas classes;
- Frequentemente, pixels classificados erroneamente não estão espacialmente isolados, eles ocorrem agrupados em áreas de tamanho e forma variada;

A abordagem mais comum para avaliar o resultado de uma classificação é comparando o cena classificada com dados de referência espacialmente e temporalmente coincidentes, os quais são considerados como de maior acurácia (COMBER et al., 2012). Uma das formas para expressar a acurácia da classificação é por meio da matriz de erro, comumente chamada de matriz de confusão. A matriz de confusão compara, basicamente, classe por classe, a relação entre os dados de referência conhecidos e os resultados correspondentes de uma classificação automática (LILLESAND et al., 2014).

A matriz de confusão é uma matriz quadrada contendo números arranjados por meio de linhas e colunas, que expressam o número de pixels atribuídos a uma categoria específica em relação a verdadeira categoria a qual o pixel pertence, sendo isso verificado em campo ou a partir de fotografias aéreas. As colunas da matriz de confusão representam os dados de referência, enquanto que as linhas indicam as classes definidas a partir dos dados de sensoriamento remoto. A partir disso, tem-se que os valores da diagonal principal representam os pixels que foram corretamente classificados (CONGALTON ; GREEN, 2008).

De acordo com a Figura 6 assume-se que n amostras são distribuídas em k^2 células. Além disso, n_{ij} é o número de amostras classificadas na classe i ($i = 1, 2, \dots, k$) na classificação e na classe j ($j = 1, 2, \dots, k$) no conjunto de dados de referência.

Figura 6 – Representação de uma matriz de confusão

		j = Colunas (Referência)			Total linha
		1	2	k	n_{i+}
i = Linhas (Classificação)	1	n_{11}	n_{12}	n_{1k}	n_{1+}
	2	n_{21}	n_{22}	n_{2k}	n_{2+}
	k	n_{k1}	n_{k2}	n_{kk}	n_{k+}
Total coluna		n_{+1}	n_{+2}	n_{+k}	n
	n_{+j}				

Fonte: Adaptado de Congalton ; Green, 2008

Onde:

$n_{i+} = \sum_{j=1}^k n_{ij}$ é o número de amostras classificadas em cada classe i na classificação.

$n_{+j} = \sum_{i=1}^k n_{ij}$ é o número de amostras classificadas em cada classe j no conjunto de dados de referência.

Para geração da matriz de confusão, normalmente, são obtidas unidades amostrais para avaliação da qualidade da classificação. A aquisição de amostras de treinamento requer, inicialmente, conhecimento sobre a distribuição espacial das classes de interesse, determinação dos tipos e números de amostras a serem coletadas, além de escolher o esquema de amostragem. Os padrões de amostragem comumente utilizados são a amostragem randômica, randômica estratificada, sistemática e sistemática estratificada não alinhada (CONGALTON; GREEN, 2008).

Algumas medidas descritivas podem ser obtidas por meio da matriz de confusão, tais como: acurácia global e estimativa kappa. Basicamente, o índice de concordância kappa é utilizado para avaliar estatisticamente se os dados de referência são diferentes dos dados classificados, isto é, expressa a medida da diferença entre os dados de referência e o resultado da classificação. Esse índice pode ser calculado através da Equação 12. Na qual, k é o número de linhas e colunas da matriz, n_{ij} é o número de observações na linha i e coluna j , n_{i+} e n_{+i} são os totais marginais da linha i e coluna i , e n é o número total de observações (CONGALTON; GREEN, 2008).

$$\hat{K} = \frac{n \sum_{i=1}^k n_{ii} - \sum_{i=1}^k n_{i+} n_{+i}}{n^2 - \sum_{i=1}^k n_{i+} n_{+i}} \quad (12)$$

A exatidão global é uma medida mais simples e relaciona os elementos da diagonal principal (dados corretamente classificados) com o total de pontos amostrados (CONGALTON; GREEN, 2008). A exatidão global (EG) é calculada pela razão da soma da diagonal principal da matriz de confusão (n_{ii}), pelo número total de amostras coletadas (n) (Equação 13).

$$EG = \sum_{i=1}^k \frac{n_{ii}}{n} \quad (13)$$

A acurácia de classes específicas pode ser computada dividindo o número de pixels que foram corretamente classificados em cada classe pelo número de pixels do conjunto de dados de treinamento usados para a classe (total da coluna). Para essa medida descritiva dá-se o nome de acurácia do produtor (AP) (Equação 14). Tem-se ainda a acurácia do usuário (AU) (Equação 15), a qual é computada pela divisão entre o número de pixels corretamente classificados em cada classe e o total de pixels que foram classificados na classe (total da linha) (LILLESAND et al., 2014).

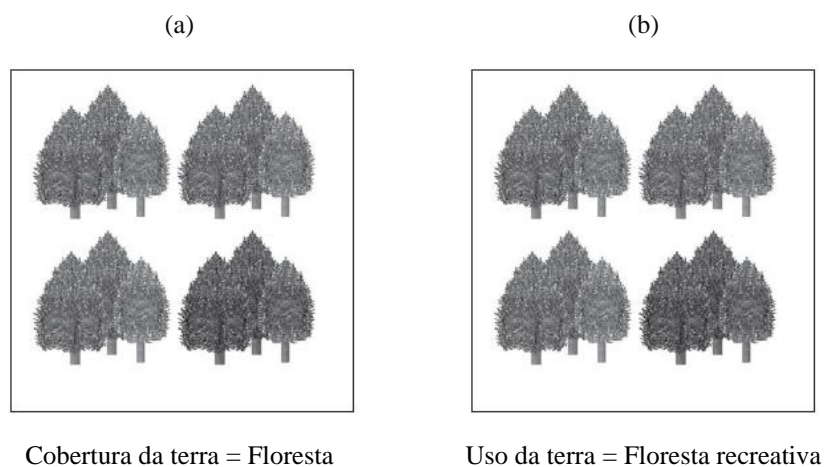
$$AP = \frac{n_{ii}}{n_{+j}} \quad (14)$$

$$AU = \frac{n_{ii}}{n_{i+}} \quad (15)$$

3 MAPEAMENTO DO USO E COBERTURA DA TERRA

Segundo Giri (2012), é frequente a confusão entre os termos uso da terra e cobertura da terra. Diante disso, torna-se essencial o conhecimento desses termos para que eles possam ser usados corretamente. Cobertura da terra (Figura 7a) se refere aos componentes bióticos e abióticos presente na superfície terrestre, tais como florestas, áreas urbanas, corpos d'água, entre outros. Uso da terra (Figura 7b), por sua vez, é definido pela forma ou maneira na qual a terra é usada e/ou ocupada pelos seres humanos. Em outras palavras, cobertura da terra representa as evidências visíveis do uso da terra.

Figura 7 - Diferença entre uso e cobertura da terra



Fonte: Adaptado de Giri (2012).

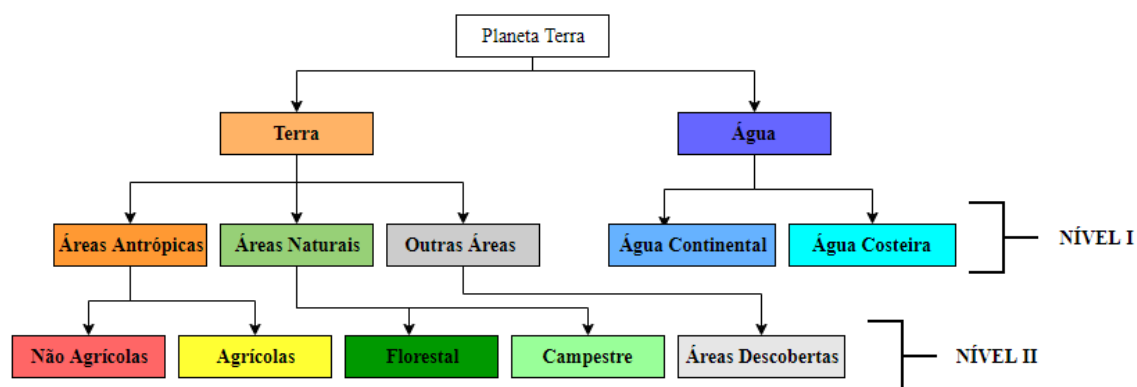
Apesar de alguns dados sobre uso da terra serem adquiridos através de observações diretas por órgãos oficiais que realizam visitas *in loco*, a grande maioria dos dados de uso e cobertura da terra são adquiridos por interpretação visual de imagens aéreas ou imagens similares. Imagens aéreas fornecem uma visão aérea, uma perspectiva espacial, e detalhes abrangentes que permitem um estudo preciso, sistemático e efetivo dos padrões de uso da terra. Além disso, as imagens de sensoriamento remoto podem fornecer um mapeamento acurado do uso e cobertura da terra, em parte devido as informações de cobertura da terra poderem ser visualmente interpretadas pelo contexto das características vizinhas (CAMPBELL; WYNNE, 2011).

No contexto da classificação de imagens para mapeamento do uso e cobertura da terra, normalmente, são empregados sistemas de classificação para padronização e compatibilização

das categorias de uso da terra. Um sistema de classificação é definido como um modelo de representação de classes temáticas em níveis de detalhamento.

O sistema de classificação de uso e cobertura da terra brasileiro foi definido pelo Instituto Brasileiro de Geografia e Estatística (IBGE), o objetivo desse sistema foi o recobrimento do país em termos de classificação dos tipos de cobertura. De acordo com o Manual Técnico de Uso da Terra proposto por IBGE (2013), a nomenclatura das classes de uso e cobertura da terra foi concebida partindo do esquema teórico da cobertura terrestre, o qual foi organizado segundo três níveis hierárquicos, conforme a Figura 8. Destaca-se que o terceiro nível, que indica o uso propriamente dito, não é representado na Figura 8 por comportar inúmeras possibilidades.

Figura 8 - Esquema teórico de construção da nomenclatura da cobertura terrestre



Fonte: Adaptado de IBGE(2013).

Segundo Campbell; Wynne (2011) alguns fatores devem ser considerados na aplicação de técnicas de classificação para mapeamento do uso e cobertura da terra. Esses fatores são: seleção das imagens, pré-processamento, seleção do algoritmo de classificação, seleção dos dados de treinamento, definição das assinaturas espectrais das classes, bem como a apresentação do mapa temático (simbolização). De acordo com os autores, o bom desempenho da classificação do uso e cobertura da terra depende das imagens selecionadas, bem como da data e estação a que elas se referem. Além disso, os dados de treinamento são de grande significância na classificação das imagens. Esses dados devem ser cuidadosamente amostrados para se garantir que a representação das variações espectrais das classes está sendo preservada.

É plausível de ser destacado, que feições de uso e cobertura da terra se modificam ao longo do tempo, principalmente devido a fatores econômicos, sociais e ambientais. Diante disso, o sensoriamento remoto pode prover subsídios para a detecção de mudanças do uso e

cobertura da terra. Basicamente, há dois métodos de detecção de mudanças: comparação entre classificações e comparação entre imagens.

Para detecção de mudanças comparando duas classificações, são geradas duas classificações independentes, representando uma mesma região geográfica, mas referentes a diferentes datas. Então, essas classificações são comparadas, ponto a ponto, com o objetivo de sumarizar as diferenças entre as duas datas. A detecção de mudanças através de duas imagens, envolve a análise das características espectrais de duas ou mais imagens e, então, identifica-se as atuais diferenças espectrais das classes de interesse (CAMPBELL; WYNNE, 2011).

No que tange a variável temporal, os métodos de detecção de mudanças ainda podem ser classificados em “bitemporal” e “multitemporal”. A detecção de mudanças bitemporal envolve a comparação da cobertura da terra através de dois pontos na escala de tempo. Esse método requer que a seleção das datas seja realizada cuidadosamente, uma vez que as mudanças detectadas podem revelar diferenças na fenologia e não diferenças nas feições de interesse. A detecção multitemporal de mudanças, compara a cobertura da terra de uma mesma área ao longo de intervalos de tempo, a partir de múltiplas imagens. Esse método necessita de grandes séries temporais para capturar a variabilidade ou tendências das mudanças de cobertura da terra (GIRI, 2012).

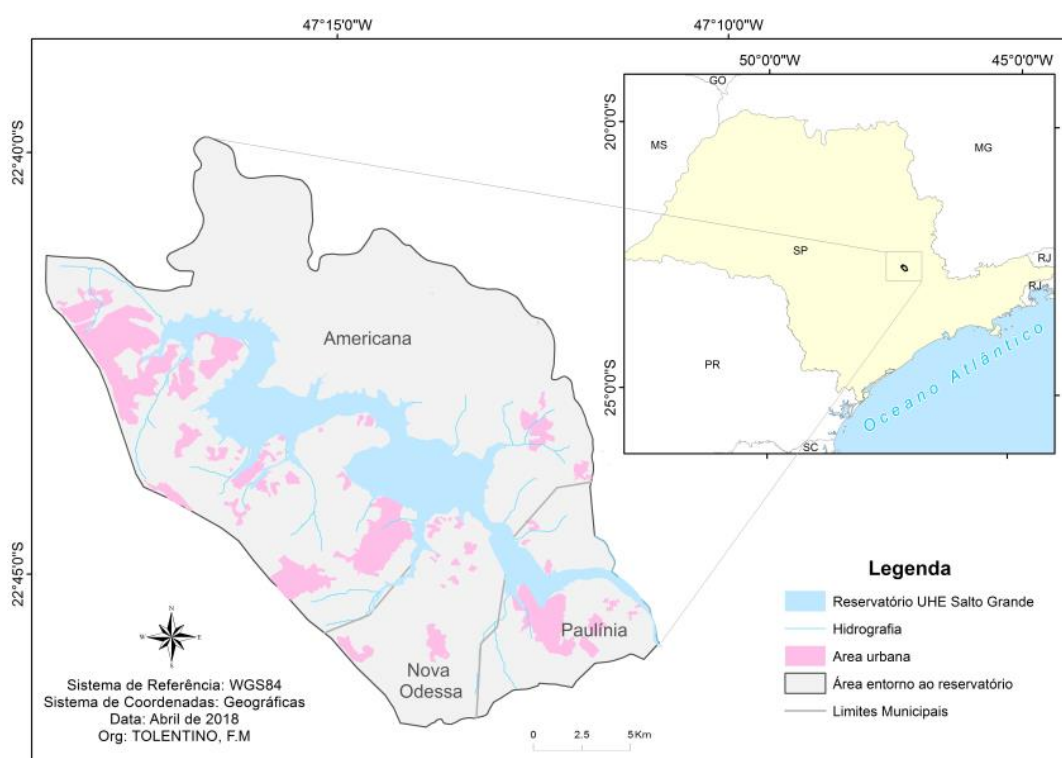
Por fim, múltiplas fontes de dados e métodos de detecção de mudanças podem ser integrados e utilizados, no entanto análises preliminares devem ser realizadas a fim de se conhecer as limitações dos conjuntos de dados e dos métodos empregados (GIRI, 2012).

4 MATERIAIS E MÉTODOS

4.1 Área de estudo

Á área de estudo compreende o reservatório de Salto Grande, inserido na sub-bacia do rio Atibaia. A Usina Hidrelétrica (UHE) de Salto Grande foi implantada no rio Atibaia, situada na região leste do estado de São Paulo, contemplando ainda os municípios de Americana, Nova Odessa e Paulínia, cidades pertencentes a região metropolitana de Campinas (Figura 9). Os limites da área de estudo foram definidos de acordo com premissas propostas no estudo de Fonseca (2013).

Figura 9 - Localização do Reservatório de Salto Grande – SP.



Fonte: O Autor.

O reservatório de Salto Grande originou-se pelo represamento do rio Atibaia, pertencente a bacia hidrográfica do rio Piracicaba, para construção da UHE de Salto Grande. O reservatório apresenta uma extensão de aproximadamente 17 km, com perímetro de 64 km (Fonseca, 2013). Outras informações quantitativas são apresentadas da Tabela 2.

Tabela 2 - Parâmetros quantitativos do reservatório de Salto Grande

Profundidade média	8 m
Área inundada	10,55 – 13,25 km ²
Volume máximo	106 x 10 ⁶ m ³
Vazão média	38,10 m ³ . s ⁻¹

Fonte: Adaptado de Fonseca (2013).

Fonseca (2013) afirma que após a formação desse reservatório iniciou-se, em seu entorno, a construção de chácaras de veraneio, loteamentos, além de espaços de lazer. Em um processo gradual, em virtude de inúmeros fatores, tais como expansão urbana, poluição por fontes difusas e degradação da qualidade da água, a área do entorno foi progressivamente sendo abandonada pela comunidade da região, bem como pelo poder público. Somando-se a isso, têm-se a degradação dos remanescentes florestais, ocasionada pelo avanço da cultura de cana-de-açúcar, da laranja e por pastagem nas áreas de preservação permanente, as quais contribuíram para o assoreamento do reservatório e para sua eutrofização, com a proliferação abundante de macrófitas.

De acordo com a Companhia Paulista de Força e Luz (CPFL) (2009), as áreas ocupadas por macrófitas, no reservatório de Salto Grande têm aumentado consideravelmente ao longo dos anos. Em 1985, a área ocupada por vegetação aquática era de, aproximadamente, 8 hectares. Após 19 anos, em 2004, o reservatório já apresentava 82 hectares ocupados por macrófitas. Diante dessa conjuntura, é possível afirmar que se trata de um reservatório eutrófico e em constante processo de degradação desde a sua formação.

4.2 Materiais

4.2.1 Dados espectrais e não espectrais

- *Imagens multiespectrais do satélite Landsat 8 – Sensor Operational Land Imager (OLI);*

O OLI é o sensor a bordo do satélite Landsat 8, lançado em fevereiro de 2013. Esse sensor coleta imagens da Terra com um ciclo de repetição de 16 dias. O tamanho aproximado da cena é de 170 km a norte-sul por 183 km a leste-oeste. Esse sensor fornece imagens coletadas com resolução radiométrica de 12 bits. O OLI inclui nove bandas espectrais com resolução espacial de 30 metros para as bandas 1 a 7 e 9 (Tabela 3).

Tabela 3 - Características das imagens Landsat 8/OLI

Imagem	Região Espectral	Banda	Intervalo Espectral (μm)	Centro da faixa espectral (μm)
Multiespectral	Costal	OLI1	0,433 – 0,453	0,443
	Azul	OLI2	0,450 – 0,515	0,482
	Verde	OLI3	0,525 – 0,600	0,562
	Vermelho	OLI4	0,630 – 0,680	0,655
	Infravermelho Próximo	OLI5	0,845 – 0,885	0,865
	Infravermelho de ondas curtas 1	OLI16	1,560 – 1,660	1,610
	Infravermelho de ondas curtas 2	OLI7	2,100 – 2,300	2,200
Pancromática	Cirrus	OLI9	1,360 – 1,390	1,375
	PAN	OLI8	0,500 – 0,680	0,590

Fonte: Adaptado de Barsi et al., (2014).

Cabe destacar que neste estudo são utilizadas bandas espectrais originais e imagens derivadas de processamentos específicos.

- Modelo digital de elevação ASTER (30 m):

O ASTER (*Advanced Spaceborne Thermal Emission and Reflection Radiometer*) é um instrumento a bordo do satélite TERRA, em funcionamento desde 2009, por meio do projeto GDEM (*Global Digital Elevation Model*). De acordo com o METI (*Ministry of Economy, Trade, and Industry*) do Japão e a NASA (*National Aeronautics and Space Administration*), as imagens provenientes do ASTER possuem recobrimento entre 83° de latitude norte e 63° de latitude sul, abrangendo aproximadamente 99% do território planeta e possuem como principais aplicações: estudos em topografia e modelagem de bacias hidrográficas e redes de drenagem (*Jet Propulsion Laboratory*, 2018).

A utilização do MDE na forma de imagem constitui um dos dados de entrada da classificação. Com a sua inclusão espera-se evitar o uso de uma máscara do reservatório, assim acredita-se que essa pode ser uma ferramenta relevante para diferenciação entre macrófitas e outros tipos de vegetação que estão presentes na área de estudo, como culturas agrícolas e áreas de vegetação natural. Em outras palavras, presume-se que a componente altitude seja preponderante para minimização da ambiguidade entre macrófitas e outros tipos de vegetação.

4.2.2 Ferramentas computacionais

- Sistema de informações geográficas IDRISI Selva:

O *software* IDRISI versão Selva, é um Sistema de Informação Geográfica (SIG), bem como um *software* de processamento de imagens desenvolvido pelo *Graduate School of Geography* da *Clark University* (EASTMAN, 1998). Nesta pesquisa o IDRISI será utilizado para geração das imagens de textura que irão compor os dados de entrada para o classificador. Disponível no Laboratório Didático I da FCT – UNESP.

- Sistema de processamento de imagens Envi 5.1:

O *software* Envi 5.1 será utilizado por apresentar ferramentas para o processamento digital de imagens. O Envi foi utilizado para extração das amostras de treinamento uma vez que permite a exportação das amostras de treinamento em formato ASCII, sendo esse o formato aceito pelo WEKA. Disponível no Laboratório Didático I da FCT – UNESP.

- Sistema de mineração de dados WEKA 3.8:

O Waikato Environment for Knowledge Analysis (WEKA) é um *software* de mineração de dados, desenvolvido pela Universidade de Waikato (Frank et al., 2016). O WEKA pode ser obtido pelo do site <http://www.cs.waikato.ac.nz/ml/weka/>. Após a instalação do *software*, não é necessária nenhuma configuração adicional para a sua execução.

O WEKA pode ser utilizado de três diferentes formas: interface gráfica, linha de comando e através de sua API (*Application Programming Interface*). A interface gráfica fornece as diversas ferramentas para seus usuários através de janelas e seus elementos. A linha de comando é um meio utilizado para dar mais agilidade a processos repetitivos e acesso direto a funcionalidades que teriam mais passos a serem executados, caso fossem acessados via interface gráfica.

Destaca-se que esse *software* é *open source* e é composto por diversos algoritmos de aprendizagem de máquina, com ferramentas específicas para pré-processamento de dados, classificação, regressão, agrupamento, regras de associação e visualização. O WEKA está implementado em linguagem Java, que tem como característica fundamental a sua portabilidade, desta forma é possível utilizá-lo em diferentes sistemas operacionais.

O WEKA foi utilizado para a classificação das imagens. Esse *software* se destaca nos procedimentos de classificação baseados em aprendizagem de máquina por possibilitar a manipulação das configurações dos algoritmos de classificação.

