



**UNIVERSIDADE DA INTEGRAÇÃO INTERNACIONAL DA LUSOFONIA AFRO-BRASILEIRA
INSTITUTO DE ENGENHARIAS E DESENVOLVIMENTO SUSTENTÁVEL
CURSO DE ENGENHARIA DE ENERGIAS**

JAIRO LIMA DO NASCIMENTO

**PROCESSAMENTO E CLASSIFICAÇÃO DE IMAGENS DE SATÉLITE DO
SEMIÁRIDO CEARENSE UTILIZANDO CLASSIFICADORES ESTATÍSTICOS**

ACARAPE - CE

2016

JAIRO LIMA DO NASCIMENTO

**PROCESSAMENTO E CLASSIFICAÇÃO DE IMAGENS DE SATÉLITE DO
SEMIÁRIDO CEARENSE UTILIZANDO CLASSIFICADORES ESTATÍSTICOS**

Monografia apresentada ao curso de Engenharia de Energias do Instituto de Engenharias e Desenvolvimento Sustentável da Universidade da Integração Internacional da Lusofonia Afro-Brasileira, como requisito para obtenção do Título de Bacharel em Engenharia de Energias.

**Orientador: Prof. Dr. João Paulo do Vale
Madeiro**

**Coorientador: Prof. Dr. George Leite
Mamede**

ACARAPE - CE

2016

Universidade da Integração Internacional da Lusofonia Afro- Brasileira
Direção de Sistema Integrado de Bibliotecas da UNILAB (DSIBIUNI)
Biblioteca Setorial Campus Liberdade
Catálogo na fonte

Bibliotecário: Gleydson Rodrigues Santos – CRB-3 / 1219

N193p Nascimento, Jairo Lima do.
Processamento e classificação de imagens de satélite do semiárido cearense utilizando classificadores estatísticos. / Jairo Lima do Nascimento. – Acarape, 2016.

50 f.; 30 cm.

Monografia apresentada do Curso de Engenharia de Energias do Instituto de Engenharia e Desenvolvimento Sustentável (IEDS) da Universidade da Integração Internacional da Lusofonia Afro-brasileira – UNILAB.

Orientador: Prof. Dr. João Paulo do Vale Madeiro.

Inclui figuras, tabelas e referências.

1. Sensoriamento remoto. I. Título.

CDD 526.982

JAIRO LIMA DO NASCIMENTO

**PROCESSAMENTO E CLASSIFICAÇÃO DE IMAGENS DE SATÉLITE DO
SEMIÁRIDO CEARENSE UTILIZANDO CLASSIFICADORES ESTATÍSTICOS**

Monografia apresentada ao curso de Engenharia de Energias do Instituto de Engenharia e Desenvolvimento Sustentável da Universidade da Integração Internacional da Lusofonia Afro-Brasileira, como requisito para obtenção do Título de Bacharel em Engenharia de Energias.

Aprovado em ____/____/____.

BANCA EXAMINADORA

Prof. Dr. João Paulo do Vale Madeiro (Orientador)
Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB)

Prof. Dr. George Leite Mamede (Coorientador)
Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB)

Prof.^a Dra. Rafaella da Silva Nogueira
Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB)

Aos meus pais e
Às minhas avós.

AGRADECIMENTOS

A Deus.

Aos meus pais, Roseli Lima e Francisco Alves, pelo apoio incondicional, dedicação e esforço para me proporcionar sempre o melhor.

Às minhas avós, Rosa e Maria, e à minha tia Cícera também pelo apoio durante toda minha jornada acadêmica até este ponto.

Ao meu irmão Ulisses Lima que, acima de tudo, me proporciona diversas gargalhadas, inclusive em momentos de aflição.

Aos meus demais familiares que sempre me apoiaram e pelos momentos de descontração que sempre me proporcionam.

Aos amigos que fiz na turma de Engenharia de Energias, com os quais passei madrugadas de aprendizado, entre gargalhadas e lágrimas, construindo laços que serão eternos, em especial com Lidiana Sabino, Verônica Dantas, Alysson Christian, Mabrysa Torres, Ana Carla Morais, Marcelo Rodrigues, Pedro Henrique, Francisco Guilherme, Aldemario Morais, Mardônio Rodrigues, Milton Cavalcante, Ivan Bandeira e Matheus Melo.

A meu professor orientador João Paulo do Vale Madeiro, que auxiliou com muita atenção, dedicação e compreensão, não medindo esforços para a realização e conclusão deste trabalho.