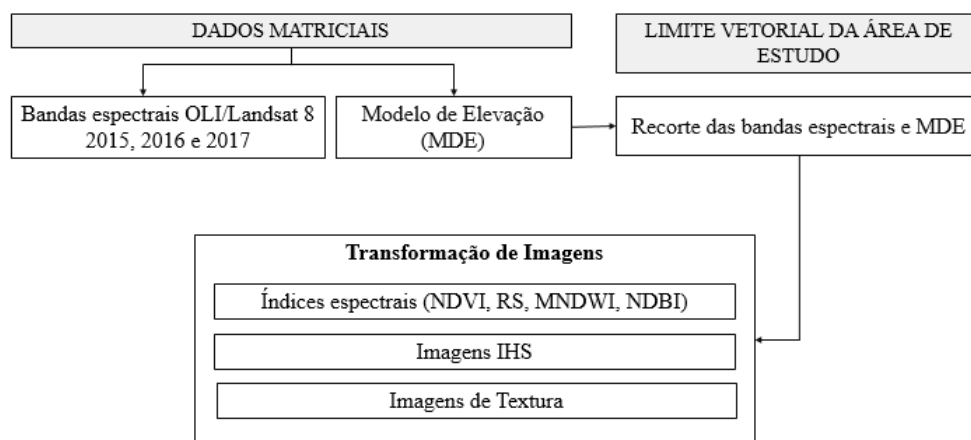
- Sistema de informações geográficas ArcGIS 10.6:

Software ArcGIS 10.6, foi utilizado para geração dos mapas temáticos oriundos das classificações realizadas no *software* WEKA 3.8. Disponível na versão para estudante, com licença EVA090213491.

4.3 Método de classificação proposto

Entre as etapas que norteiam os procedimentos metodológicos desse estudo, o que assume caráter essencial é a identificação dos atributos relevantes para uma adequada classificação dos dados. As etapas de preparação e processamento dos dados, apesar de imprescindíveis, são mais operacionais. A preparação dos dados (Figura 10) consiste, basicamente em realizar *download* das cenas que compreendem a área de estudo, para na sequência essas cenas e o MDE serem recortados para a área do entorno ao reservatório. Posteriormente ao recorte dos dados, foram geradas imagens de textura e índices espectrais, além de transformação multispectral do espaço de cor RGB para o IHS.

Figura 10 - Atividades realizadas visando a constituição da base de dados de entrada para a classificação



Fonte: O Autor


4.3.1 Aquisição dos dados multispectrais OLI/Landsat 8

Para realização desse estudo foram utilizadas imagens do satélite Landsat 8 provenientes do sensor OLI, disponibilizadas gratuitamente, sob demanda, pelo *United States Geology Survey* (USGS), na forma de dados de reflectância de superfície. Essas imagens processadas para reflectância de superfície fornecem uma estimativa da reflectância espectral da superfície, logo, são corrigidas de efeitos atmosféricos e são geradas a partir do *Provisional Landsat 8 Surface Reflectance Code* (LaSRC). O LaSRC é um algoritmo que utiliza a banda do azul

costal, além de dados auxiliares de clima do MODIS e um modelo de transferência radiativa exclusivo (USGS, 2017). Vermote et al., (2016), realizaram uma análise preliminar da performance dos dados de reflectância de superfície, provenientes do sistema Landsat 8/OLI e verificaram que esses dados apresentam boa performance para análise de séries temporais e para geração do NDVI.

As imagens utilizadas referem-se ao período entre 2015 e 2017, correspondentes à órbita/ponto 219-76 e 220-76 (Tabela 4), visto que a área de interesse está completamente inserida em cada uma das órbitas/ponto (Figura 11). Por problemas relacionados com cobertura de nuvens, foram consideradas as duas órbitas/pontos, dessa forma garantiu-se a cobertura sazonal de imagens da área.

Figura 11 – Órbitas-ponto que recobrem a área de estudo.



Fonte: O Autor.

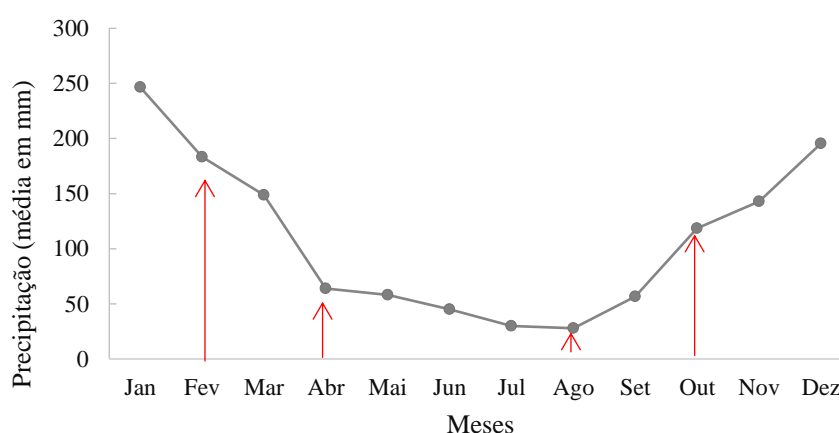
Tabela 4 - Especificação das datas de aquisição das imagens multiespectrais, de modo a possibilitar a cobertura sazonal da área de estudos.

Ano	Data da imagem	Órbita-ponto
2015	26/06/2015	220-76
	09/10/2015	219-76
	05/02/2016	220-76
2016	18/04/2016	219-76
	07/07/2016	219-76
	02/10/2016	220-76
	23/02/2017	220-76
2017	28/04/2017	220-76
	27/08/2017	219-76
	05/10/2017	220-76

Fonte: O Autor.

As imagens foram adquiridas considerando quatro períodos do ano, a primavera (imagens de outubro), o verão (imagens de fevereiro), o outono (imagens de abril) e o inverno (imagens de junho, julho ou agosto, considerando a menor cobertura de nuvens). Essas datas foram consideradas por compreenderem períodos representativos de estiagem e cheia na região, conforme indicado no hietograma da Figura 12. No entanto, cabe destacar que para o ano de 2015 foram consideradas imagens somente de épocas (26/06/2015 e 09/10/2015) por motivos de disponibilidade de imagens da área de estudo.

Figura 12 - Hietograma para o período de 1985 – 2016 para o município de Americana-SP. As setas vermelhas indicam períodos representativos da área de estudo, sendo considerados para aquisição de imagens.



Fonte: Portal do Departamento de Águas e Energia Elétrica do Estado de São Paulo.

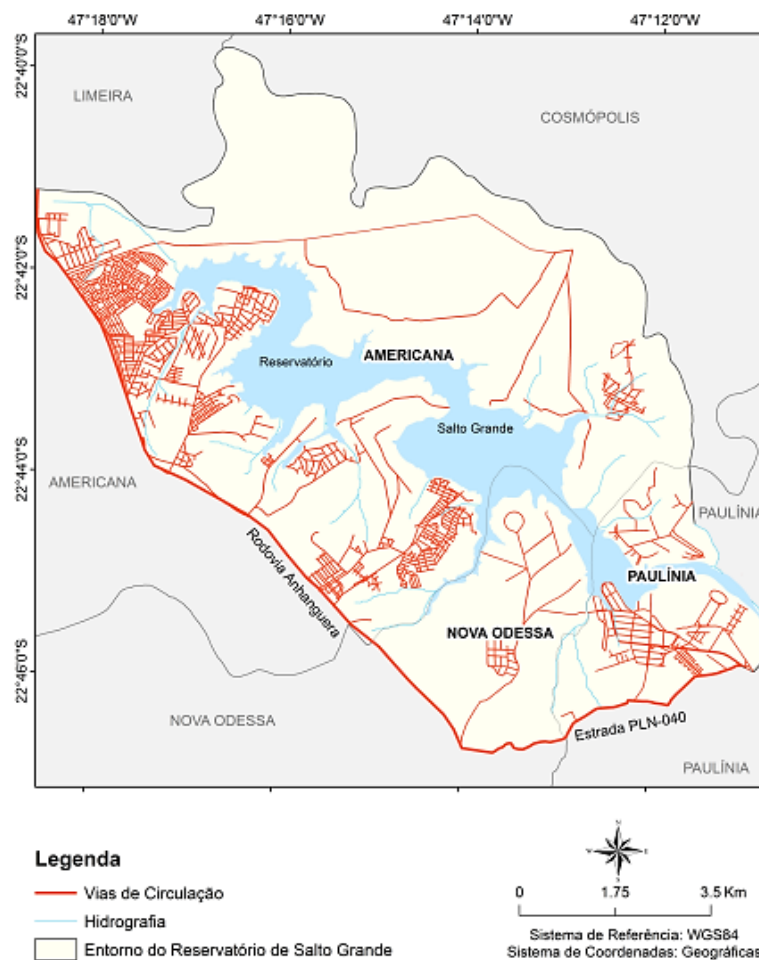
4.3.2 Recorte das imagens para a área de estudo

Os limites da área de estudo foram definidos pela área de influência direta ao reservatório, bem como pela área que compreende a represa de Salto Grande.

Como mencionado na Seção 5.1, a área de estudo foi definida de acordo com os pressupostos estabelecidos por Fonseca (2013). Diante disso, o polígono da área de estudo foi definido abrangendo os seguintes limites: no município de Americana a área é delimitada pelos limites municipais (leste/oeste), rodovia Anhanguera (sul) e área do pós-represa (norte, até limite municipal com Cosmópolis); no município de Nova Odessa, a área é delimitada pela rodovia Anhanguera e Estrada Municipal PLN-040 (sul), limite municipal com Paulínia (leste), e divisas municipais com Americana (norte/oeste); no município de Paulínia, a área é delimitada pelas divisas municipais com Nova Odessa (oeste), Americana e Cosmópolis (norte), Estrada Municipal PLN-040 (sul), e divisores de água (leste) (Figura 13). Destaca-se que a delimitação

da área de estudo foi realizada através de ferramentas de extração de feições do *software* ArcGIS 10.6.

Figura 13 - Recorte Espacial da área de estudo – entorno do reservatório de Salto Grande (SP).



Fonte: Adaptado de Fonseca (2013).

Por fim, o recorte dos dados matriciais foi realizado utilizando o *software* Envi 5.1, com apoio do limite vetorial definido anteriormente.

4.3.3 Geração de índices espectrais, imagens de textura e componentes IHS

A geração das imagens dos índices espectrais NDVI, RS, MNDWI e NDBI (Tabela 1) foi realizada no *software* Envi 5.1. Esses índices realçam alvos específicos da cena, tais como vegetação, superfícies úmidas e edificações. Dessa forma, esses índices podem prover melhor desempenho na geração de mapas de uso e ocupação da terra.

As imagens de textura foram obtidas a partir do cálculo do índice de fragmentação, implementado no Idrisi. De acordo com Galo (2000), o índice de fragmentação da paisagem é uma medida local de textura e indica que se um atributo não se repete na janela de tamanho fixo deslocada sobre a imagem, o valor calculado para o pixel central será máximo ($F=1,0$). Porém, se todos os pixels da janela tiverem o mesmo atributo ($F=0$) não ocorre variabilidade espacial na região analisada.

O índice de fragmentação foi computado para as bandas espectrais OLI2, OLI3, OLI4, OLI5, OLI6 e OLI7, referentes das cada umas das cenas temporais relacionadas na Tabela 4. Adotando os mesmos critérios de Galo (2000), foi utilizada uma janela de 3 x 3 para cálculo do operador. O índice de fragmentação (F) pode ser obtido através da seguinte equação:

$$F = (n - 1)/(c - 1) \quad (16)$$

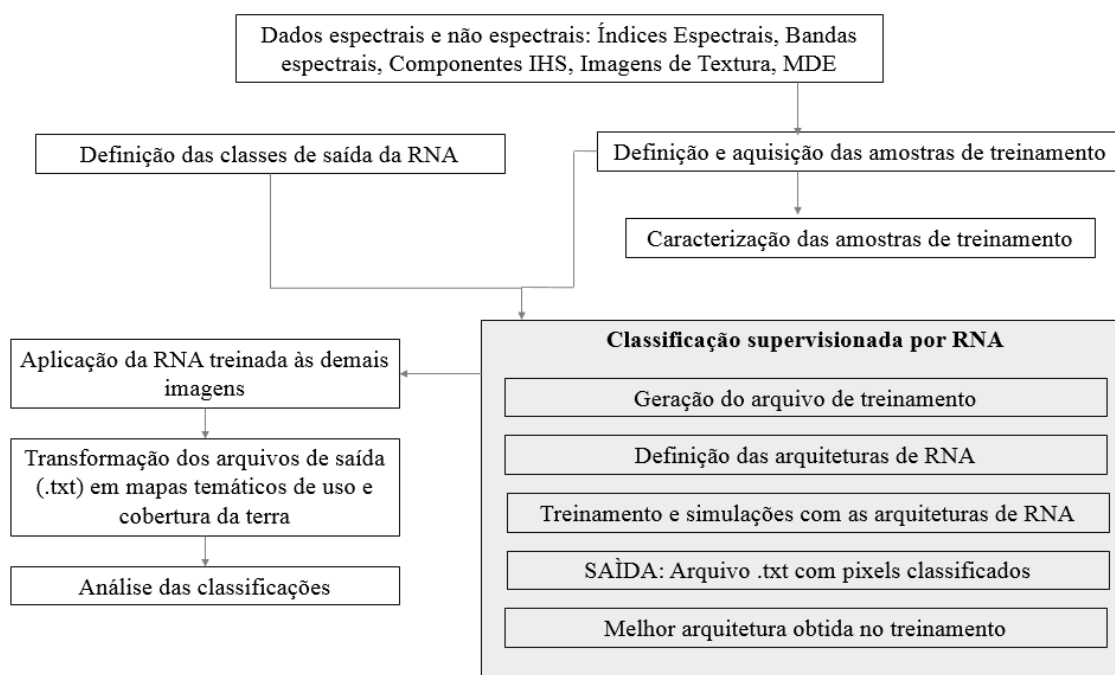
na qual n é o número de pixels com diferentes atributos (valores radiométricos atribuídos aos pixels) presentes em uma janela de dimensão c .

Visando realçar as informações contidas nas bandas originais, foram geradas imagens no espaço de cor IHS a partir de combinações das bandas espectrais do visível (OLI4, OLI3, OLI2) e uma composição falsa cor das bandas OLI4, OLI5 e OLI6). As três componentes I, H e S podem ser efetivas no realce dos alvos. A componente matiz está associada a informações de natureza espectral do alvo, de modo a inferir sobre a cor do alvo. A imagem de saturação revela informações sobre mistura espectral de alvos, dessa forma pode auxiliar na discriminação de alvos urbanos, por exemplo. A componente intensidade pode apresentar informações de natureza espacial da cena analisada. Destaca-se que procedimento de transformação do espaço RGB - IHS foi realizado utilizando o *software* Envi 5.1.

4.3.4 Aplicação de RNAs na classificação dos dados

A etapa de processamento de imagens é definida principalmente pela classificação das imagens. Nessa fase, foram definidas as classes de interesse, bem como a respectiva legenda. Em seguida, foram especificados os elementos amostrais e os parâmetros para o treinamento da RNA e a classificação das imagens. Ainda, foram gerados mapas temáticos das classificações realizadas. A metodologia proposta para classificação das imagens é apresentada na Figura 14.

Figura 14 - Atividades desenvolvidas no processo de classificação das imagens



Fonte: O Autor.

A utilização de RNAs para classificação de dados de sensoriamento remoto, requer a determinação da dimensionalidade dos atributos de entrada (camada de entrada), bem como a definição das classes de uso e cobertura do solo (camada de saída). A quantidade de camadas escondidas foi mantida como sendo duas em todas as simulações. Essa etapa foi baseada nos resultados obtidos por (GALO, 2000), nos quais foi verificado que os melhores resultados foram obtidos com redes neurais com duas camadas intermediárias, sendo estas com um número maior que o número de classes de saída. Sendo assim, para especificar a arquitetura das redes treinadas, adotou-se o seguinte critério: [número de nós na camada de entrada – número de nós na primeira camada escondida – número de nós na segunda camada escondida – número de nós na camada de saída].

A imagem do mês de junho de 2015 foi adotada como base para aquisição das amostras de treinamento e para o treinamento das estruturas de redes que foram testadas para a classificação dos dados. A utilização dessa imagem também permitiu verificar a capacidade de generalização temporal da rede treinada, de modo que essa rede seja capaz de discriminar as mesmas classes dos dados de treinamento em conjuntos de dados adquiridos em diferentes épocas.

4.3.4.1 Definição das classes de saída da RNA

A identificação das classes de uso e cobertura da terra no entorno do reservatório de Salto Grande –SP ocorreu a partir da interpretação visual das imagens OLI. A priori, foram identificadas 6 classes de uso e cobertura da terra, sendo estas: AC = Água Continental, AVN = Áreas de Vegetação Natural, AD = Áreas Descobertas, AAA = Áreas Antrópicas Agrícolas, AU = Áreas Urbanizadas e M = Macrófitas. A legenda empregada na elaboração dos mapas de uso e cobertura da Terra foi definida segundo as categorias de uso da terra, dispostas no Manual Técnico de Uso da Terra (IBGE, 2013) (Quadro 1).

Quadro 1 - Legenda aplicada no Mapa de Uso e Cobertura da Terra.

Tema	Descrição
Água Continental	Os corpos d'água continentais referem-se aos corpos d'água naturais e artificiais que não são de origem marinha.
Áreas Naturais	Compreende um conjunto de estruturas florestais e campestres, abrangendo desde florestas e campos originais (primários) e alterados até formações florestais espontâneas secundárias, arbustivas, herbáceas e/ou gramíneo-lenhosas.
Áreas Descobertas	Ambientes naturais, como rochas desnudas ou praias, quanto a ambientes antrópicos, decorrentes da degradação provocada pelas atividades humanas.
Áreas Antrópicas Agrícolas	A terra agrícola pode ser definida como terra utilizada para a produção de alimentos, fibras e commodities do agronegócio. Encontram-se inseridas nesta categoria as lavouras temporárias, lavouras permanentes, pastagens plantadas, silvicultura e áreas comprovadamente agrícolas.
Áreas Urbanizadas	Áreas correspondentes às cidades (sedes municipais), às vilas (sedes distritais) e às áreas urbanas isoladas conforme classificação do IBGE. Compreendem áreas de uso intensivo, estruturadas por edificações e sistema viário, onde predominam as superfícies artificiais não agrícolas.

Fonte: Manual Técnico de Uso da Terra do IBGE (2013).

O manual técnico afirma que a construção da nomenclatura da cobertura e do uso da terra precisa estar adequada para mapear a diversidade do território considerado e deve ser compatível com a escala, o tamanho da menor área a ser mapeada, a fonte básica de dados e

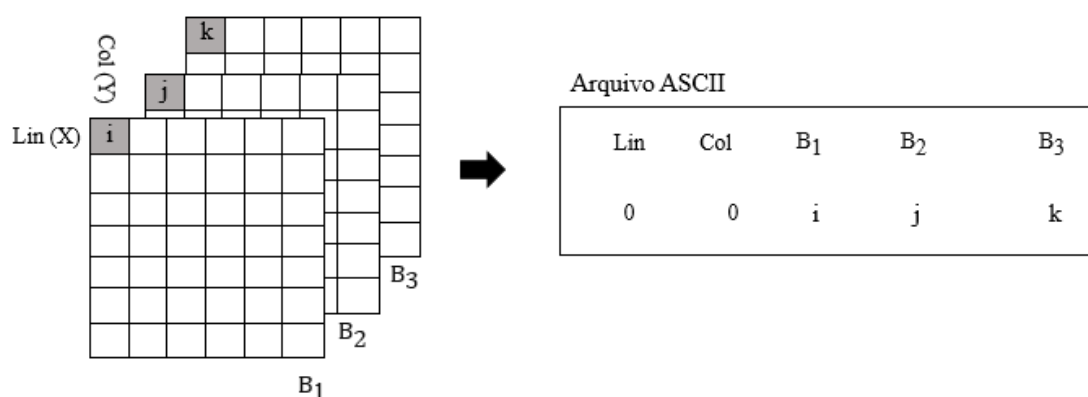
necessidades do usuário. Nesse sentido, devido a resolução espacial das imagens OLI, a nomenclatura das classes de interesse foi nomeada conforme Nível II do esquema teórico (Figura 7). No entanto, as classes relacionadas com vegetação nativa e corpos d'água foram identificadas de acordo com o primeiro nível de mapeamento.

O primeiro nível (NÍVEL I), indica as principais categorias da cobertura terrestre, as quais podem ser discriminadas a partir da interpretação direta dos dados de sensores remotos. O segundo nível (NÍVEL II) se refere a cobertura e o uso em uma escala mais regional. Nesse nível nem todas as categorias podem ser interpretadas com igual confiabilidade somente a partir de dados de sensores remotos, sendo necessário o uso de dados complementares e observações de campo. Tais premissas justificam o uso do NÍVEL I para indicar as nomenclaturas das classes relacionadas com vegetação nativa e corpos d'água.

4.3.4.2 Definição e aquisição das amostras para treinamento da RNA

A aquisição das amostras para treinamento da RNA foi realizada no Envi 5.1. Essas amostras foram definidas como pequenos polígonos e, posteriormente, exportadas no formato de arquivo ASCII. Os polígonos foram extraídos sobre uma composição colorida com bandas do visível, referente a junho de 2015, sendo identificados com o nome das classes de uso e cobertura a qual eles pertencem. Apesar das amostras serem definidas na forma de polígonos, no momento da exportação do arquivo ASCII os atributos são adquiridos para cada pixel que compõe o polígono. Assim, para cada pixel são extraídos os valores que esse pixel possui em cada plano de entrada (Figura 15).

Figura 15 - Representação da definição do arquivo ASCII



Fonte: O Autor.

Foram tomados como amostras 6790 pixels, sendo esses subdivididos em, aproximadamente, 1000 pixels por classe (Tabela 5). Exceto para a classe macrófitas, a aquisição de maiores quantidades de pixels foi limitada devido a representatividade dessas classes na imagem de 2015.

Tabela 5 - Números de pixels em cada amostra de treinamento

Classes	Número de pixels de treinamento
Água Continental	1203
Áreas de Vegetação Natural	1152
Macrófitas	215
Área Descoberta	1589
Área Antrópica Agrícola	1411
Áreas Urbanizadas	1220

Fonte: O Autor.

Destaca-se, que o Envi foi utilizado por permitir a caracterização das amostras para diversos planos de entrada, além de permitir a exportação do arquivo resultante em formato ASCII. A primeira coluna (*ID*) do arquivo saída ASCII (Figura 16) se refere ao número de identificação de cada pixel. A segunda (*X*) e terceira (*Y*) coluna são as coordenadas no sistema imagem de cada pixel. As colunas *Map X* e *Map Y* são as coordenadas no sistema UTM de cada pixel, por sua vez as colunas *Lat* (Latitude) e *Lon* (Longitude) são as coordenadas geográficas de cada pixel da imagem. As colunas *B1* e *B2* são atributos que descrevem os pixels da imagem.

Figura 16 - Amostras de treinamento obtidas através do Envi

ID	X	Y	Map X	Map Y	Lat	Lon	B1	B2
1	229	98	885595.97	7486250.28	-22.687035	-47.247906	-1.0685	532.0000
2	230	98	885625.53	7486250.28	-22.687028	-47.247619	-1.0192	536.0000
3	231	98	885655.09	7486250.28	-22.687021	-47.247332	-0.9767	534.0000
4	232	98	885684.64	7486250.28	-22.687014	-47.247045	-0.9413	536.0000
5	228	98	885566.41	7486250.28	-22.687041	-47.248194	-1.0197	525.0000
6	229	99	885595.97	7486220.72	-22.687301	-47.247899	-1.0661	524.0000
7	230	99	885625.53	7486220.72	-22.687294	-47.247612	-1.0810	529.0000
8	231	99	885655.09	7486220.72	-22.687288	-47.247325	-1.0638	532.0000
9	232	99	885684.64	7486220.72	-22.687281	-47.247038	-1.0753	532.0000
10	233	99	885714.20	7486220.72	-22.687274	-47.246751	-1.0799	532.0000
11	234	99	885743.76	7486220.72	-22.687267	-47.246463	-1.1009	531.0000
12	235	99	885773.32	7486220.72	-22.687261	-47.246176	-1.1050	528.0000
13	236	99	885802.88	7486220.72	-22.687254	-47.245889	-1.0898	530.0000
14	237	99	885832.44	7486220.72	-22.687247	-47.245602	-1.0898	533.0000
15	238	99	885861.99	7486220.72	-22.687240	-47.245315	-1.0689	529.0000
16	239	99	885891.55	7486220.72	-22.687234	-47.245028	-1.0700	524.0000
17	235	100	885773.32	7486191.17	-22.687527	-47.246169	-1.1088	530.0000
18	231	100	885655.09	7486191.17	-22.687554	-47.247318	-1.1007	531.0000
19	232	100	885684.64	7486191.17	-22.687547	-47.247030	-1.1023	524.0000
20	233	100	885714.20	7486191.17	-22.687541	-47.246743	-1.0979	529.0000
21	234	100	885743.76	7486191.17	-22.687534	-47.246456	-1.1035	531.0000

Fonte: O Autor.

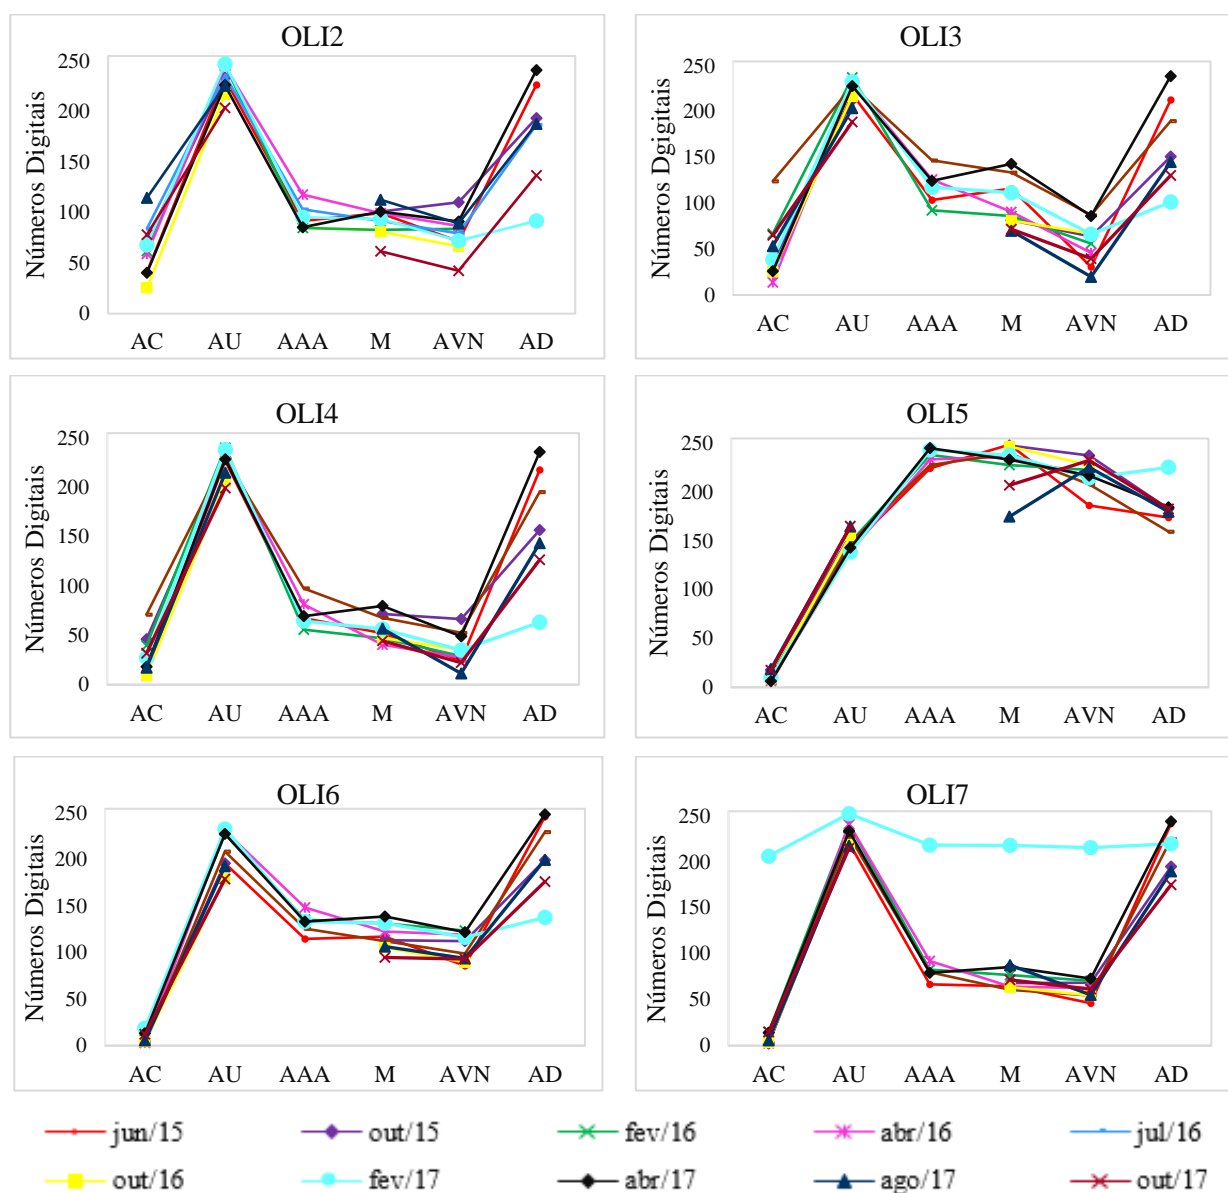
4.3.4.3 Caracterização espectral e textural dos dados de treinamento por classe

Para auxiliar na identificação dos planos de entrada a fim de definir uma arquitetura preliminar de rede neural, bem como analisar o comportamento espectral, textural e temporal das amostras de treinamento que definiram as classes de uso e cobertura da terra, foi avaliada a discriminação entre as classes, a partir da média dos valores digitais dos pixels amostrados para cada classe. Para isso, foram gerados polígonos para cada classe, e então analisados os valores de média em cada plano de entrada e para cada época considerada nesse estudo. Cabe destacar que para algumas classes os valores de média não foram calculados devido a variações temporais, uma vez que algumas regiões amostradas apresentaram mudanças no tipo da cobertura, em especial as áreas agrícolas e áreas descobertas.

Os valores de média foram calculados para cada um dos planos de entrada a serem utilizados para treinamento da rede neural, em cada data de aquisição dos dados multiespectrais. Ainda, foram elaborados gráficos com os valores obtidos para cada classe temáticas (Águas Continentais, Áreas de Vegetação Natural, Áreas Descobertas, Áreas Antrópicas Agrícolas, Áreas Urbanizadas e Macrófitas) definidas para a área de estudo. Na Figura 17, é apresentado o gráfico de níveis digitais (ND) médios definidos pelas bandas multiespectrais do sensor OLI.

De acordo com a Figura 17 a classe águas continentais apresenta baixos valores de reflectância em todas bandas espectrais, causados pelas altas taxas de absorção do fluxo radiante incidente e pelo baixo espalhamento. As classes áreas descobertas e áreas urbanizadas apresentam comportamento similar em todas bandas espectrais, sendo caracterizadas por altos valores de reflectância. Já as classes áreas antrópicas agrícolas, áreas de vegetação natural e macrófitas apresentam comportamento espectral característico da vegetação, com baixa reflectância nas bandas da região do visível (OLI2, OLI3 e OLI4), alta reflectância na região do infravermelho próximo (OLI5) e baixa reflectância, novamente, da região do infravermelho médio (OLI6).

Figura 17 - Variabilidade espectral das classes nas bandas OLI2 (azul), OLI3 (verde), OLI4 (vermelho), OLI5 (infravermelho próximo), OLI6 (infravermelho de ondas curtas 1), OLI6 (infravermelho de ondas curtas 2) do sensor OLI/Landsat 8. AC é Águas Continentais, AU = Áreas Urbanizadas, AAA = Áreas Antrópicas Agrícolas, M = Macrófitas, AVN = Áreas de Vegetação natural e AD = Áreas Descobertas.



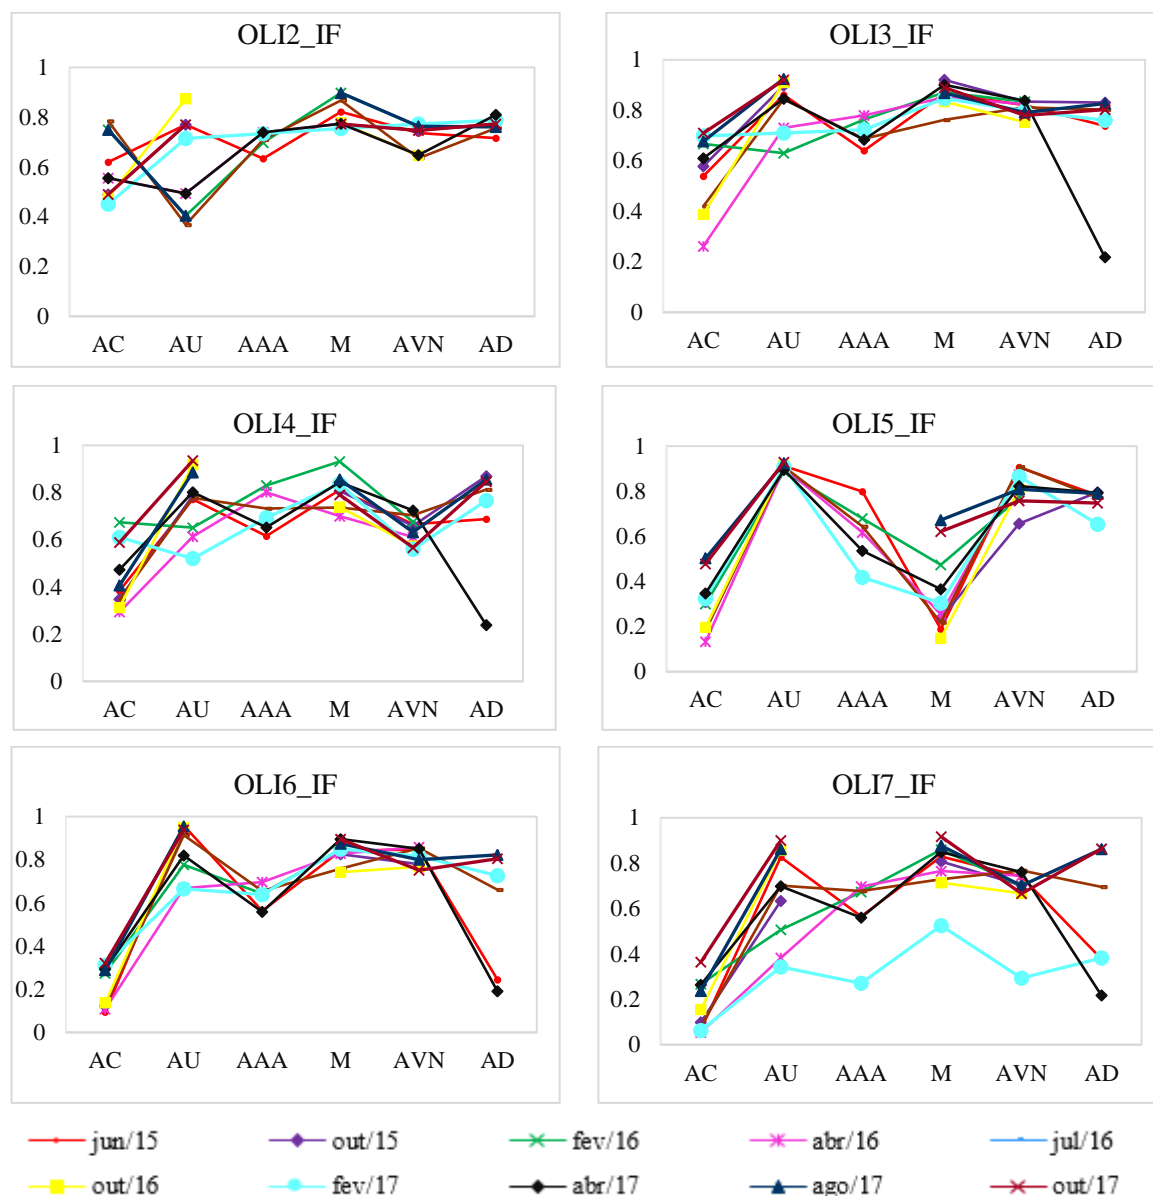
Fonte: O Autor.

A Figura 17 indica mudanças significativas nas médias dos valores de brilho para algumas classes em algumas bandas espectrais e épocas. Essas mudanças são perceptíveis para a classe áreas descobertas, nas bandas OLI2, OLI3 e OLI4. A banda OLI7 apresentou comportamento inesperado em Fev/2017 para todas as classes, o que pode prejudicar discriminação entre as classes se essa banda for incluída como plano de entrada da RNA. Pode-se observar, ainda, que as bandas que apresentaram média dos valores de brilhos mais estáveis ao longo do tempo foram as bandas OLI4, OLI5 e OLI6. Analisando essas bandas, é notável

que as classes áreas descobertas e áreas urbanizadas apresentam comportamento espectral bastante similar, indicando uma possível dificuldade na diferenciação entre esses alvos. Ainda, a similaridade espectral entre as classes áreas antrópicas agrícolas, áreas de vegetação natural e macrófitas indica uma possível confusão entre essas classes.

Buscando melhorar a discriminação, bem como analisar a variabilidade interna das classes, optou-se pela inserção de imagens de textura para composição dos planos de entrada da RNA, conforme indicado por GALO (2000). Para isso, foram geradas imagens de textura a partir das bandas OLI2, OLI3, OLI4, OLI5, OLI6 e OLI7. Assim, como ocorreu com as bandas espectrais, algumas imagens de textura apresentaram diferenças significativas nos valores de média, conforme pode ser observado a partir das imagens computadas a partir das bandas OLI2, OLI3, OLI4 e OLI7 (Figura 18). A imagem de textura gerada a partir das bandas OLI5 e OLI6 pode contribuir significativamente na discriminação entre áreas antrópicas agrícolas e macrófitas. Além disso, a imagem de textura computada sobre a banda OLI6, pode ser essencial na separação entre as classes áreas urbanizadas e áreas descobertas.

Figura 18 - Variabilidade textural das classes indicada pelo Índice de Fragmentação (IF) extraídos das bandas espectrais do sensor OLI/Landsat 8. AC é Águas Continentais, AU = Áreas Urbanizadas, AAA = Áreas Antrópicas Agrícolas, M = Macrófitas, AVN = Áreas de Vegetação natural e AD = Áreas Descobertas.



Fonte: O Autor.

Chen et al., (2006) afirmam que a integração de índices espectrais possui potencial para representar e discriminar quantitativamente os tipos de cobertura da terra. Nesse sentido, foram calculados alguns índices espectrais para serem incluídos aos dados de treinamento, como uma tentativa de melhorar a discriminação entre os principais alvos presentes na cena de Jun/2015. Os índices espectrais calculados foram o NDVI, RS, NDBI e MDWI.

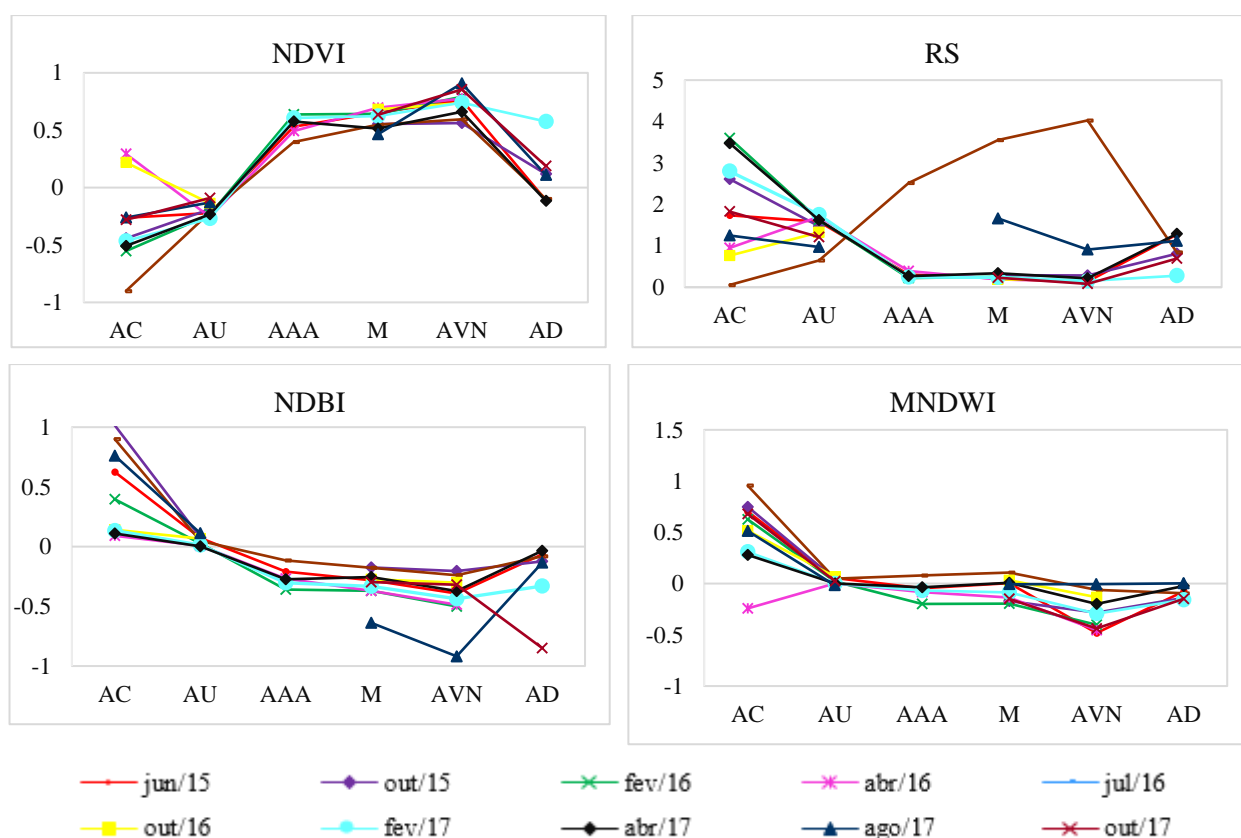
Como apresentado na Figura 19, é evidente a contribuição dos índices NDVI e MNDWI na definição das classes relacionadas com vegetação e corpos d'água, respectivamente. No

entanto, é notável a variabilidade dos valores de média do índice MNDWI na classe Água Continental, o que demonstra a dinamicidade sazonal do corpo d'água.

Em relação ao índice RS, esse apresentou grandes variações nos valores de médias, em algumas classes, como pode ser observado na classe águas continentais. Na época out/2017, esse índice teve um comportamento discrepante quando comparado com as demais épocas. Devido a isso, esse índice foi excluído dos planos de entrada para treinamento da RNA, uma vez que pode aumentar a confusão entre as classes no momento de treinamento da rede.

A uniformidade do índice NDBI para as classes áreas descobertas e áreas urbanizadas está relacionada com a similaridade espectral entre esses alvos (Figura 19), sendo esse um indicador de confusão entre essas classes.

Figura 19 - Variabilidade média das classes obtida a partir dos índices espectrais. AC é Águas Continentais, AU = Áreas Urbanizadas, AAA = Áreas Antrópicas Agrícolas, M = Macrófitas, AVN = Áreas de Vegetação natural e AD = Áreas Descobertas.