A meu professor coorientador George Leite Mamede, por todas as contribuições acerca deste trabalho, sempre com muita atenção e dedicação, e por toda a paciência e conhecimento transmitido durante os anos em que me orientou como aluno de Iniciação Científica.

A todos aqueles que conheci durante o período de graduação e que, de alguma forma, me ajudaram a evoluir, em especial a Marcelo da Silva Chaves Ribeiro, principalmente pelo constante incentivo durante a realização desse trabalho.

Aos meus professores da graduação, pela dedicação e paciência na construção de ensinamentos que se estendem além das fronteiras da universidade.

A Efraim Araújo, pela grande contribuição com parte dos dados para elaboração deste trabalho.

Ao Instituto de Engenharias e Desenvolvimento Sustentável (IEDS), que por meio de sua gestão, auxiliou a todos os estudantes do curso de Engenharia de Energias, do qual faço parte, não medindo esforços para que o curso recebesse conceito de excelência.

E à Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB), a qual me deu a oportunidade de realização do Curso de graduação em Engenharia de Energias, no qual fui um dos alunos pioneiros da instituição.

RESUMO

A aplicação de técnicas de sensoriamento remoto tem sido cada vez mais utilizada em estudos ambientais, possibilitando avaliar os resultados da ação antrópica e prever impactos de tais ações. Tais técnicas são ferramentas de grande importância para estudos como, por exemplo, a análise de uso e ocupação do solo. Nesse estudo, buscou-se aplicar técnicas de processamento digital de imagens de sensoriamento remoto e classificação supervisionada de alvos, baseada em classificadores estatísticos, como ferramenta para a gestão de recursos hídricos e de usos do solo. Foram utilizadas imagens de satélite do sensor óptico Landsat-8, de setembro de 2014, do entorno dos reservatórios Paus Branco, Marengo e Nova Vida, localizados no assentamento 25 de Maio, situado entre os municípios de Madalena, Boa Viagem e Quixeramobim, no estado do Ceará. Inicialmente, foram aplicadas duas técnicas de transformação de intensidade (*ImAdjust* e *Contrast-Stretching*) nas imagens originais, considerando-se cada uma das componentes RGB. Posteriormente, realizou-se um processo de classificação supervisionada a partir de algoritmos classificadores baseados em dois métodos: Mínima Distância Euclidiana e Máxima Verossimilhança. Tanto os métodos de transformação de intensidade como os classificadores foram implementados no ambiente computacional MATLAB. As imagens foram segmentadas em nove diferentes classes de usos do solo e foi, então, avaliada a concordância da classificação com os dados reais através do coeficiente *kappa*. Os resultados demonstraram que a concordância dos produtos das classificações com pré-processamento das imagens foi superior à concordância apresentada quando não é aplicado qualquer pré-processamento. Quanto aos valores máximos de coeficiente *kappa*, não houve distinção significativa entre os métodos de pré-processamento para um mesmo classificador, obtendo-se coeficientes *kappa* globais iguais a 0,53 para o classificador de mínima distância e 0,63 para o classificador de máxima verossimilhança. Analisando-se os resultados de *kappa* por classe para cada método de classificação, observa-se que o classificador de máxima verossimilhança apresenta concordância maior para a classe de maior interesse (água) do que o algoritmo de mínima distância. Aplicando-se os classificadores nas áreas do entorno dos reservatórios estudados, observa-se que o classificador de máxima verossimilhança apresentou resultados mais coerentes com os usos reais observados na área de estudo, com quantidade inferior de confusões na classificação de pixels (elementos de água como sombra de nuvem). Nesta pesquisa, foi possível implementar algoritmos classificadores de imagens para a área de estudo, utilizando diferentes combinações de métodos de pré-processamento de imagens e métodos de classificação. Os

resultados de concordância obtidos podem ser classificados como “bom” e “muito bom”. A partir da aplicação dos classificadores em áreas do entorno dos reservatórios estudados, observa-se que os métodos empregados permitem classificar os diferentes usos do solo na região estudada, mas necessitam de ajustes para aumentar a acurácia em relação a determinadas classes, tais como: vegetação rala, agricultura e vazante.

Palavras-chave: Sensoriamento Remoto. Técnicas de Realce de Imagens. Classificação de Imagens.