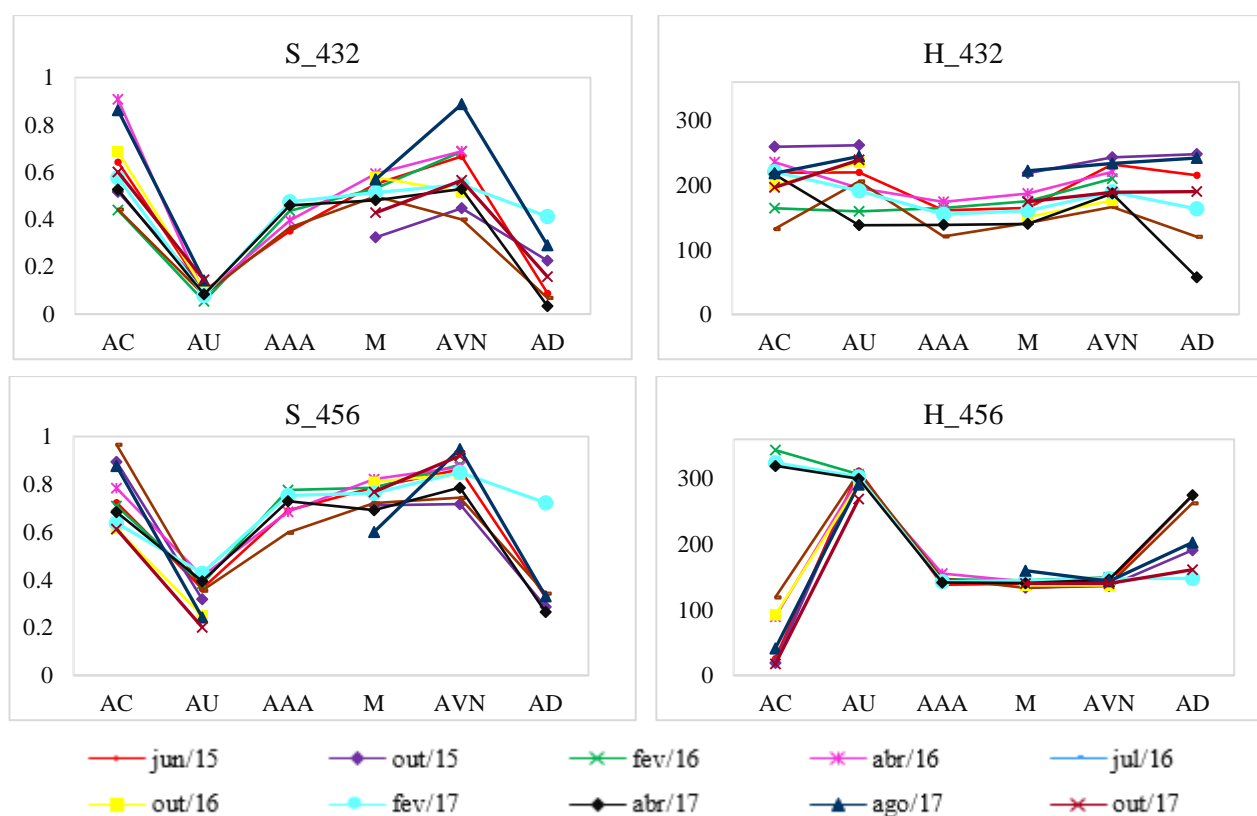
Fonte: O Autor.

Foi verificada também a contribuição da inclusão das componentes da transformação IHS aos planos de entrada. Essas componentes foram geradas a partir de combinações de

bandas espectrais do visível (OLI2, OLI3 e OLI4) e uma combinação falsa cor (OLI4, OLI5 e OLI6) (Figura 20).

A partir das componentes S, é possível observar que a composição que pode melhor contribuir para discriminação entre as classes é aquela oriunda da composição com bandas do visível. Destaca-se que essa componente pode ser importante na separação entre as classes áreas antrópicas agrícolas e áreas de vegetação natural, devido a significativa variação de valores médios entre essas classes. A componente H, proveniente de composição das bandas do visível, tem potencial para maior discriminação entre as classes, uma vez que apresenta variação significativa entre as classes. Ainda, essa componente pode auxiliar na discriminação entre áreas antrópicas agrícolas e áreas de vegetação natural.

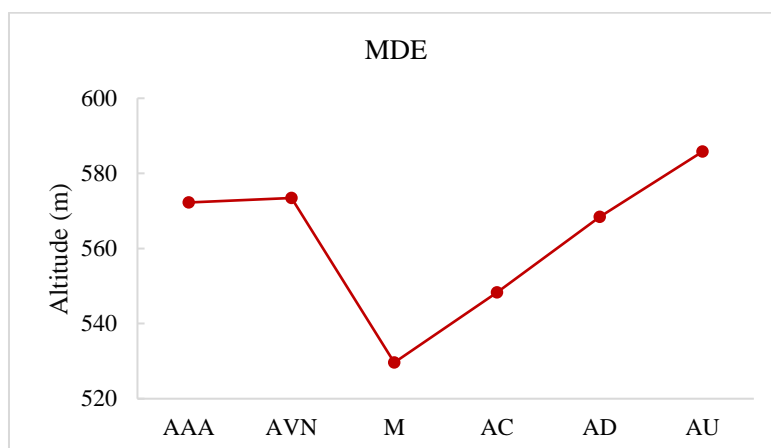
Figura 20 - Variabilidade dos valores de H (matiz) e S (saturação) para as classes. AC é Águas Continentais, AU = Áreas Urbanizadas, AAA = Áreas Antrópicas Agrícolas, M = Macrófitas, AVN = Áreas de Vegetação natural e AD = Áreas Descobertas.



Fonte: O Autor.

Adicionalmente, foi inserido ao conjunto de dados de treinamento um MDE, uma vez que se pressupõe que seja possível discriminar e diminuir a ambiguidade entre macrófitas aquáticas e outros tipos de vegetação que ocorrem próximas ao corpo d'água (Figura 21).

Figura 21 - Variabilidade dos valores de altitude para as classes. AC é Águas Continentais, AU = Áreas Urbanizadas, AAA = Áreas Antrópicas Agrícolas, M = Macrófitas, AVN = Áreas de Vegetação natural e AD = Áreas Descobertas.



Fonte: O Autor.

4.3.4.4 Geração dos arquivos de treinamento no formato ARFF

Para treinar e classificar dados utilizando o WEKA é necessário convertê-los para o formato padrão do WEKA, o *Attribute – Relation File Format* (ARFF). O ARFF possui duas seções, no qual a primeira é definida pelo cabeçalho e em seguida a seção dos dados. O cabeçalho do arquivo ARFF contém o nome da relação, uma lista dos atributos e seus tipos. O nome da relação (@relation) é definido como a primeira linha no arquivo. Os tipos de atributos suportados pelo *software* são numéricos, nominais e datas. Além disso, no arquivo os campos devem ser separados por vírgulas, e as classes são especificadas entre colchetes (Figura 2).

Figura 22 - Arquivo ARFF

```
@relation Amostras
@attribute classe {Cultura,Mata,Macrofitas,Agua,SoloExposto,SoloPreparado,AreaUrbana}
@attribute MDS NUMERIC
@attribute B6_IF NUMERIC
@attribute B6 NUMERIC
@attribute B5_IF NUMERIC
@attribute B5 NUMERIC
@attribute B4_IF NUMERIC
@attribute B4 NUMERIC
@attribute NDWI NUMERIC
@attribute NDVI NUMERIC
@attribute NDBI NUMERIC
@attribute H(456) NUMERIC
@attribute S(456) NUMERIC
@attribute H(RGB) NUMERIC
@attribute S(RGB) NUMERIC

@data
Cultura,532,1,106,1,241,0.75,46,0.389,0.6794,-1.0685,138.4615,0.8091,166.0465,0.4886
```

Fonte: O Autor.

O arquivo de treinamento ARFF foi composto pelos planos de entrada que compõem a arquitetura da rede neural, além das classes de saída. Considerando que foram realizados

experimentos no sentido de incluir ou excluir planos de entrada, destaca-se que para cada teste, é utilizado o mesmo arquivo de treinamento, sendo excluído ou inserido apenas os planos de entrada utilizados no treinamento de cada RNA. O WEKA é flexível em permitir que seja escolhido quais padrões, daqueles presentes no arquivo ARFF, serão utilizados no momento do treinamento.

4.3.4.5 Treinamento e simulações das arquiteturas de RNA

As simulações realizadas para o treinamento da rede neural, consistiram na aplicação de diferentes arquiteturas de rede, a fim de selecionar a arquitetura que apresenta um melhor desempenho na classificação dos dados. Os dados de treinamento e validação foram submetidos a uma configuração de rede neural constituída por camadas escondidas, além da entrada e camada de saída, designada *Multilayer Perceptron (ML)*.

Para as simulações de redes realizadas, a priori foram definidos os parâmetros de configuração da rede, estabelecendo o número de camadas escondidas, bem como a quantidade de elementos de processamento em cada camada.

Para os experimentos realizados foi verificado a influência da inclusão e/ou exclusão de determinados planos de entrada. Essa etapa foi baseada em investigar a influência dos planos de entrada na discriminação das classes de saída. Ao total, foram avaliadas (treinadas) 15 arquiteturas de RNA com a finalidade de se identificar a configuração de rede mais adequada para classificar os dados selecionados. Em todas as simulações, variou-se as combinações de planos de entrada mas mantendo os mesmos parâmetros da rede, desde número de camadas intermediárias, taxa de aprendizagem, taxa de momento e ciclos de treinamento. As arquiteturas de rede que apresentaram melhor desempenho são apresentadas no Quadro 2.

O Experimento 1 foi composto pelos seguintes planos de entrada: imagens multiespectrais referentes as bandas OLI2, OLI3, OLI4, OLI5, OLI6 e OLI7, imagens de textura provenientes das bandas OLI2, OLI3, OLI4, OLI5, OLI6 e OLI7, índices espectrais NDVI, RS, MNDWI e NDBI, componentes matiz (H) e saturação (S), resultantes das composições coloridas normal (OLI2, OLI3 e OLI4) e falsa cor (OLI4, OLI5 e OLI6), além do MDE. No experimento 2, com a finalidade de reduzir o espaço de atributos, contudo mantendo um bom desempenho da classificação, os planos de entrada se restringiram as bandas OLI3, OLI4, OLI5 e OLI6, imagens de textura provenientes das bandas OLI5 e OLI6, índices espectrais NDVI, MNDWI e NDBI, componentes matiz (H) e saturação (S) referentes à composição colorida normal (OLI2, OLI3 e OLI4) e componente matiz (H) da composição falsa

cor, além do MDE. Já no experimento 3, os planos de entrada utilizados foram as bandas OL 4, OLI5 e OLI6, imagens de textura provenientes das bandas OLI5 e OLI6, índices espectrais NDVI, MNDWI e NDBI, componentes matiz (H) e saturação (S) referentes a composição colorida normal (OLI2, OLI3 e OLI4) e o MDE.

Quadro 2 - Composição de dados de entrada para a RNA

Experimentos	Composição dos dados de entrada	Arquitetura
1	<ul style="list-style-type: none"> - <u>Bandas espectrais</u>: Jun/2015: OLI2, OLI3, OLI4, OLI5, OLI6, OLI7; - <u>Imagem textura</u>: OLI2, OLI3, OLI4, OLI5, OLI6, OLI7; - <u>Índices espectrais</u>: NDVI, RS, MNDWI, NDBI; - <u>Transformação no espaço cor IHS</u>: Componentes H e S (OLI432 e OLI456); - MDE. 	21 – 27 – 14 - 6
2	<ul style="list-style-type: none"> - <u>Bandas espectrais</u>: Jun/2015: OLI3, OLI4, OLI5, OLI6; - <u>Imagem textura</u>: OLI5, OLI6; - <u>Índices espectrais</u>: NDVI, MNDWI, NDBI; - <u>Transformação no espaço cor IHS</u>: Componentes H e S (OLI432) e componente H(OLI456); - MDE. 	13 – 19 -10 - 6
3	<ul style="list-style-type: none"> - <u>Bandas espectrais</u>: Jun/2015: OLI4, OLI5 e OLI6; - <u>Imagem textura</u>: OLI5 e OLI6; - <u>Índices espectrais</u>: NDVI, MNDWI, NDBI; - <u>Transformação no espaço de cor IHS</u>: Componentes H e S (OLI432); - MDE. 	11 – 17 – 9 -6

Fonte: O Autor.

Para todos os experimentos realizados foram definidos a taxa de aprendizagem (α) de 0,01, termo de momento como sendo 0,1, bem como foi utilizada a função de ativação sigmodal. Além disso, estabeleceu-se o número de ciclos de treinamento como sendo 3000. O número de épocas de treinamento pode afetar consideravelmente a qualidade da resposta da rede. Em casos em que o número de épocas é pequeno, a rede pode não extrair adequadamente as características dos dados de entrada, já um número elevado de épocas pode provocar um sobreajuste da rede, quando a rede memoriza os padrões fornecidos e se torna incapaz de generalizar as

características extraídas para outros conjuntos de dados. Dessa forma, o número de épocas foi definido a partir da análise da convergência do erro médio quadrático (EMQ) no treinamento. Sendo assim, em experimentos preliminares foi observado que o EMQ no treinamento alcançava valores estáveis em torno da época 3000.

O arquivo de treinamento foi dividido de modo que 80% dos pixels amostrados fossem utilizados para treinamento e 20% para validação. Destaca-se que os dados de treinamento e validação são definidos de forma randômica pelo WEKA.

4.3.4.6 Aplicação da rede treinada para classificação das imagens sazonais

Após a seleção da rede neural cuja arquitetura de pesos ajustados apresentou melhor desempenho, é necessário aplicá-la para classificar o conjunto de imagens sazonais. A rede neural selecionada, então, foi utilizada para a classificação das imagens tomadas em cada época considerada nesse estudo. Essa etapa foi realizada no próprio WEKA, por meio da ferramenta *Supplied test set*, que faz uma classificação do conjunto de dados a partir da arquitetura de rede neural gerada anteriormente. Dessa forma, para cada data de aquisição das imagens multiespectrais, as classificações foram realizadas pelo modelo de rede neural treinada a partir dos conjuntos de dados de Jun/2015.

Para classificação do conjunto de imagens, deve ser gerado um novo arquivo ARFF para cada época considerada. Nesse arquivo ARFF de classificação devem constar os valores de cada pixel de toda a cena, em cada plano de entrada. Além disso, os pixels devem ser rotulados como *unclassified* ou, simplesmente, sem rótulo (?).

Por fim, com base no resultado da aplicação das redes treinadas e em análises para estimar a exatidão da classificação, foi selecionada a arquitetura de rede mais adequada para classificar o conjunto de dados espaciais.

4.3.4.7 Geração das imagens resultantes da classificação

O *software* WEKA produz um arquivo de saída o qual indica as classes de saída previstas para cada pixel da cena classificada, além do erro de predição (Figura 23), o qual está associado a probabilidade de determinado pixel ter sido classificado corretamente. No entanto, para geração do mapa temático da classificação, é necessário associar cada pixel classificado com as suas coordenadas associadas com as imagens OLI. Tal procedimento é necessário uma vez

que o arquivo de saída do *software* WEKA não associa os pixels classificados com suas coordenadas.

Figura 23 - Arquivo de saída WEKA 3.8

inst#	actual	predicted	error prediction
1	1:?	3:Macrofitas	0.684
2	1:?	3:Macrofitas	0.477
3	1:?	4:Agua	0.53
4	1:?	3:Macrofitas	0.664
5	1:?	3:Macrofitas	0.983
6	1:?	3:Macrofitas	0.588
7	1:?	3:Macrofitas	0.648
8	1:?	3:Macrofitas	0.668
9	1:?	4:Agua	0.782
10	1:?	4:Agua	0.917
11	1:?	4:Agua	0.993
12	1:?	4:Agua	0.99

Fonte: O Autor.

Posteriormente, o resultado da aplicação de cada rede neural é convertido em formato imagem (*raster*). Essa etapa é realizada no ArcGis 10.6, por meio da ferramenta *Point to Raster*. Para a utilização dessa ferramenta é necessário a definição dos seguintes parâmetros: tamanho da célula (pixel) e qual atributo será atribuído a cada pixel. Nesse sentido, o tamanho da célula é definido como sendo 30 e o atributo atribuído ao pixel se refere às classes de saída da classificação gerada pelo WEKA.

4.4 Estimativa da exatidão das cenas classificadas e análise da incerteza do processo de classificação

A verificação de cada modelo de RNA treinado será realizada utilizando métricas clássicas como índice kappa e exatidão global. Ressalta-se que as métricas citadas anteriormente foram obtidas através de matrizes de concordância geradas pelo próprio WEKA.

O processo de classificação será avaliado por meio da análise de medidas de incerteza. A incerteza para cada pixel da imagem classificada é dada a partir de um valor de probabilidade, a qual indica a chance do pixel ter sido classificado na classe verdadeira. Então, esse valor de probabilidade representa a probabilidade *a posteriori* de um determinado pixel da imagem pertencer a uma das classe de uso e cobertura do solo e é dado por:

$$P(\omega = \omega_j | \vec{x}) \quad (15)$$

onde \vec{x} é um vetor de atributos que descreve um pixel e $(\omega_j | \vec{x})$ indica a probabilidade da classe ω_j , para $j= 1, \dots, M$ classes, ser correta para esse pixel (RICHARDS e JIA, 2006).

A partir disso têm -se que a incerteza associada ao pixel para uma classe ω_j é definida como sendo:

$$1 - P(\omega = \omega_j | \vec{x}) \quad (15)$$

Para analisar a incerteza das cenas classificadas foram utilizadas imagens de incerteza, geradas a partir de valores de probabilidade. Esses valores de probabilidade são computados pelo próprio WEKA, e são obtidos para cada pixel por meio do arquivo de saída da classificação. E, indicam uma estimativa da probabilidade que o modelo de RNA treinado tenha classificado os dados corretamente.

5 RESULTADOS

5.1 Arquitetura de redes neurais artificiais utilizadas

Estabelecidas as combinações de dados que seriam utilizados para as classificações (Quadro 2), definiram-se as arquiteturas de RNA para a realização dos experimentos, utilizando a cena tomada em junho de 2015, como referência temporal. A Tabela 6 indica as arquiteturas de rede usadas nos experimentos realizados, bem como os valores de EMQ obtidos no treinamento e na validação. Cabe destacar que no treinamento de redes neurais é esperada uma redução gradativa do EMQ, contudo o desempenho de uma arquitetura de rede neural não deve ser avaliado apenas pelo EMQ, mas sim pela sua capacidade em discriminar as ocorrências na amostra de validação (GALO, 2000).

Tabela 6 - Arquiteturas de RNA avaliadas nos experimentos realizados com base na cena de Jun/2015. Cada arquitetura é especificada da seguinte forma: número de variáveis de entrada – número de nós da primeira camada escondida – número de nós da segunda camada escondida – número de classes de saída. EQM é o Erro Médio Quadrático obtido usando dados de treinamento ou validação.

Experimentos	Arquitetura	EMQ – Treinamento	EMQ - Validação
1	21 – 27 – 14 - 6	0,007161	0,000938
2	13 – 19 -10 - 6	0,0018498	0,0015313
3	11 – 17 – 9 - 6	0,001183	0,001394

Fonte: O Autor.

Pode-se verificar pela Tabela 6 que a arquitetura definida no Experimento 2 [13 – 19 -10 – 6] foi a que produziu maior valor de EMQ para os dados de validação (20% da amostra), levando a descartar a sua aplicação para classificação dos demais conjuntos de imagens. Por outro lado, observa-se que as arquiteturas analisadas no Experimento 1 [21 – 27 – 14 – 6] e Experimento 3 [11 – 17 – 9 – 6] apresentou resultados próximos, contudo o EMQ de treinamento obtido no Experimento 1 foi muito superior ao obtido no Experimento 3.

Cabe destacar que a escolha de uma arquitetura de RNA deve ser feita com cautela, pois uma rede neural pode fornecer resultados imprecisos se o número de camadas escondidas e/ou neurônios nessas camadas for inconsistente. Isso ocorre porque o modelo pode fazer o subajuste (*underfitting*) dos dados de treinamento quando a RNA apresenta desempenho insatisfatório nos dados de treinamento, isso ocorre porque a rede não consegue realizar a correspondência entre os dados de entrada e as classes de saída. Além disso, a RNA pode fazer um sobreajuste (*overfitting*) dos dados de treinamento, quando ela apresenta desempenho satisfatório nos dados

de treinamento, mas não nos dados de avaliação. Dessa forma, para a escolha da RNA com melhor desempenho, optou-se pela rede apresentada no Experimento 3, uma vez que o EMQ de treinamento (0,001183) obtido nesse experimento foi muito inferior ao obtido no Experimento 1 (0,007161), evitando assim o erro de subajuste.

Por fim, verificou-se que a redução de dados altamente correlacionados e, conseqüentemente, utilizando apenas os atributos de entrada que determinaram maior discriminação entre as classes, teve melhor desempenho quanto ao erro de treinamento e validação da RNA.

5.2 Desempenho das redes neurais utilizadas na classificação da cena de Jun/2015

A Tabela 7 apresenta as estatísticas geradas a partir dos dados de validação para os experimentos realizados utilizando toda a cena de Jun/2015. Além disso, é apresentado o tempo que foi necessário para o treinamento de cada arquitetura de RNA.

Tabela 7 - Indicadores estatísticos da validação para a classificação da cena de Jun/2015, considerando os três experimentos realizados. EG é a exatidão global da classificação.

Arquitetura	Experimento 1	Experimento 2	Experimento 3
Estatísticas	21-27-14-6	13-19 -10-6	11-17-9-6
Kappa (%)	0,9811	0,9829	0,9829
EG	0,9847	0,9847	0,9862
Tempo treinamento	10 min	11 min	8 min

Fonte: O Autor.

A Tabela 7 permite verificar que todos os experimentos proporcionaram resultados satisfatórios, uma vez que apresentaram valores de índice Kappa superiores a 0,98. A robustez das arquiteturas de RNA é comprovada quando, mesmo com a redução do número de planos de entrada, os valores de acurácia alcançados aumentam e o tempo de processamento é reduzido. Além disso, os resultados apontam para a necessidade de considerar a capacidade dos dados de entrada em discriminar as classes de interesse.

A arquitetura [13-19-10-6] (Kappa = 0,9829), Experimento 2, obteve resultado similar ao obtido pela arquitetura [11-17-9-6] (Kappa = 0,9829), Experimento 3, e ligeiramente superior ao da arquitetura [21-27-14-6] (Kappa = 0,9811), Experimento 1. Apesar do Experimento 2 e Experimento 3 apresentarem o mesmo valor de Kappa, nota-se que o terceiro experimento apresentou valores ligeiramente superiores de EG. A partir disso, presume-se que

a arquitetura de RNA apresentada no Experimento 3 pode apresentar melhores resultados. Quando se considera a quantidade de atributos utilizados em cada arquitetura de RNA, nota-se que a arquitetura [21-27-14-6] foi a que apresentou menor valor de índice Kappa, mesmo utilizando todos os 21 planos de entrada disponíveis. Por outro lado, a arquitetura [11-17-9-6] apresentou valores superiores de precisão, utilizando apenas 11 planos de entrada. Esse resultado evidencia a possibilidade de se obter resultados satisfatórios com uma RNA que dispõe de menor número de planos de entrada e que ofereçam maior potencial de discriminação de classes de uso e cobertura da terra.

As Tabelas 8, 9 e 10 apresentam as matrizes de confusão geradas para os experimentos realizados. Destaca-se que a matriz de confusão foi computada sobre 20% dos dados da amostra de treinamento, sendo definidos de forma randômica pelo WEKA.

Tabela 8 - Matriz de confusão computada para os Experimento 1 (arquitetura 21-27-14-6) (a). Em que: AAA significa áreas antrópicas agrícolas; AVN, áreas de vegetação natural; M, Macrófitas; AC, água continental; AD, áreas descobertas e; AU, áreas urbanizadas. AU, áreas urbanizadas. AUs é a acurácia do usuário e APr é a acurácia do produtor.

	AAA	AVN	M	AC	AD	AU	Total	AUs
AAA	278	0	1	0	0	0	279	0,996
AVN	0	239	1	0	0	0	240	0,996
M	3	1	42	0	0	0	46	0,913
AC	0	0	0	224	0	0	224	1
AD	0	0	0	0	336	5	341	0,985
AU	0	0	0	0	10	237	247	0,959
Total	281	240	44	224	346	242	1377	
APr	0,989	0,996	0,954	1	0,971	0,979		

Fonte: O Autor.

Tabela 9 - Matriz de confusão computada para os Experimento 2 (arquitetura 13-19-10-6). Em que: AAA significa áreas antrópicas agrícolas; AVN, áreas de vegetação natural; M, Macrófitas; AC, água continental; AD, áreas descobertas e; AU, áreas urbanizadas. AUs é a acurácia do usuário e APr é a acurácia do produtor.

	AAA	AVN	M	AC	AD	AU	Total	AUs
AAA	279	0	0	0	0	0	279	1
AVN	0	240	0	0	0	0	240	1
M	4	0	42	0	0	0	46	0,913
AC	0	0	0	224	0	0	224	1
AD	0	0	0	0	333	8	341	0,957
AU	0	0	0	0	7	240	247	0,972
Total	283	240	42	224	340	248	1377	
APr	0,986	1	1	1	0,979	0,968		

Fonte: O Autor.

Tabela 10 - Matriz de confusão computada para o Experimento 3 (11-17-9-6). Em que: AAA significa áreas antrópicas agrícolas; AVN, áreas de vegetação natural; M, Macrófitas; AC, água continental; AD, áreas descobertas e; AU, áreas urbanizadas. AUs é a acurácia do usuário e APr é a acurácia do produtor.

	AAA	AVN	M	AC	AD	AU	Total	AUs
AAA	279	0	0	0	0	0	279	1
AVN	0	239	1	0	0	0	240	0,996
M	3	0	43	0	0	0	46	0,935
AC	0	0	0	224	0	0	224	1
AD	0	0	0	0	334	7	341	0,979
AU	0	0	0	0	8	239	247	0,968
Total	282	239	44	224	342	246	1377	
APr	0,989	1	0,977	1	0,977	0,971		

Fonte: O Autor

Os valores de acurácia, para cada classe, foram superiores a 0,90 para todos os testes. Destaca-se que, em todos os experimentos, a classe água continental foi a melhor identificada, com valores de acurácia iguais a 1 tanto para a acurácia do produtor quanto do usuário, o que demonstra que o reservatório é bem delimitado em todas as arquiteturas avaliadas.

Seguida da classe água continental, a classe melhor identificada foi áreas de vegetação natural, apresentando valores máximo de acurácia nos experimentos 2 e 3. No experimento 1, houve confusão dessa classe com a classe macrófitas, o que pode ser atribuído ao comportamento espectral bastante similar entre essas coberturas. Nos demais experimentos essa

confusão pode ter sido reduzida em decorrência da diminuição de planos de entrada e, conseqüentemente, redução de dados altamente correlacionados.

As classes áreas descobertas e áreas urbanizadas apresentaram valores inferiores de acurácia quando comparadas com as demais classes, em todos os experimentos. Esses resultados também são decorrentes da similaridade espectral entre essas duas classes. Nesse caso, verificou-se grande confusão entre áreas descobertas/ áreas urbanizadas, independente do conjunto de dados utilizados. Esse grau de confusão pode também ser explicado pelas características das áreas urbanizadas, visto que é um alvo com grande frequência de pixels mistos, ou seja, com subcategorias de outras classes de uso da terra.

Com base nos resultados obtidos nas etapas de treinamento e validação dos dados derivados da imagem de referência tomada em junho de 2015, acrescidos do MDE, a arquitetura adotada nas classificações das imagens das demais épocas foi aquela especificada no Experimento 3 (Quadro 2).

5.3 Imagens sazonais classificadas com a arquitetura definida para Jun/2015

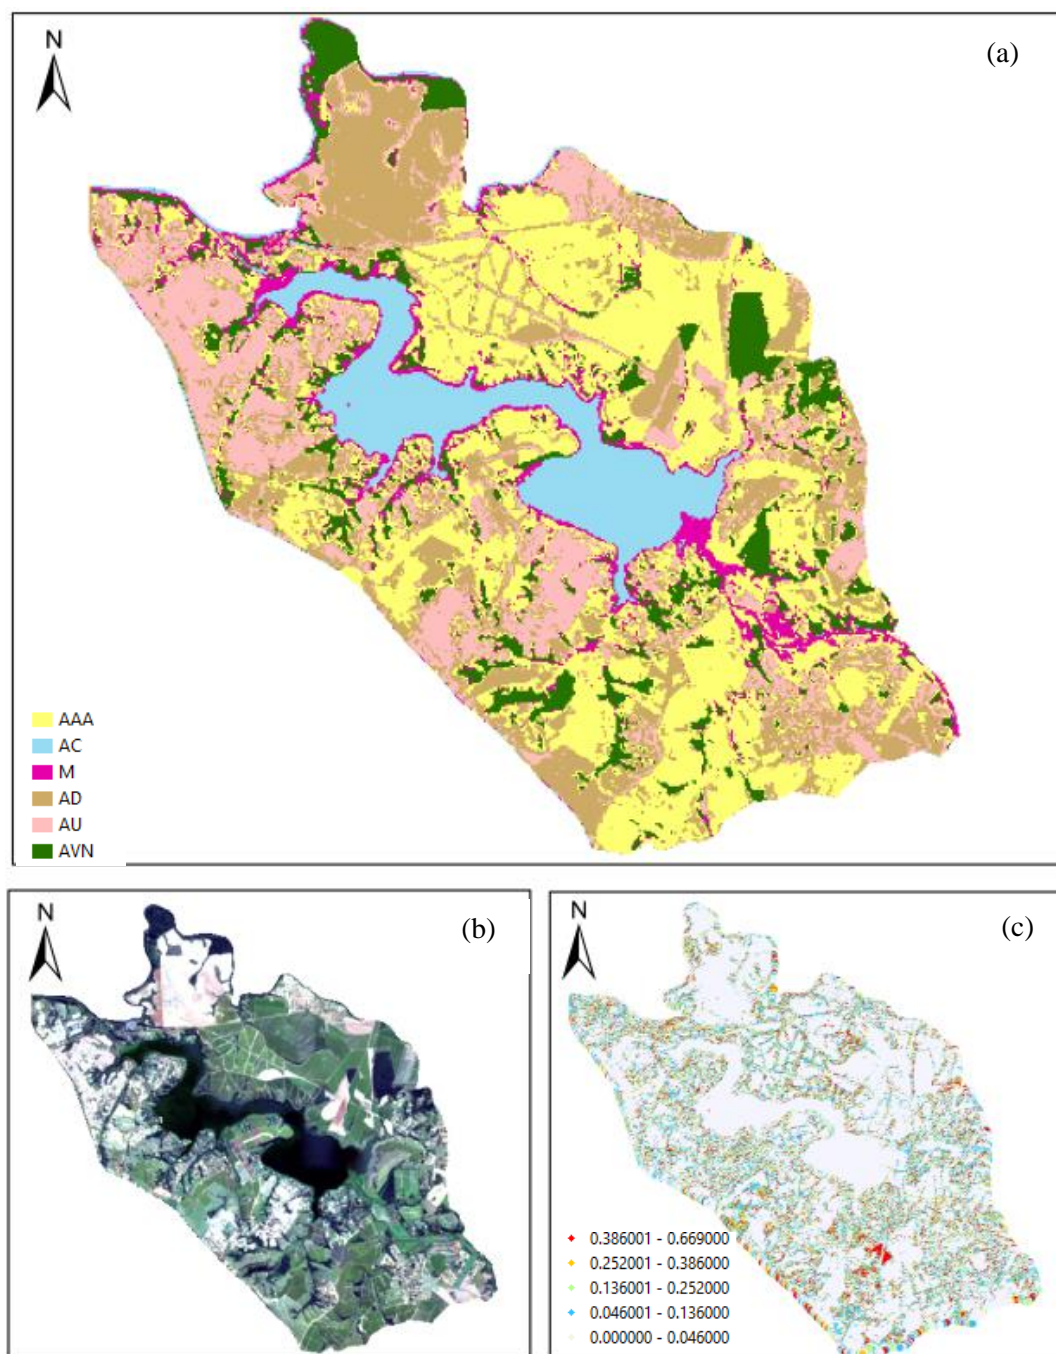
Diante dos experimentos realizados e dos resultados até aqui apresentados, optou-se pela utilização da arquitetura de RNA avaliada no experimento 3 (11-17-9-6) para classificação do conjunto de imagens sazonais. A seguir são apresentados os resultados obtidos a partir da aplicação da arquitetura de RNA treinada com amostras adquiridas de imagens de junho de 2015, na classificação imagens sazonais de 26 de junho de 2015 (Figura 24), 9 de outubro de 2015 (Figura 25), 5 de fevereiro de 2016 (Figura 27), 18 de abril de 2016 (Figura 29), 7 de julho de 2016 (Figura 30), 2 de outubro de 2016 (Figura 32), 23 de fevereiro de 2017 (Figura 35), 28 de abril de 2017 (Figura 36), 27 de agosto de 2017 (Figura 38), e 5 de outubro de 2017 (Figura 41). Além disso, para cada classificação foi associada a imagem de incerteza decorrente do resultado da classificação de cada época. Essa imagem de incerteza permitiu reconhecer as regiões mapeadas com maior probabilidade de erro.

A cena classificada para época Jun/2015 pode ser visualizada na Figura 24a. Em uma primeira análise é possível verificar que todas as classes de uso da terra foram bem representadas. A partir disso, têm-se as áreas antrópicas agrícolas como a classe predominante no entorno do reservatório. Observa-se ainda a classe áreas urbanizadas definiu ocorrências dispersas em toda a área de estudo, porém com grandes núcleos situados próximos às margens do reservatório. Quanto as áreas de vegetação natural, há déficit de fragmentos florestais e áreas de preservação permanente às margens do reservatório.

Ainda, no que diz respeito a classificação de junho de 2015 (Figura 24a), percebe-se que a RNA apresentou dificuldade em distinguir as classes áreas urbanizadas e áreas descobertas, mesmo com a utilização do índice NDBI. Esse resultado é aparente na porção norte da área de estudo, e é decorrente da similaridade espectral entre essas classes. Em contrapartida, as classes relacionadas a vegetação foram classificadas com exatidão, sendo a classe macrófitas bem discriminada das classes áreas de vegetação natural e áreas agrícolas.

A imagem de incerteza, Figura 24c, gerada a partir da classificação da cena de Jun/2015 (Figura 24a), confirma o bom desempenho da RNA na definição dos tipos de cobertura da terra de interesse, mostrado pela predominância e baixa incerteza (cinza no mapa). Assim sendo, percebe-se que a RNA não encontrou maiores dificuldades em classificar os pixels pertencentes a classe água continental e macrófitas. Essas classes apresentaram incerteza quase nula, por outro lado as regiões com presença de áreas urbanizadas e áreas descobertas, bem como as regiões de transições entre essas duas classes, apresentaram maior grau de incerteza.

Figura 24 - Classificação resultante da aplicação da RNA à imagem de Jun/2015 (a); Composição colorida (OLI4/OLI3/OLI2) com imagens de Jun/2015 (b); Imagem de incerteza da classificação de Jun/2015 (c). Em que: AAA = áreas antrópicas agrícolas, AC = água continental, M = Macrófitas, AD = áreas descobertas, AU = áreas urbanizadas, AVN = áreas de vegetação natural.

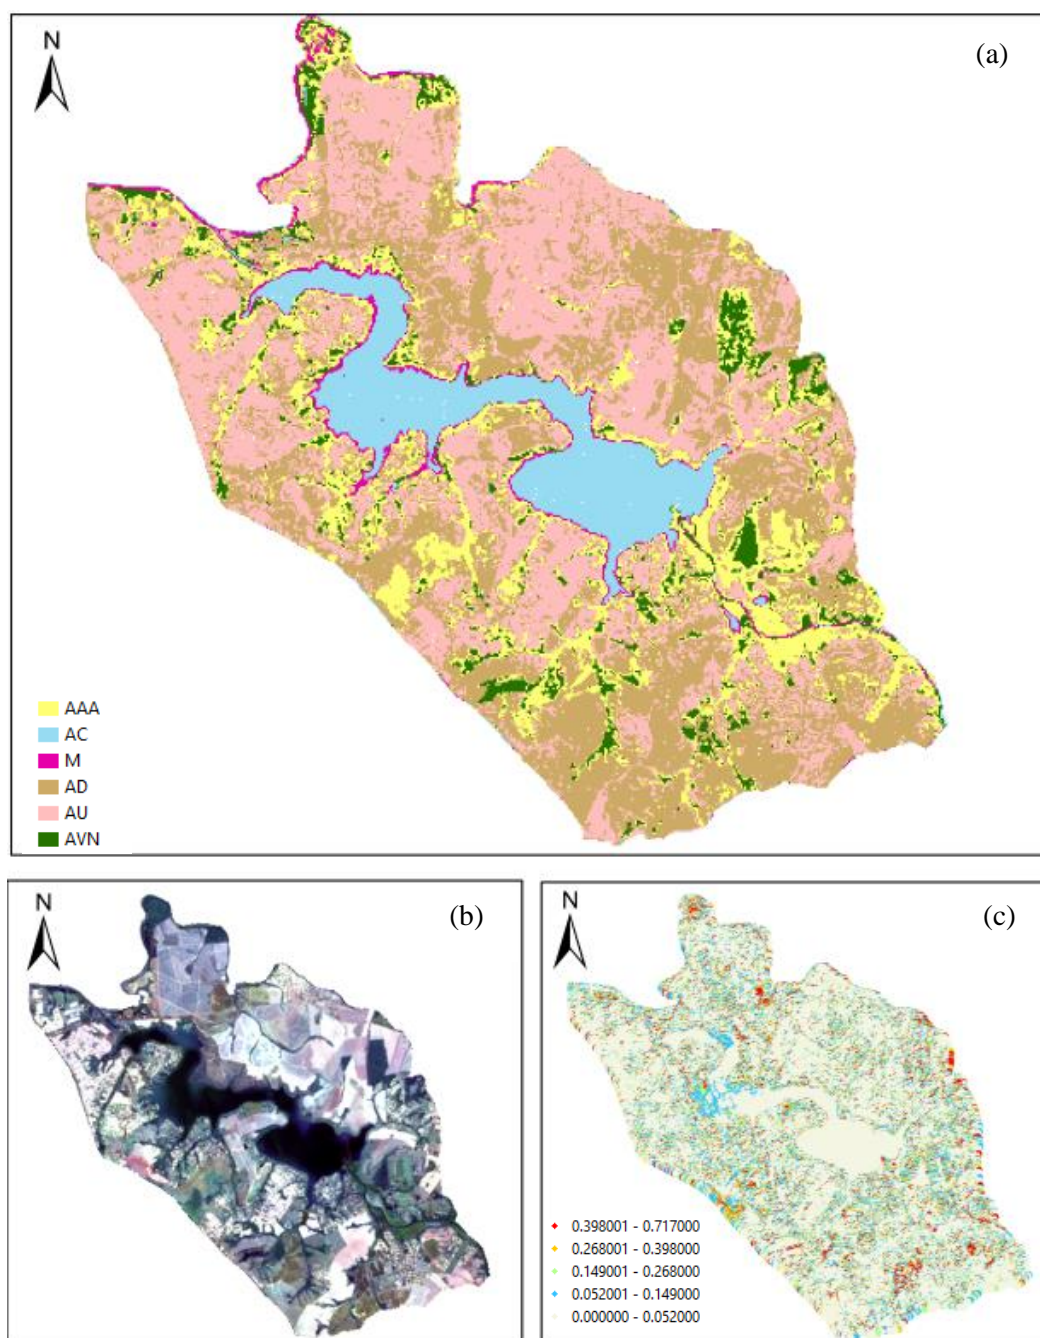


Fonte: O Autor.

O resultado da aplicação da RNA, treinada com amostras coletadas em dados de Junho de 2015, para classificação das cenas de Out/2015 é apresentado na Figura 25a. Por essa classificação foi possível verificar que a RNA não apresentou bons resultados para discriminação das áreas descobertas e áreas urbanizadas. A confusão entre essas classes, foi

caracterizada principalmente pela classificação de pixels de áreas descobertas como sendo da classe áreas urbanizadas. Como pode ser visualizado na Figura 25b, a área ao entorno do reservatório, na época de outubro de 2015, é caracterizada por grandes áreas descobertas. Logo, devido aos padrões de comportamento espectral semelhantes verificados para essas classes, é esperado uma maior dificuldade de discriminação.


Figura 25 - Classificação resultante da aplicação da RNA à imagem de Out/2015 (a); Composição colorida (OLI4/OLI3/OLI2) com imagens de Out/2015 (b); Imagem de incerteza da classificação de Out/2015 (c). Em que: AAA = áreas antrópicas agrícolas, AC = água continental, M =Macrófitas, AD = áreas descobertas, AU = áreas urbanizadas, AVN = áreas de vegetação natural.



Fonte: O Autor.

Ainda de acordo com os resultados obtidos para a época Out/2015, é possível verificar na Figura 25c que os pixels pertencentes as classes áreas descobertas e áreas urbanizadas são caracterizadas por valores de incerteza variando entre 0,268001 -0,7170. Ao analisar as imagens utilizadas para classificar as cenas de Out/2015, nota-se que os índices de fragmentação das bandas OLI6 e OLI5, podem ter influenciado para que se alcançasse altos valores de incerteza. Essas imagens de textura indicam se há variabilidade espacial na região da janela onde o operador é calculado. Ao considerar que a resposta espectral entre áreas urbanizadas e áreas descobertas são bastante similares, é razoável supor que o operador não represente a variabilidade espacial entre essas classes, sendo isto observado nas Figuras 26a e 26b.

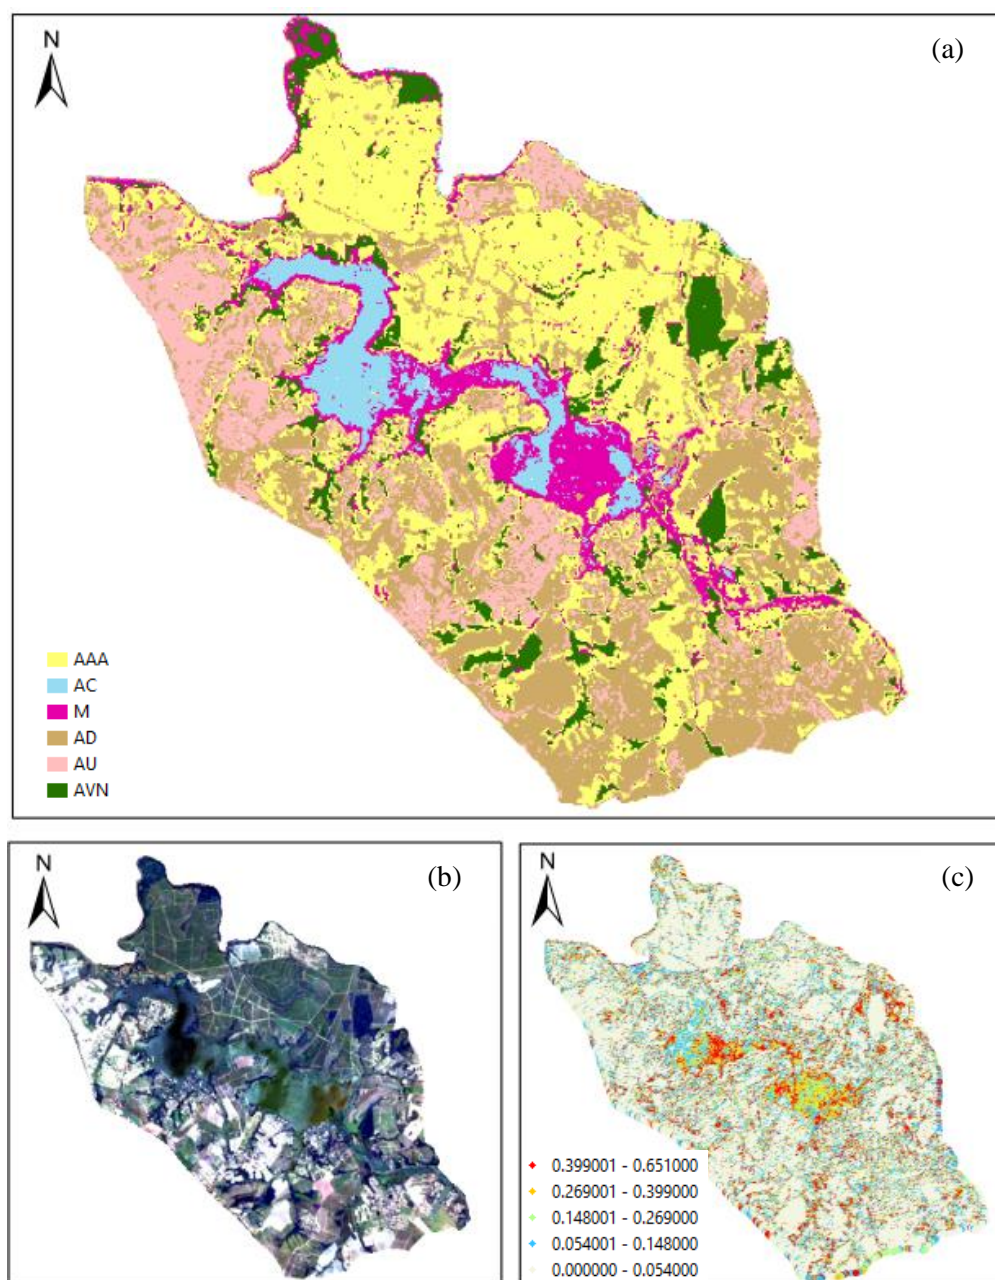
Figura 26 - a) Composição com bandas do visível: OLI4/OLI3/OLI2 da época out/2015; b) Imagem de textura gerada a partir da banda OLI6; c) Imagem de textura gerada a partir da banda OLI5



Fonte: O Autor.