ABSTRACT

The development of remote sensing techniques has been hugely applied in environmental studies, allowing the evaluation of anthropic actions and the estimation of impacts of such actions. These techniques are tools of great importance for studies such as analysis of land use and occupation. In the present study, concerning remote sensing images, we apply digital image processing techniques and supervised target classification, based on statistical classifiers, aiming to obtaining a tool for hydric resources and land uses management. The referred methods are implemented over satellite images of the Landsat-8 optical sensor, acquired in September, 2014, around Paus Branco, Marengo and Nova Vida reservoirs, which are located in the May 25 settlement region, between the limits of Madalena, Boa Viagem and Quixeramobim, in the state of Ceará. Initially, two intensity transformation techniques (ImAdjust and Contrast-Stretching) are applied over the original images, considering each of the RGB components. Subsequently, a supervised classification process is performed considering statistical classifiers based on two methods: Minimum Euclidean Distance and Maximum Likelihood. Both the intensity transformation methods and statistical classifiers are implemented in the Matlab computational environment. The remote sensing images are segmented into nine different land use classes, and the classification agreement with the real data is evaluated through the kappa coefficient. The results emphasize that the agreement levels of the classification algorithms over enhanced images are higher than the agreement levels of the classifications when no preprocessing is applied. Regarding the maximum values of kappa coefficient, there is no significant distinction between the preprocessing methods for the same classifier. The maximum obtained global kappa coefficient is equal to 0.53 for the minimum distance classifier and 0.63 for the maximum likelihood classifier. By analyzing the individual kappa results for each class for each classification method, it is observed that the maximum likelihood classifier presents higher agreement for the main interest class (water) than the minimum distance algorithm. By applying the classifiers in the areas surrounding the studied reservoirs, it is observed that the maximum likelihood classifier provide results more coherent with the real uses in the studied area, with lower number of confusions for classified pixels (water elements as cloud shadow). Through this research, we successfully implement image classifying algorithms for the studied area, using different combinations of image preprocessing methods and classification techniques. The obtained concordance results are classified as "good" and "very good", according to literature reporting. From the application of the classifiers in areas around the studied reservoirs, we conclude that the employed

methods allow classifying the different land uses, although they need adjustments and improvements for increasing the accuracy concerning important classes, such as shallow vegetation, agriculture and ebb.

Keywords: Remote Sensing. Image Enhance Techniques. Classification.

LISTA DE FIGURAS

Figura 1 - Esquema representativo dos quatro elementos fundamentais das técnicas de sensoriamento remoto.....	16
Figura 2 - Espectro Eletromagnético.....	19
Figura 3 - Representação de uma imagem digital.....	20
Figura 4 - Localização do assentamento 25 de Maio no estado do Ceará.....	23
Figura 5 - Comportamento da função <i>Contrast-Stretching</i> ($E = 8$).....	25
Figura 6 - Formas de mapeamento disponíveis na função <i>ImAdjust</i>	26
Figura 7 - Resposta da transformação de potência para diferentes valores da constante γ ($c = 1$).....	27
Figura 8 - Classificador de mínima distância.....	29
Figura 9 - Valores de <i>kappa</i> em função de <i>gamma</i> para classificadores de mínima distância e máxima verossimilhança.....	33
Figura 10 - Gráfico dos valores de <i>kappa</i> em função de <i>gamma</i> para classificadores de mínima distância.....	34
Figura 11 - Valores de <i>kappa</i> em função de E para classificadores de mínima distância e máxima verossimilhança.....	35
Figura 12 - Variação de <i>kappa</i> por classe e por método de pré-processamento para o classificador de mínima distância – <i>ImAdjust</i> com <i>gamma</i> = 3,5 e <i>Contrast Stretching</i> com E = 0,1.....	36
Figura 13 - Variação de <i>kappa</i> por classe e por método de pré-processamento para o classificador de máxima verossimilhança – <i>ImAdjust</i> com <i>gamma</i> = 0,9 e <i>Contrast Stretching</i> com E = 2,3.....	37
Figura 14 - Classificação do entorno do reservatório Paus Branco – resultados de todas as combinações.....	40
Figura 15 - Classificação do entorno do reservatório Marengo – resultados de todas as combinações.....	42
Figura 16 - Classificação do entorno do reservatório Nova Vida – resultados de todas as combinações.....	44