A classificação resultante da aplicação da RNA aos dados de fevereiro de 2016 (Figura 27a) aponta uma área considerável do reservatório classificada como macrófitas. Contudo, ao analisar a Figura 27b verifica-se que a área classificada como macrófitas, não corresponde de fato a essa classe. Trata-se na verdade de variações na cor do espelho d'água, podendo estas estarem relacionadas com correntes de ventos que movimentam o fundo do corpo d'água e aumentam, dessa forma, a quantidade de materiais suspensos. Assim, como observado na classificação de Out/2015, as imagens de textura também podem ter influenciado para a tomada de decisão do classificador.

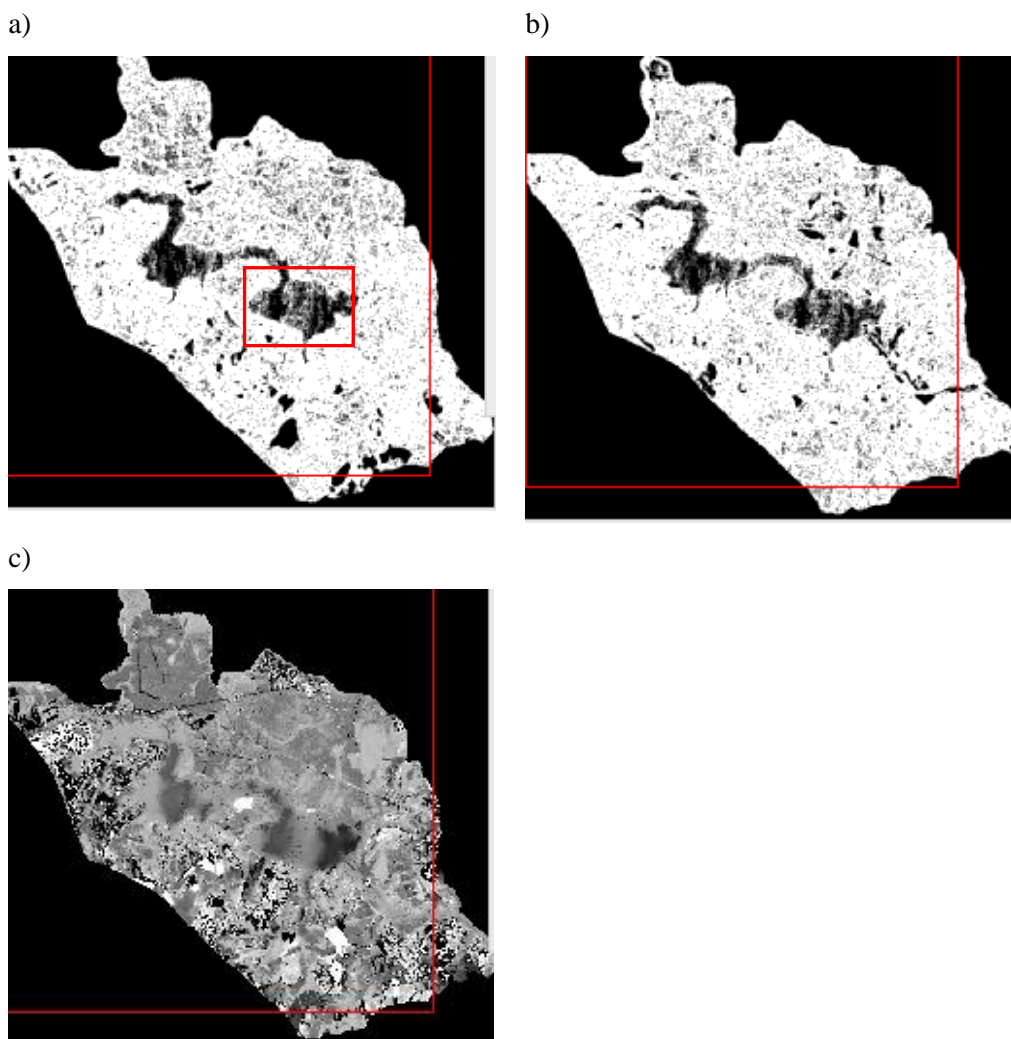
Figura 27 - Classificação resultante da aplicação da RNA à imagem de Fev/2016 (a); Composição colorida (OLI4/OLI3/OLI2) com imagens de Fev/2016 (b); Imagem de incerteza da classificação de Fev/2016 (c). Em que: AAA = áreas antrópicas agrícolas, AC = água continental, M =Macrófitas, AD = áreas descobertas, AU = áreas urbanizadas, AVN = áreas de vegetação natural.



Fonte: O Autor.

Ao analisar a Figura 27c, verifica-se uma expressiva variabilidade espectral no corpo da água, o que é bastante evidenciado nas imagens de textura (Figuras 28a e 28b). Esse comportamento também é evidente na componente matiz gerada a partir das bandas OLI4/OLI3/OLI2 (Figura 28c). A imagem de incerteza também evidencia esse erro na classificação da classe macrófitas (Figura 27c), onde grande parte do reservatório apresenta altos valores de incertezas, variando entre 0,269001-0,651000.

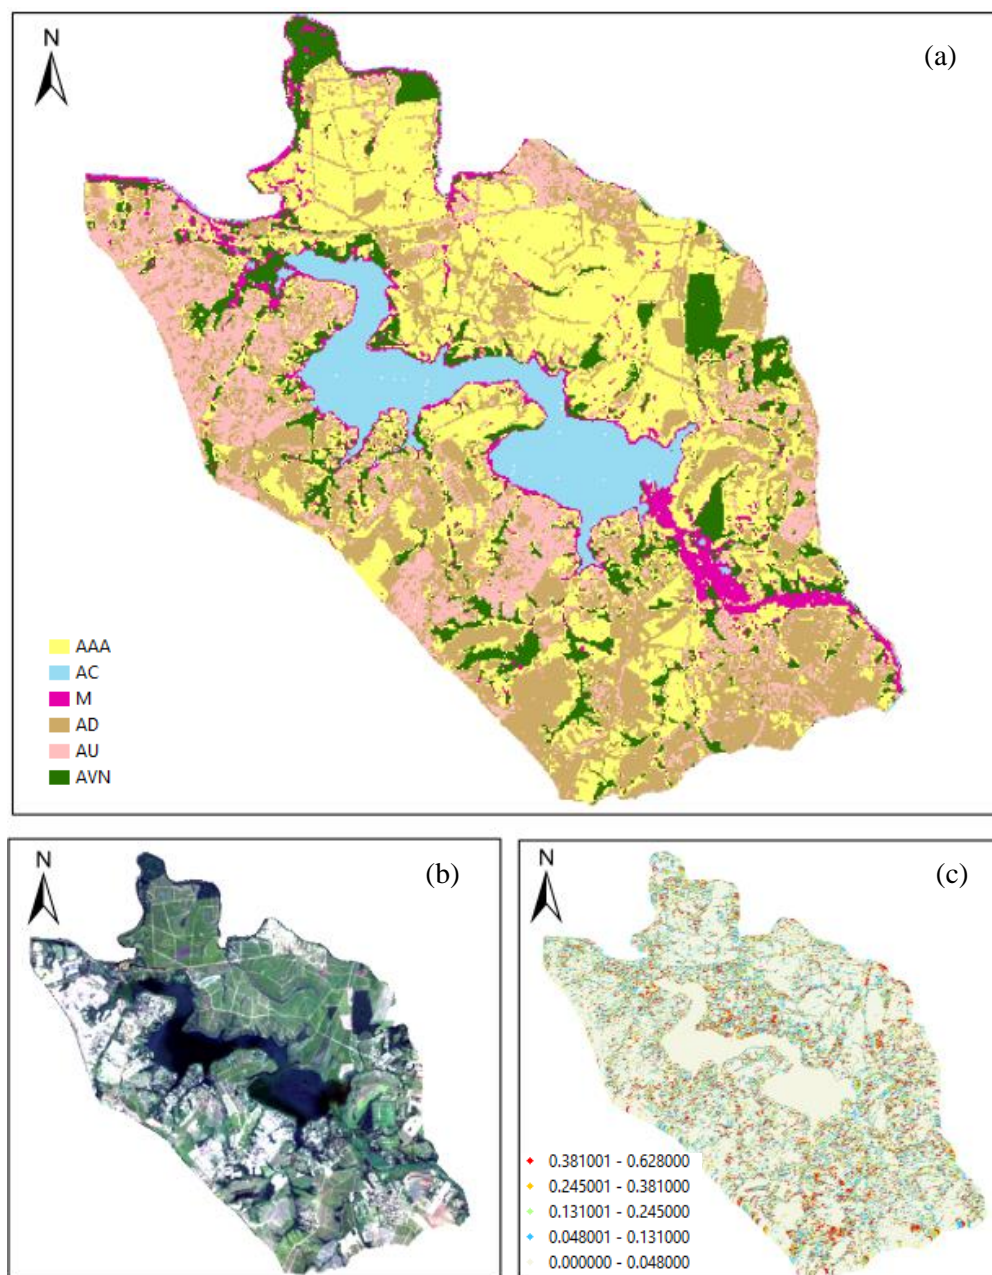
Figura 28 - a) Composição com bandas do visível: OLI4/OLI3/OLI2 da época Fev/2016; b) Imagem de textura gerada a partir da banda OLI6; c) Imagem de textura gerada a partir da banda OLI5; d) imagem matiz geradas a partir das bandas OLI4/OLI3/OLI2.



Fonte: O Autor.

A classificação apresentada na Figura 29a, mostra que a RNA apresentou desempenho satisfatório na discriminação das classes de uso da terra na época Abr/2016. No entanto, é observado a ocorrência de áreas com presença de macrófitas classificadas como áreas de vegetação natural, a jusante do reservatório. Essa área de possível erro é visível na Figura 29c, onde valores de incerteza ocorrem entre 0,245001-0,6280.

Figura 29 - Classificação resultante da aplicação da RNA à imagem de Abr/2016 (a); Composição colorida (OLI4/OLI3/OLI2) com imagens de Abr/2016 (b); Imagem de incerteza da classificação de Abr/2016 (c). Em que: AAA = áreas antrópicas agrícolas, AC = água continental, M =Macrófitas, AD = áreas descobertas, AU = áreas urbanizadas, AVN = áreas de vegetação natural.

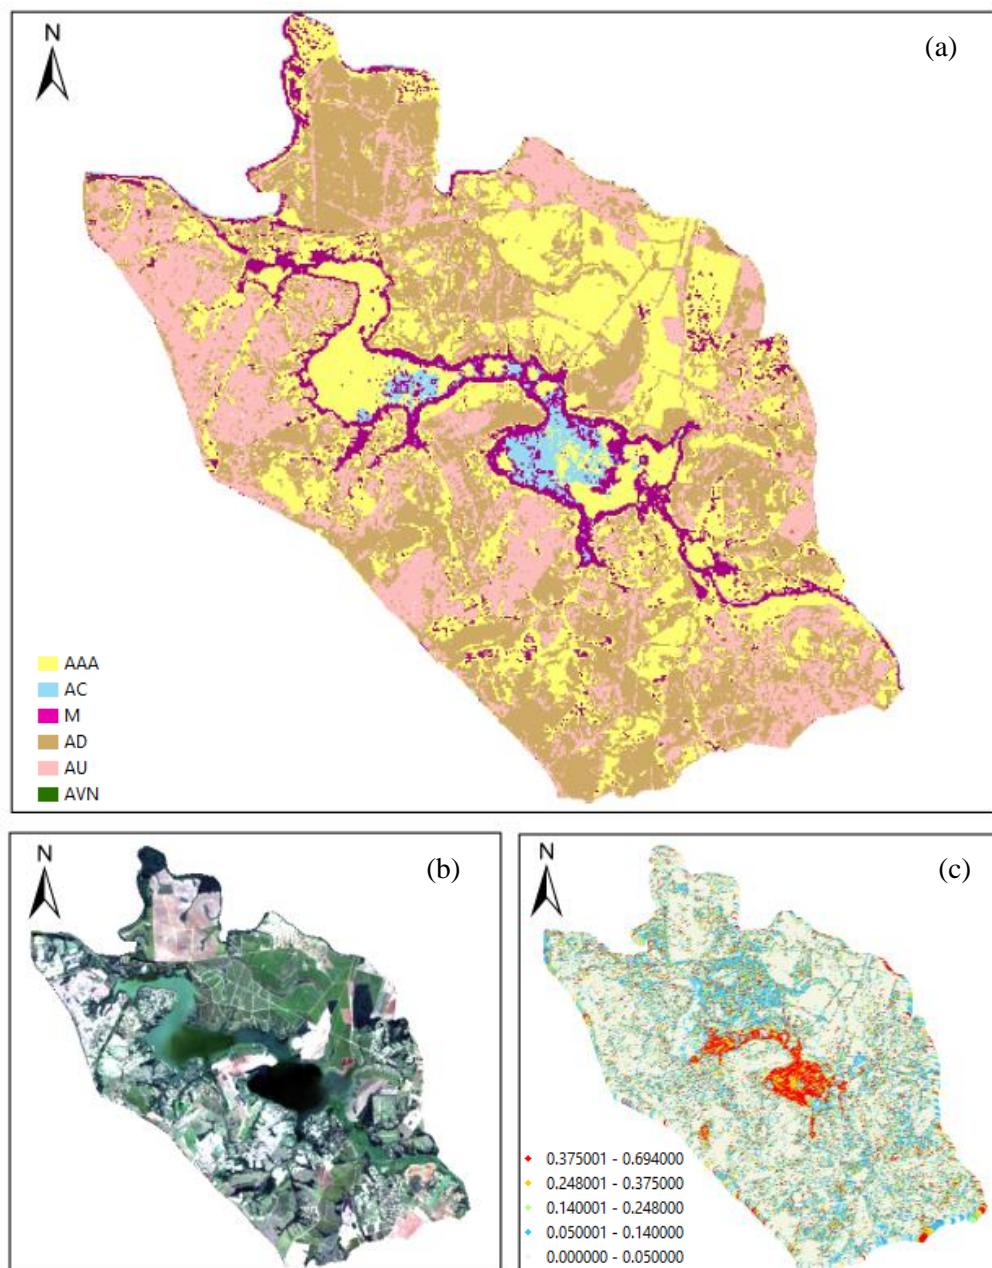


Fonte: O Autor.

De acordo com a Figura 30a, a classificação das cenas de Jul/2016 não apresentou bom desempenho, uma vez que não foram discriminadas todas as classes de saída pré-definidas. Em uma primeira análise, é observado que a classe áreas de vegetação natural não foi discriminada, sendo esta classe associada a áreas agrícolas. No entanto, a RNA conseguiu discriminar

algumas áreas onde ocorrem a presença de macrófitas no reservatório. Acredita-se que o MDE tenha sido determinante para a discriminação da classe macrófitas.

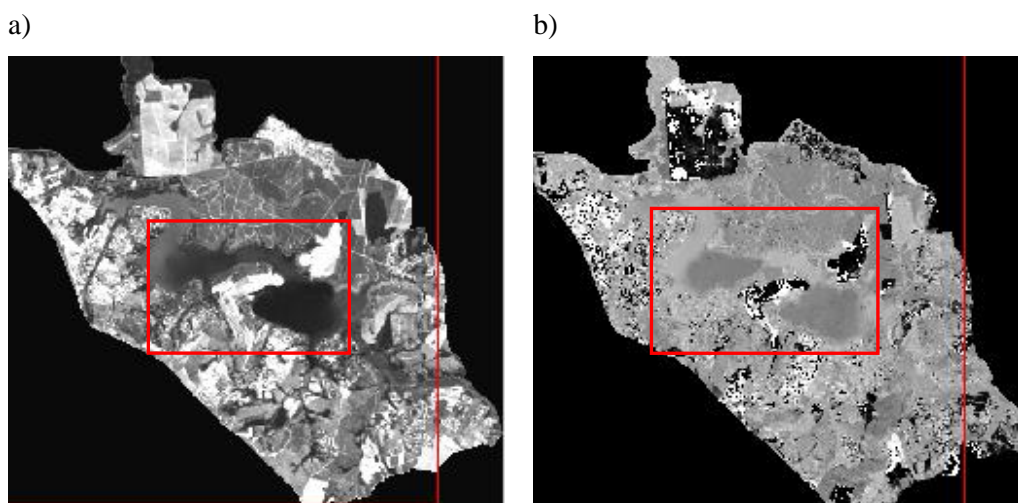
Figura 30 - Classificação resultante da aplicação da RNA à imagem de Jul/2016 (a); Composição colorida (OLI4/OLI3/OLI2) com imagens de Jul/2016 (b); Imagem de incerteza da classificação de Jul/2016 (c). Em que: AAA = áreas antrópicas agrícolas, AC = água continental, M = Macrófitas, AD = áreas descobertas, AU = áreas urbanizadas, AVN = áreas de vegetação natural.



Fonte: O Autor.

O aspecto mais relevante apresentado na imagem de incerteza computada para classificação de Jul/2016 (Figura 30c) é que as áreas que apresentaram maiores valores de incerteza foram as regiões classificadas como água continental. Quando se analisa as imagens de Jul/2016, especificamente a composição colorida com bandas do visível (Figura 30b), observa-se a ocorrência de condições de bruma em regiões do reservatório. Essas regiões podem ser percebidas em duas imagens utilizadas para a classificação, sendo elas a banda do vermelho (Figura 31a) e componente matiz (Figura 31b). Diante disso, presume-se que a ocorrência de bruma, evidente nessas imagens, inviabilizou a classificação do corpo d'água com exatidão.

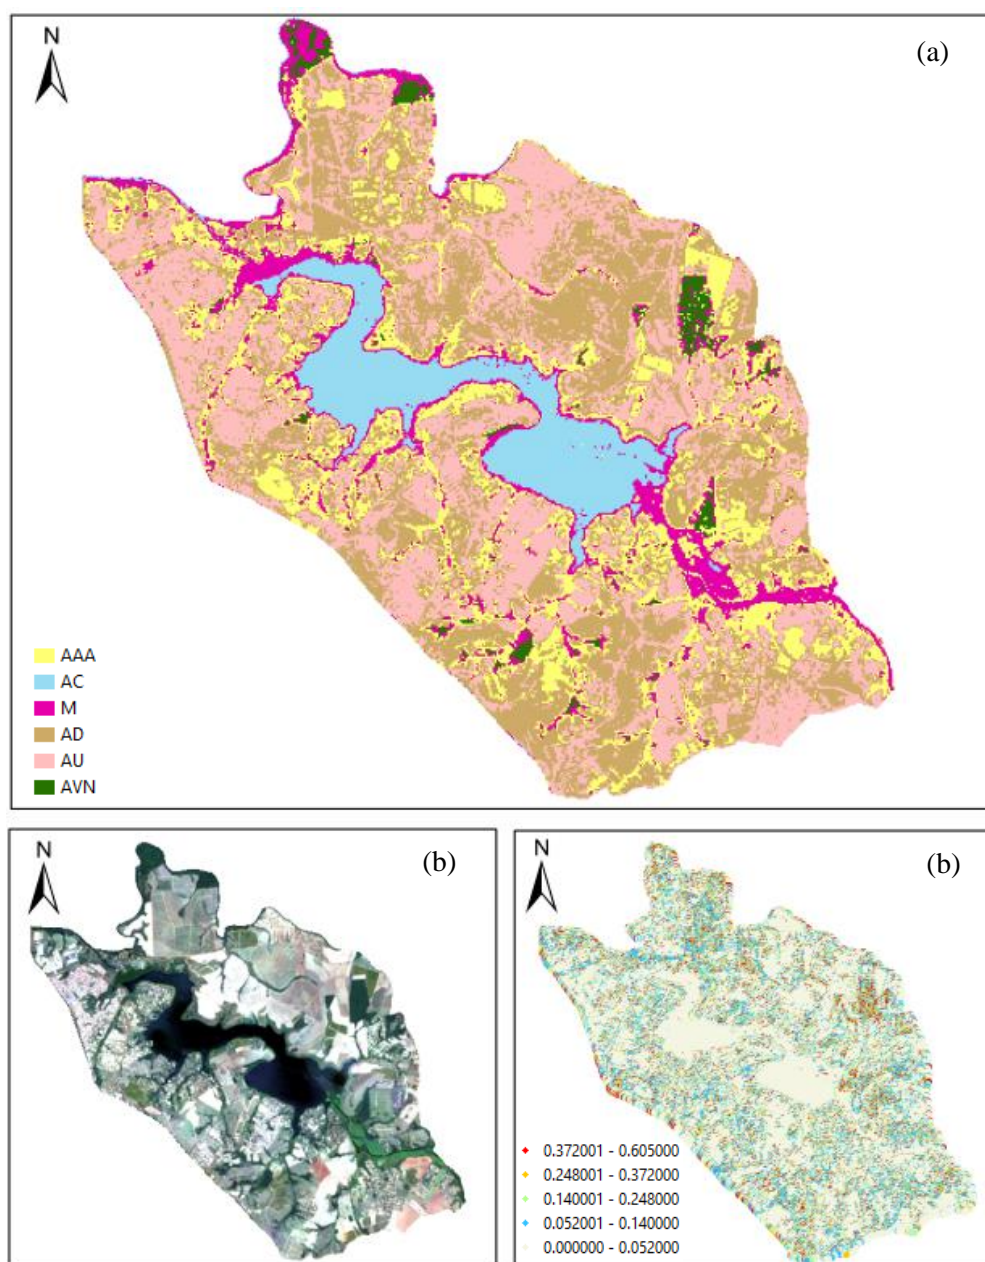
Figura 31 - a) Banda espectral do vermelho (OLI4); c) Componente matiz gerada a partir das bandas OLI4/OLI3/OLI2.



Fonte: O Autor.

A classificação obtida para a época Out/2016 (Figura 32a) apresenta uma boa delimitação do reservatório e discriminação de áreas com presença de macrófitas. Porém, observa-se que algumas áreas de vegetação natural foram classificadas como macrófitas. Além disso, têm-se a área ao entorno do reservatório sendo classificada por áreas representativas de áreas descobertas e áreas urbanizadas. Como estas classes guardam grande similaridade espectral, é esperado uma maior dificuldade de discriminação entre essas classes, o que é confirmado pela imagem de incerteza (Figura 32c).


Figura 32 - Classificação resultante da aplicação da RNA à imagem de Out/2016 (a); Composição colorida (OLI4/OLI3/OLI2) com imagens de Out/2016 (b); Imagem de incerteza da classificação de Out/2016 (c). Em que: AAA = áreas antrópicas agrícolas, AC = água continental, M = Macrófitas, AD = áreas descobertas, AU = áreas urbanizadas, AVN = áreas de vegetação natural.



Fonte: O Autor.

Como mencionado anteriormente, as maiores confusões observadas na classificação de Out/2016 (Figura 32a) ocorreram entre as classes áreas descobertas e áreas urbanizadas. A confusão entre essas duas classes é devido à presença de grandes áreas com solo exposto (Figura 32b). Diante disso, é possível verificar pelas imagens de textura (Figura 33a e 33b) que todo o entorno do reservatório não apresenta variabilidade espectral evidente, sendo esse padrão refletido no resultado da classificação.


Figura 33 - a) Imagem de textura gerada a partir da bandas OLI6; b) Imagem de textura gerada a partir da banda OLI5.



Fonte: O Autor.

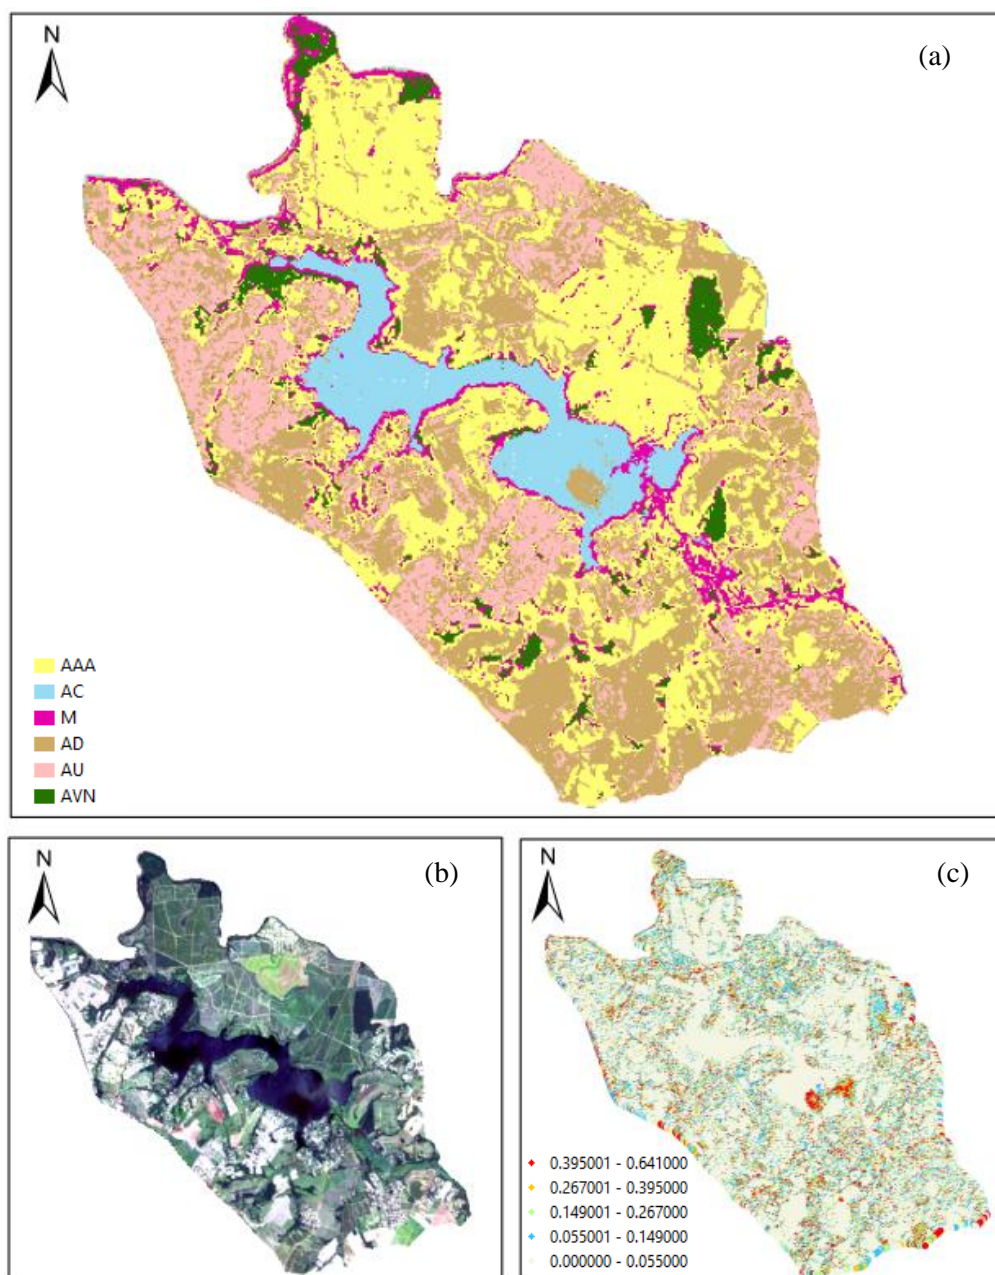
A classificação apresentada na Figura 35a, referente a aplicação da RNA aos dados de Fev/2017, permite identificar confusões ocorridas entre algumas classes, dentre elas macrófitas e áreas de vegetação natural. A razão disso, é que essas classes apresentam características espectrais similares. Um segundo erro que pode ser visualizado na Figura 35a, é a classificação de uma pequena parcela do reservatório como áreas descobertas. Analisando os dados de Fev/2016, constatou-se que na componente matiz (Figura 34) a região classificada como área descoberta apresenta grande variabilidade espectral em relação ao restante do corpo d'água. A partir disso, pode-se dizer que esse atributo viabilizou a associação, errônea, da classe água continental à classe áreas descobertas. No mais, a imagem de incerteza (Figura 35c) indica essa área com valores de incerteza variando entre 0,267001-0,6410.

Figura 34 - Componente matiz gerada a partir das bandas OLI4/OLI3/OLI2.



Fonte: O Autor.

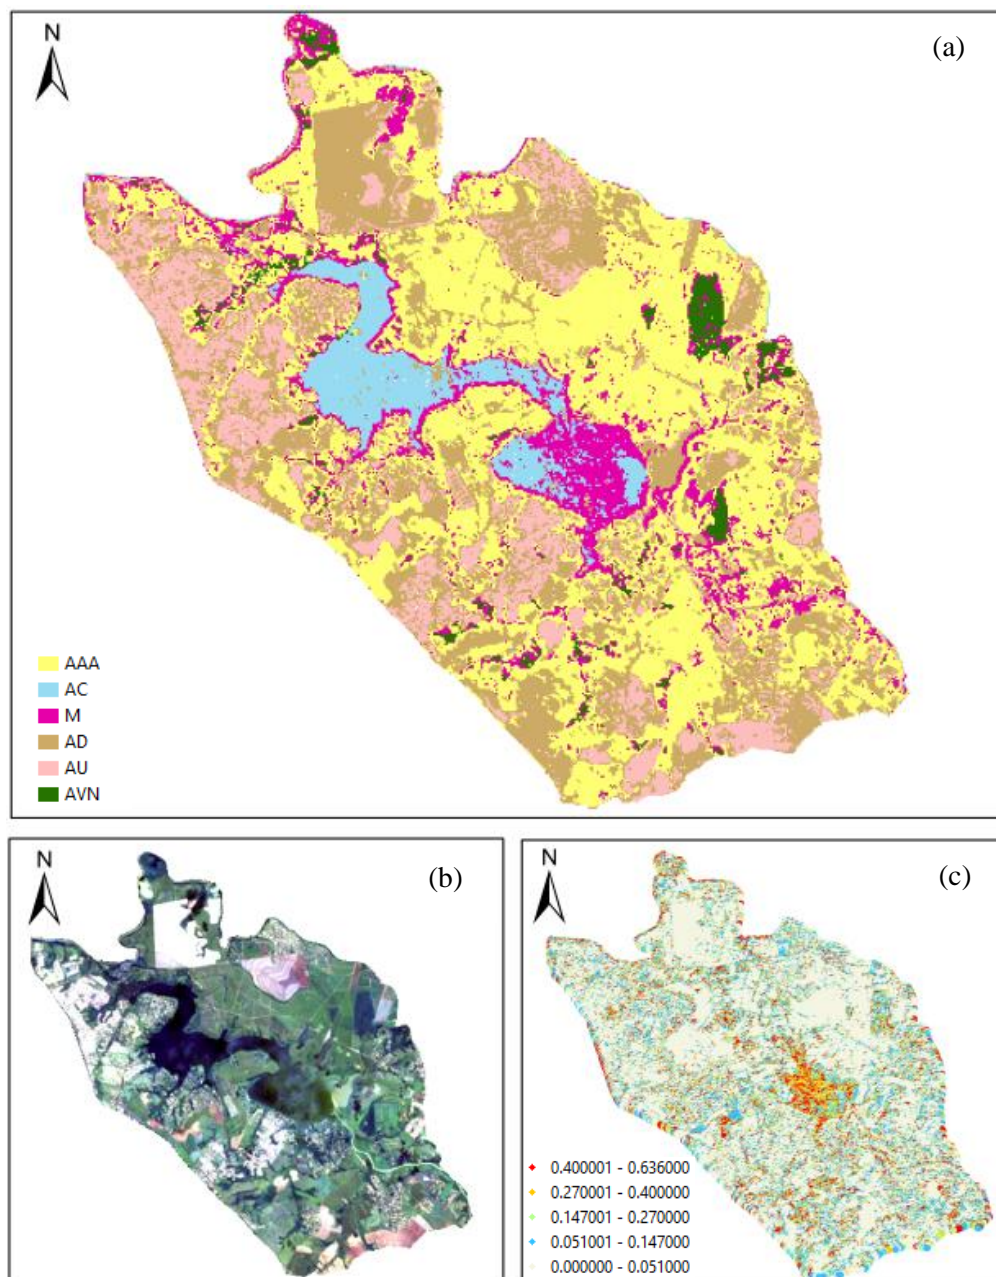
Figura 35 - Classificação resultante da aplicação da RNA à imagem de Fev/2017 (a); Composição colorida (OLI4/OLI3/OLI2) com imagens de Fev/2017 (b); Imagem de incerteza da classificação de Fev/2017 (c). Em que: AAA = áreas antrópicas agrícolas, AC = água continental, M =Macrófitas, AD = áreas descobertas, AU = áreas urbanizadas, AVN = áreas de vegetação natural.



Fonte: O Autor.

A simples observação das Figuras 36a e 36b permite verificar que a classe macrófitas foi superestimada na época Abr/2017. A imagem que expressa a incerteza (Figura 36c), apresenta essa área com altos valores de incerteza, o que implica em uma maior probabilidade de erro na classificação. Outra verificação possibilitada é que na área a jusante do reservatório, as macrófitas foram classificadas como áreas agrícolas.

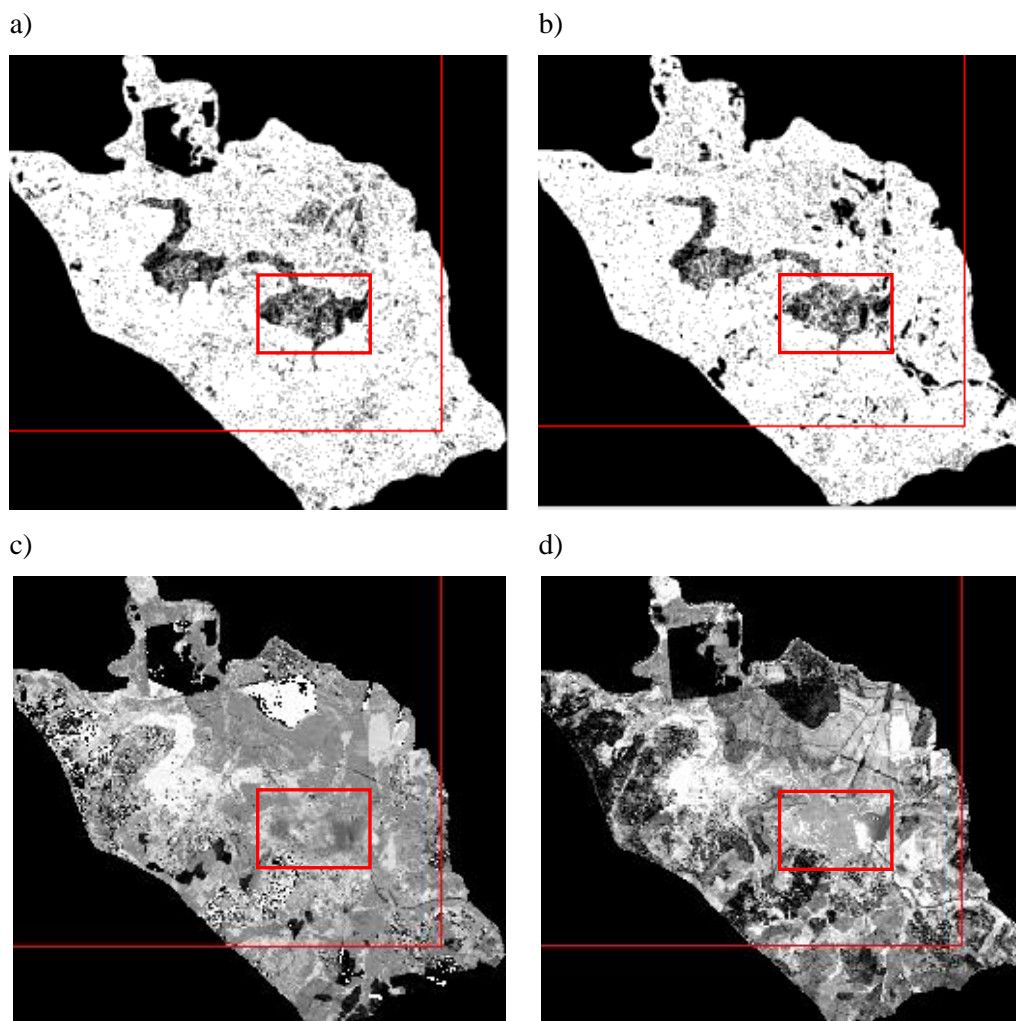
Figura 36 - Classificação resultante da aplicação da RNA à imagem de Abr/2017 (a); Imagem de incerteza da classificação de Abr/2017 (b). Em que: AAA = áreas antrópicas agrícolas, AVN = áreas de vegetação natural, M = Macrófitas, AC = água continental, AD = áreas descobertas, AU = áreas urbanizadas.



Fonte: O Autor.

No que se refere aos dados de Abr/2017, estes revelam grandes variações no espelho d'água, as quais são bem visíveis nas imagens de textura (Figura 37a e 37b) e nas componentes matiz (Figura 37c) e saturação (Figura 37d). Dessa maneira, considerando que quatro dos onze atributos utilizados na classificação destacam essas variações, é evidente a alta probabilidade de erro na tomada de decisão do classificador.

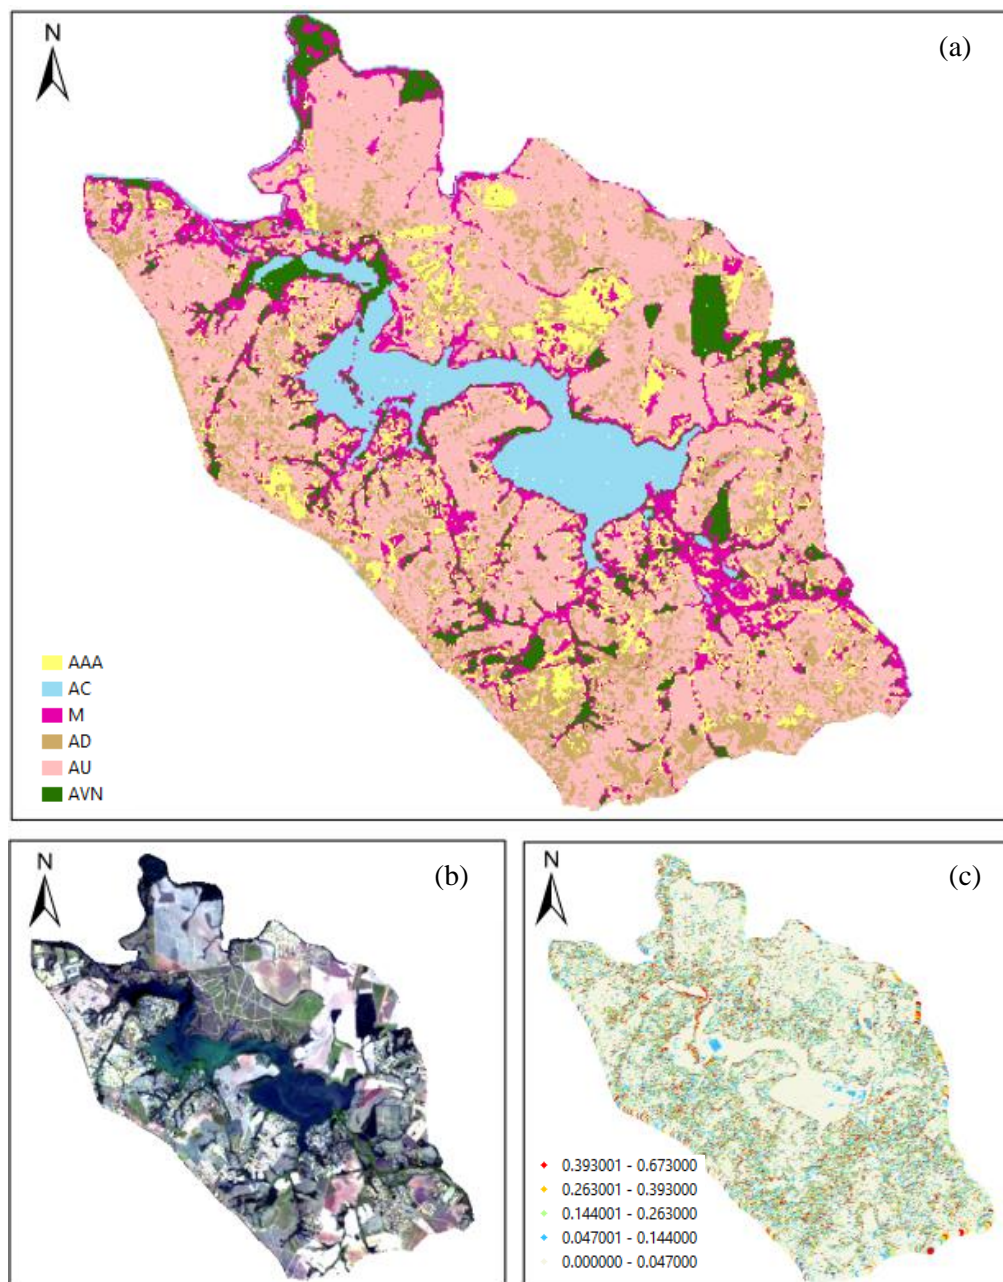
Figura 37 - a) Imagem de textura gerada a partir da bandas OLI6; b) Imagem de textura gerada a partir da banda OLI5, c) Componente matiz gerada a partir das bandas OLI4/OLI3/OLI2; d) Componente saturação gerada a partir das bandas OLI4/OLI3/OLI2.



Fonte: O Autor.


A Figura 38a apresenta a classificação obtida para Ago/2017. Nessa classificação é possível verificar que grande parte da área ao entorno do reservatório foi classificada como área urbanizada, situação semelhante à ocorrida em Out/2016, na qual parte da área de estudo é composta principalmente por áreas descobertas. A imagem de textura obtida a partir da banda OLI6 (Figura 39), representa a baixa variabilidade interna entre as classes áreas descobertas e áreas urbanizadas. Diante disso, classes que apresentam características espectrais similares e, conseqüentemente, baixa variação espectral dificilmente serão representadas adequadamente na classificação resultante.

Figura 38 - Classificação resultante da aplicação da RNA à imagem de Ago/2017 (a); Imagem de incerteza da classificação de Ago/2017 (b). Em que: AAA = áreas antrópicas agrícolas, AVN = áreas de vegetação natural, M = Macrófitas, AC = água continental, AD = áreas descobertas, AU = áreas urbanizadas.



Fonte: O Autor.

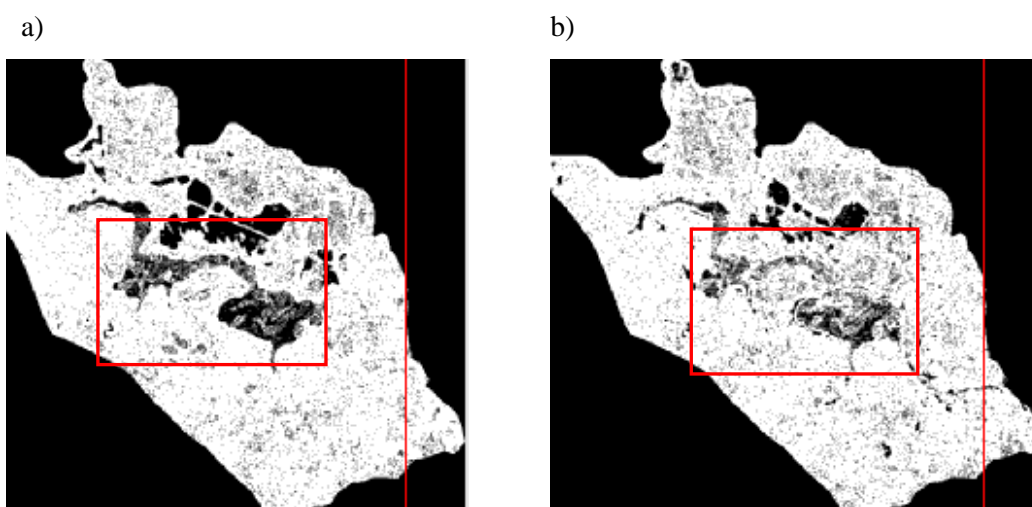
Figura 39 - Imagem de textura obtida a partir da banda OLI6 para a época Ago/2017.



Fonte: O Autor.