LISTA DE TABELAS

Tabela 1 - Bandas do Landsat-8	17
Tabela 2 - Características físicas dos reservatórios no assentamento 25 de maio.....	24
Tabela 3 - Coeficiente κ e desempenho de classificação	31
Tabela 4 - Valores de κ e parâmetros de controle (E e γ) para combinações de métodos de realce e classificadores.....	32
Tabela 5 - Cores utilizadas na classificação do entorno dos reservatórios.....	38
Tabela 6 - Quantificação de áreas das classes (%) por combinação de método de realce e classificador – açude Paus Branco	41
Tabela 7 - Quantificação de áreas das classes (%) por combinação de método de realce e classificador – açude Marengo	43
Tabela 8 - Quantificação de áreas das classes (%) por combinação de método de realce e classificador – açude Nova Vida	45

SUMÁRIO

1 INTRODUÇÃO	13
2 OBJETIVOS	15
2.1 Objetivo geral	15
2.2 Objetivos específicos	15
3. FUNDAMENTAÇÃO TEÓRICA	16
3.1 Sensoriamento Remoto	16
3.1.1 Sensor óptico Landsat-8	17
3.2 Processamento digital de imagens	18
3.2.1 Transformações de intensidade em imagens	21
3.2.2 Classificação de imagens.....	21
4 MATERIAL E MÉTODOS	23
4.1 Caracterização da área de estudo	23
4.2 Realce de imagens	24
4.2.1 Transformação por <i>contrast-stretching</i>	25
4.2.2 Função <i>ImAdjust</i> – MATLAB	26
4.3 Classificação de alvos em imagens	27
4.3.1 Classificador de Mínima Distância	28
4.3.2 Classificador de Máxima Verossimilhança	29
4.3.3 Análise de concordância – Matriz de confusão e κ (<i>kappa</i>).....	30
5 RESULTADOS E DISCUSSÃO	32
5.1 Análise de concordância global	33
5.2 Análise de concordância local	36
5.3 Classificação do entorno dos reservatórios	38
6 CONCLUSÕES	46
REFERÊNCIAS	47

1 INTRODUÇÃO

O mapeamento do uso da terra é uma importante análise para o planejamento ambiental devido à possibilidade de espacializar e quantificar os diferentes tipos de usos do solo. Os conhecimentos da distribuição dos tipos de cobertura do solo e suas variações são hoje um aspecto indispensável para o planejamento de uma política coerente e eficiente de desenvolvimento sustentável, assim como para a compreensão e avaliação objetiva da convivência de diferentes ecossistemas (GIBBS *et al.*, 2007).

Técnicas de sensoriamento remoto possuem potencial para serem utilizadas na obtenção de informações através de dados de satélites, tornando possível identificar e mapear diversos tipos de uso do solo. É necessário reconhecer os padrões de resposta espectral baseando-se na extração de informações das imagens orbitais. A classificação de objetos ou fenômenos é uma ferramenta eficaz, onde há a escolha das características que as descrevem para que ocorra a diferenciação das mesmas (ARAÚJO, 2015).

O Nordeste brasileiro é caracterizado por uma região semiárida. A alta variabilidade sazonal e interanual da precipitação, alto risco de seca e baixa disponibilidade de água causam uma elevada vulnerabilidade aos habitantes e ecossistemas nesta região (CREUTZFELDT, 2006).

O Ceará está inserido no semiárido nordestino, possuindo características próprias da região sob os aspectos hidroclimáticos, destacando-se o regime de precipitações irregulares, altas taxas de evaporação e rios intermitentes, sendo que o abastecimento hídrico da região depende em grande parte das águas superficiais acumuladas nos reservatórios. No Ceará, 93% da água ofertada aos usuários vem das barragens (ARAÚJO, 2003; MALVEIRA, 2009).

No cenário atual das regiões semiáridas do Nordeste brasileiro, a preocupação com o uso e disponibilidade de água tem se tornado cada vez mais constante, haja vista que tais fatores influem de forma marcante no desenvolvimento dessas regiões. A ocorrência cíclica das secas e seus efeitos catastróficos são bem conhecidos e remontam aos primórdios da história do semiárido brasileiro (AGUIAR, 2004).

Segundo Araújo (2015), após meados do século XX, o sensoriamento remoto (SR) passou a ser integrado fortemente aos estudos geográficos e atualmente apresenta crescente utilização e importância, especialmente no que se refere ao planejamento geográfico (ambiental, rural ou urbano) e ao monitoramento e estudo do meio-ambiente.

Com a aplicação das técnicas de sensoriamento remoto, é possível avaliar as respostas decorrentes de perturbações introduzidas pela atividade humana, de modo a prever o impacto dessas ações sobre suas condições de sustentabilidade em médio e longo prazo (NOVO, 2012 *apud* ARAÚJO, 2015), tornando-se uma ferramenta de grande importância para vários estudos ambientais, como por exemplo a análise de uso e ocupação do solo.