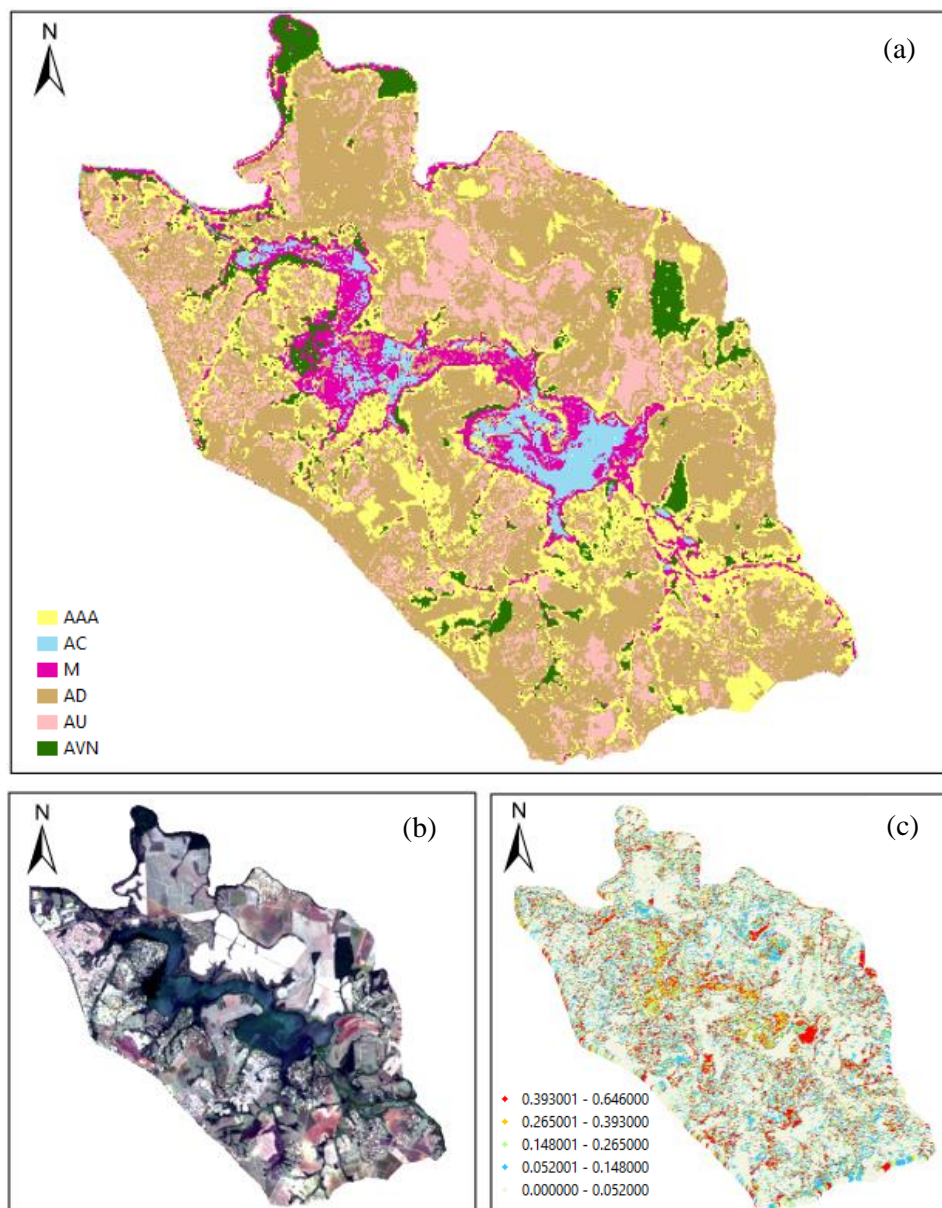
A última época em que foi avaliada a generalização temporal da RNA, foi Out/2017. O resultado da classificação (Figura 41a) permite verificar inconsistências na discriminação das classes macrófitas e áreas descobertas, principalmente. No que concerne à representação da classe macrófitas, as imagens de textura (Figuras 40a e 40b) destacam grande variabilidade espectral no reservatório. A Figura 41c apresenta o reservatório, quase que em sua totalidade, representado por altos valores de incerteza (0,265001 - 0,6460). Diante dessa características, é plausível afirmar que a classe macrófitas foi classificada de forma inconsistente na classificação de Out/2017.

Figura 40 - a) Imagem de textura obtida a partir da banda OLI6; b) Imagem de textura obtida a partir da banda OLI5.



Fonte: O Autor.

Figura 41 - Classificação resultante da aplicação da RNA à imagem de Out/2017 (a); Imagem de incerteza da classificação de Out/2017 (b). Em que: AAA = áreas antrópicas agrícolas, AVN = áreas de vegetação natural, M = Macrófitas, AC = água continental, AD = áreas descobertas, AU = áreas urbanizadas.



Fonte: O Autor.

Sobre os resultados apresentados, observa-se que grandes variações espectrais dos alvos podem refletir diretamente na qualidade da classificação. Nesse estudo, isso é evidente, por exemplo, nas imagens de textura geradas a partir das bandas OLI5 e OLI6, as quais inviabilizaram a discriminação até mesmo do corpo d'água, como observado na classificação de Jul/2016 e Fev/2017. Dessa forma, uma análise minuciosa dos planos de entrada da RNA, associada com imagens de incerteza podem apontar os atributos que tiveram maior contribuição em possíveis erros no processo de classificação.

No que se refere aos resultados obtidos pelo processo de generalização temporal de RNA, pode-se dizer que o potencial de associação dos padrões de treinamento apresentados a rede é reduzido à medida que os dados de entrada da classificação se afastam temporalmente dos dados de treinamento. Contudo, a abordagem de generalização da RNA permitiu verificar que o ambiente de estudo é caracterizado por atividade antrópica intensa, o que explica a ocorrência de grandes áreas ocupadas por macrófitas no reservatório de Salto Grande.

6 CONCLUSÕES E RECOMENDAÇÕES

A RNA treinada com dados de Jun/2015 classificou as imagens de outras épocas, preservando a natureza espectral dos tipos de cobertura, mostrando seu potencial no monitoramento dos tipos de cobertura da terra, principalmente no que se refere à detecção de mudanças. Porém, os resultados mostraram que é importante considerar as variações sazonais intrínsecas e extrínsecas dos alvos, sugerindo a necessidade de realizar o treinamento para épocas específicas do ano, de acordo com a influência sazonal no comportamento do alvo.

Foi verificado o potencial dos planos de entrada para discriminação das classes de uso e ocupação da terra. As bandas espectrais OLI4, OLI5 e OLI6 foram as que apresentaram média dos valores de brilho mais estáveis ao longo do tempo. As imagens de textura provenientes das bandas OLI5 e OLI6, foram utilizadas com a finalidade de analisar a variabilidade interna entre as classes. No entanto, em cenas que houve a predominância de áreas descobertas, as imagens de textura inviabilizaram a discriminação entre essa classe e as áreas urbanizadas. Além disso, é plausível afirmar que as imagens de textura também influenciaram para que o corpo d'água (água continental) fosse classificado de forma inconsistente nas cenas em que o corpo d'água apresentou expressivas variações espectrais, como o verificado nas classificações de Fev/2016, Abr/2017 e Out/2017.

O MDE foi utilizado com a finalidade de minimizar a ambiguidade entre classes que guardam grande similaridade, principalmente a vegetação que ocorre no ambiente aquático e a que ocorre no ambiente terrestre. Essa expectativa é concretizada, uma vez que não foram identificadas áreas consideráveis classificadas como macrófitas fora do contexto do reservatório. Portanto, o procedimento de incorporar o MDE, atributo de natureza não espectral, resultou em uma melhor discriminação das áreas com ocorrência de macrófitas.

Foram realizadas diversas simulações com diferentes arquiteturas de RNA, as quais tiveram por finalidade identificar a configuração de rede mais adequada para classificar imagens sazonais. Dentre as simulações realizadas, a arquitetura [11-17-9-6], Experimento 3, foi selecionada para o treinamento da RNA. Com uma arquitetura composta por 11 atributos de entrada, pôde-se concluir que a medida que se seleciona os atributos com maior capacidade de discriminação entre as classes, melhor é o desempenho da RNA.

Os resultados da generalização temporal da RNA foram considerados adequados, e pode ser utilizado como uma alternativa na análise multitemporal de alvos. No entanto, as cenas de Out/2015, Fev/2016, Jul/2016, Out/2016, Abr/2017, Ago/2017 e Out/2017 foram as que apresentaram os maiores erros de classificação, com destaque para as classes áreas urbanizadas

e áreas descobertas e áreas antrópicas agrícolas. Essas observações deixam claro que a análise de alvos que apresentam notáveis variações sazonais, como áreas agrícolas, pode ser prejudicada. Isso é comprovado quando se observa que o melhor resultado obtido foi com os dados da mesma época em que a rede foi treinada (Jun/2015), ao passo que quando se afastava da época em que o classificador foi treinado os resultados tenderam a ser inferiores.

A informação sobre incerteza, utilizada para análise da classificação, permitiu identificar as áreas com maior probabilidade de erro no processo de tomada de decisão do classificador, sendo esta uma informação útil para representar e identificar padrões espaciais de erros da classificação. Além de ser uma alternativa para se melhorar a qualidade da classificação e, conseqüentemente, gerar um produto de maior confiabilidade.

O tema abordado nesse trabalho é bastante amplo e ainda pouco estudado na literatura, além de apresentar ainda uma série de fatores que ainda devem ser estudados. Além disso, destaca-se a oportunidade de classificar uma série de imagens sem que seja necessário treinar novamente o classificador para cada período em análise. No entanto, é importante mencionar que os dados a serem utilizados no processo de classificação exerce importante papel para o bom desempenho do classificador e, diante disso, é necessário uma análise rigorosa para seleção dos atributos que melhor descrevem as classes de interesse. No mais, observou-se que a classificação generalizada pode ter resultados satisfatórios na análise multitemporal de alvos que não apresentem expressivas variações temporais e espectrais, como por exemplo ambientes aquáticos e áreas agrícolas. Contudo, quando se tem por objetivo a classificação sazonal de ambientes aquáticos, recomenda-se que o corpo d'água seja isolado do seu entorno, uma vez que esse alvo sofre grandes interferências do seu contexto.

Por fim, algumas recomendações para trabalhos futuros podem ser propostas, dentre elas a generalização de RNA com dados multisensores, tendo por finalidade investigar a viabilidade de treinar a RNA com atributos de um sensor com melhor resolução espacial, e posteriormente, aplica-la para classificar cenas de outro sensor. Para isso é necessário recorrer a uma normalização radiométrica entre imagens. A partir disso, pode-se melhorar a identificação das classes de uso e ocupação da terra e assim minimizar a ambigüidade entre alvos espectralmente similares. Uma outra sugestão, é a análise a priori das características do conjunto de imagens sazonais, de modo a conhecer as variações espectrais e temporais dos alvos presentes nas cenas, em especial quando se trata de classificações sazonais de ambiente complexos, como é o caso do ambiente aquático.

REFERÊNCIAS

ADAM, E; MUTANGA, O; RUGEGE, D. Multispectral and hyperspectral remote sensing for identification and mapping of wetland vegetation: a review. **Wetlands Ecology and Management**, v. 18, n. 3, p. 281-296, 2010.

ALAHUHTA, J; KANNINEN, A; VUORI, K. Response of macrophyte communities and status metrics to natural gradients and land use in boreal lakes. **Aquatic Botany**, v. 103, p. 106-114, 2012.

ALI, I.; GREIFENEDER, F.; STAMENKOVIC, J.; NEUMANN, M.; NOTARNICOLA, C. Review of machine learning approaches for biomass and soil moisture retrievals from remote sensing data. **Remote Sensing**, v. 7, n. 12, p. 16398-16421, 2015.

DE ALBAN, J. D. T.; CONNETTE, G. M.; OSWALD, P.; WEBB, E. L. Combined Landsat and L-Band SAR Data Improves Land Cover Classification and Change Detection in Dynamic Tropical Landscapes. **Remote Sensing**, v. 10, n. 2, p. 306, 2018.

ALEXANDER, M.L.; WOODFORD, M.P.; HOTCHKISS, S.C. Freshwater macrophyte communities in lakes of variable landscape position and development in northern Wisconsin, USA. **Aquatic Botany**, v. 88, n. 1, p. 77-86, 2008.

BAKER, C.; LAWRENCE, R.; MONTAGNE, C.; PATTEN, D. Mapping wetlands and riparian areas using Landsat ETM+ imagery and decision-tree-based models. **Wetlands**, v. 26, n. 2, p. 465, 2006.

BARSI, J. A.; LEE, K.; KVARAN, G.; MARKHAM, B. L.; PEDELTY, J. A. The spectral response of the Landsat-8 operational land imager. **Remote Sensing**, v. 6, n. 10, p. 10232-10251, 2014.

BARBOZA, G.C.; FRANCO, R.A.M.; HERNANDEZ, F.B.T. **Ocorrência de Macrófitas Aquáticas no Córrego do Boi**. In: II WORKSHOP INTERNACIONAL DE INOVAÇÕES TECNOLÓGICAS NA IRRIGAÇÃO e I SIMPÓSIO BRASILEIRO SOBRE O USO MÚLTIPLO DA ÁGUA, 2008, Fortaleza - CE. Anais. 2008. p. 680 – 686.

BENEDIKTSSON, J. A.; SWAIN, P. H.; ERSOY, O. K. Neural network approaches versus statistical methods in classification of multisource remote sensing data. 1990.

BIRTH, G. S.; MCVEY, G. R. Measuring the Color of Growing Turf with a Reflectance Spectrophotometer 1. **Agronomy Journal**, v. 60, n. 6, p. 640-643, 1968.

CAMPBELL, J.B.; WYNNE, R.H. **Introduction to Remote Sensing**. 4.ed.2011

CHERUVELIL, K. S.; SORANNO, P. A Relationships between lake macrophyte cover and lake and landscape features. **Aquatic Botany**, v. 88, n. 3, p. 219-227, 2008.

CONGALTON, R.G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. CRC press, 2008.

COMBER, A.; FISHER, P.; BRUNSDON, C.; KHMAG, A. Spatial analysis of remote sensing image classification accuracy. **Remote Sensing of Environment**, v. 127, p. 237-246, 2012.

COMPANHIA PAULISTA DE FORÇA E LUZ - CPFL. **Controle de Plantas Aquáticas no Reservatório de Americana**. 2009.

EGERTSON, C.J.; KOPASKA, J.A.; DOWNING, J.A. A century of change in macrophyte abundance and composition in response to agricultural eutrophication. **Hydrobiologia**, v. 524, n. 1, p. 145-156, 2004.

FILIPPI, A.M.; JENSEN, J.R. Fuzzy learning vector quantization for hyperspectral coastal vegetation classification. **Remote Sensing of Environment**, v. 100, n. 4, p. 512-530, 2006.

FLORENZANO, T.G. **Iniciação em sensoriamento remoto**. 2007.

FONSECA, M.F. **Análise territorial do entorno do reservatório de Salto Grande (SP) com o uso de geoprocessamento: contribuições para usos múltiplos da água**. 2013. 300 p. 2013. Tese (Doutorado), Campinas.

FRANK, E.; HALL, M.A.; WITTEN, I.H. **The WEKA Workbench: Online Appendix for "Data Mining: Practical Machine Learning Tools and Techniques**. 4.ed. Morgan Kaufmann, 2016. p.128.

GALO, M.L.B.T. **Caracterização ambiental do Parque Estadual Morro do Diabo através de dados e técnicas de sensoriamento remoto: abordagens usando redes neurais artificiais**. 2000. 205 p. 2000. Tese (Doutorado), São Carlos.

GAO, B. NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. **Remote sensing of environment**, v. 58, n. 3, p. 257-266, 1996.

GIRI, C.P. **Remote sensing of land use and land cover: Principles and Application**, 2012.

GONZALEZ, R.C; WOODS, R.E. **Processamento Digital de Imagens**. 3.ed. 2010

HWANG, S. J.; LEE, S. W.; SON, J. Y.; PARK, G. A.; KIM, S. J. Moderating effects of the geometry of reservoirs on the relation between urban land use and water quality. **Landscape and Urban Planning**, v. 82, n. 4, p. 175-183, 2007.

IBGE. **Manual técnico de uso da terra**. IBGE, 2013.

JENSEN, J.R. **Remote sensing of the environment: An earth resource perspective 2/e**. Pearson Education India, 2000.

JET PROPULSION LABORATORY. **Advanced Spaceborne Thermal Emission and Reflection Radiometer (ASTER)**. Disponível em: <https://asterweb.jpl.nasa.gov/index.asp>. Acesso em: Junho de 2018.

LARY, D. J.; ALAVI, A. H.; GANDOMI, A. H.; WALKER, A. L. Machine learning in geosciences and remote sensing. **Geoscience Frontiers**, v. 7, n. 1, p. 3-10, 2016.

LILLESAND, T; KIEFER, R.W.; CHIPMAN, J. **Remote sensing and image interpretation**. John Wiley & Sons, 2014.

LUO, J.; XINCHUAN, L.; RONGHUA, M.; LI, F.; DUAN, H.; HU, W.; QIN, B.; HUANG, W. Applying remote sensing techniques to monitoring seasonal and interannual changes of aquatic vegetation in Taihu Lake, China. **Ecological Indicators**, v. 60, p. 503-513, 2016.

MARTINS, J.E. Caracterização da comunidade de plantas aquáticas de dezoito reservatórios pertencentes a cinco bacias hidrográficas do estado de São Paulo. **Revista Planta Daninha**, v.26, n. 1, p. 17 – 32, 2008.

MIKULYUK, A.; SHARMA, S. EGEREN, S.V.; ERDMANN, E.; NAUL, M.E.; HAUXWELL, J. The relative role of environmental, spatial, and land-use patterns in explaining aquatic macrophyte community composition. **Canadian Journal of Fisheries and Aquatic Sciences**, v. 68, n. 10, p. 1778-1789, 2011.

MINAEI, M; KAINZ, W. Watershed land cover/land use mapping using remote sensing and data mining in Gorganrood, Iran. **ISPRS International Journal of Geo-Information**, v. 5, n. 5, p. 57, 2016.

NOVO, E.M.L. de M. **Sensoriamento Remoto: Princípios e Aplicações**. 4.ed. São Paulo: Blucher, 2002. p.387.

PALMER, S. C. J.; KUTSER, T.; HUNTER, P. D. Remote sensing of inland waters: Challenges, progress and future directions. **Remote Sensing of Environment**, v. 157, p. 1–8, 2015.

PAOLA, J. D.; SCHOWENGERDT, R. A. A review and analysis of backpropagation neural networks for classification of remotely-sensed multi-spectral imagery. **International Journal of Remote Sensing**, v. 16, n. 16, p. 3033-3058, 1995.

PRADO, R.B. **Geotecnologias aplicadas à análise espaço-temporal do uso e cobertura da terra e qualidade da água do reservatório de Barra Bonita, SP, como suporte à gestão de recursos hídricos**. 2004. 197 p. 2004. Tese (Doutorado), São Carlos.

RICHARDS, J.; JIA, X. **Remote Sensing Digital Image Analysis**. 2006.

RODRIGUEZ-GALIANO, V.; CHICA-OLMO, M. Land cover change analysis of a Mediterranean area in Spain using different sources of data: Multi-seasonal Landsat images, land surface temperature, digital terrain models and texture. **Applied Geography**, v. 35, n. 1-2, p. 208-218, 2012.

ROUSE, J. H. Monitoring Vegetation Systems in the Great Plains with ERTS. In: **Proceedings, Third Earth Resources Technology Satellite-1 Symposium, Greenbelt, 1974**. 1974. p. 3010-3017.

SAMARASINGHE, S. **Neural networks for applied sciences and engineering: from fundamentals to complex pattern recognition**. Auerbach publications, 2016.

SONG, X; DUAN, Z; JIANG, X. Comparison of artificial neural networks and support vector machine classifiers for land cover classification in Northern China using a SPOT-5 HRG image. **International Journal of Remote Sensing**, v. 33, n. 10, p. 3301-3320, 2012.

- STRATOULIAS, D.; BALZTER, H.; ZLINSZKY, A.; TÓTH, V. R.. A comparison of airborne hyperspectral-based classifications of emergent wetland vegetation at Lake Balaton, Hungary. **International Journal of Remote Sensing**, p. 1-27, 2018.
- TAGHIZADEH-MEHRJARDI, R.; NABIOLLAHI, K.; MINASNY, B.; TRIANTAFILIS, J. Comparing data mining classifiers to predict spatial distribution of USDA-family soil groups in Baneh region, Iran. **Geoderma**, v. 253, p. 67-77, 2015.
- TRAN, D.X.; FILIBERTO, P.; LATORRE-CARMONA, P.; MYINT, S.W.; CAETANO, M.; KIEU, H.V. Characterizing the relationship between land use land cover change and land surface temperature. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 124, p. 119-132, 2017.
- TUIA, D; PASOLLI, E.; EMERY, W J. Using active learning to adapt remote sensing image classifiers. **Remote Sensing of Environment**, v. 115, n. 9, p. 2232-2242, 2011.
- United States Geological Survey (USGS). **Landsat 8 Surface Reflectance Code (LASRC) Product**. v.4.2.2017. p.39.
- VALTA-HULKKONEN, K.; PELLIKKA, P.; TANSKANEN, H.; USTINOV, A.; SANDMAN, O. Digital false colour aerial photographs for discrimination of aquatic macrophyte species. **Aquatic Botany**, v. 75, n. 1, p. 71-88, 2003.
- VERMOTE, E.; JUSTICE, C.; CLAVERIE, M.; FRANCH, B. Preliminary analysis of the performance of the Landsat 8/OLI land surface reflectance product. **Remote Sensing of Environment**, v. 185, p. 46-56, 2016.
- VILLA, P.; PINARDI, M.; TÓTH, V. R.; HUNTER, P. D.; BOLPAGNI, R.; BRESCIANI, M. Remote sensing of macrophyte morphological traits: Implications for the management of shallow lakes. **Journal of Limnology**, v. 76, n. s1, 2017.
- WITTEN, I. H.; FRANK, E. *Data Mining: Practical Machine Learning Tools and Techniques*. 2005.
- XU, H. Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery. **International Journal of Remote Sensing**, v. 27, n. 14, p. 3025-3033, 2006.
- ZHA, Y; GAO, J; NI, S. Use of normalized difference built-up index in automatically mapping urban areas from TM imagery. **International Journal of Remote Sensing**, v. 24, n. 3, p. 583-594, 2003.
- ZHANG, C; XIE, Z. Combining object-based texture measures with a neural network for vegetation mapping in the Everglades from hyperspectral imagery. **Remote Sensing of Environment**, v. 124, p. 310-320, 2012.