2 OBJETIVOS

2.1 Objetivo geral

O objetivo geral do trabalho proposto é aplicar técnicas de processamento digital de imagens de sensoriamento remoto e classificação supervisionada de alvos, baseada em classificadores estatísticos.

2.2 Objetivos específicos

Enumeram-se os seguintes objetivos específicos:

- a) Analisar diferentes métodos (*Contrast-Stretching* e *ImAdjust*) e parâmetros de transformação de intensidade em imagens para diferenciar alvos no processo de classificação de imagens multiespectrais Landsat 8;
- b) Implementar algoritmos computacionais de classificadores estatísticos de alvos em imagens digitais, analisar e comparar sua eficiência na região de estudo;
- c) Caracterizar os diferentes usos do solo da região estudada por área classificada.

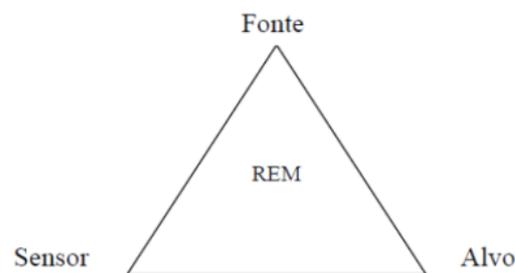
3. FUNDAMENTAÇÃO TEÓRICA

3.1 Sensoriamento Remoto

Sensoriamento remoto é a utilização de sensores para a aquisição de informações sobre objetos e fenômenos sem que haja contato direto entre eles (NOVO, 1998). Os sensores são os equipamentos capazes de coletar energia proveniente do objeto, convertê-la em sinal passível de ser registrado e apresentá-lo de forma adequada para a extração de informações.

Para o sensoriamento remoto, é essencial a existência de uma fonte de energia para iluminar o alvo (exceto no caso em que a energia esteja sendo emitida pelo próprio alvo). Esta energia ocorre na forma de radiação eletromagnética (REM). Na Figura 1 estão identificados os quatro elementos fundamentais para a aplicação das técnicas de sensoriamento remoto (ARAÚJO, 2015).

Figura 1 - Esquema representativo dos quatro elementos fundamentais das técnicas de sensoriamento remoto



Fonte: PONZONI, 2001.

A fonte de REM fundamental para a aplicação das técnicas de sensoriamento remoto no estudo dos recursos naturais é o Sol. Pode ser também a Terra para os sensores passivos de micro-ondas e termais; podem ser antenas de micro-ondas para os sistemas radares. Já o sensor é o instrumento capaz de coletar e registrar a REM refletida ou emitida pelo alvo, e que representa o elemento do qual se pretende extrair informação. A energia irradiada pela superfície aparente do Sol em direção a Terra denomina-se de Fluxo Radiante e o máximo de energia solar disponível na superfície terrestre para fins de sensoriamento remoto encontra-se na faixa de 0,4 μm a 0,7 μm , que é conhecida como a região visível do espectro eletromagnético (ARAÚJO, 2015).

3.1.1 Sensor óptico Landsat-8

A série Landsat surgiu no final dos anos 60 como parte do Programa de Levantamento de Recursos Terrestres da NASA. Por se tratar do programa de satélites de recursos terrestres mais antigo, operando ininterruptamente desde 1972 e disponibilizando imagens gratuitas desde 1973, o programa apresenta um importantíssimo acervo histórico de imagens orbitais. No Brasil, o INPE é a instituição responsável pela manutenção e disponibilização deste acervo (ARAÚJO, 2015).

Em 11 de fevereiro de 2013, foi lançada ao espaço a Missão de Continuidade dos Dados Landsat (LDCM) – chamada de Landsat 8. Esse novo satélite traz várias novidades importantes para usuários que demandam mapeamentos em meso escala, como o Brasil.

A Tabela 1 apresenta o conjunto de bandas disponíveis no Landsat-8, bem como comprimento de onda e a resolução espacial.

Tabela 1 - Bandas do Landsat-8

Bandas	Comprimento de onda (μm)	Resolução (m)
Banda 1 – Coastal aerosol	0,43 – 0,45	30
Banda 2 – Blue	0,45 – 0,51	30
Banda 3 – Green	0,53 – 0,59	30
Banda 4 – Red	0,64 – 0,67	30
Banda 5 – Near Infrared (NIR)	0,85 – 0,88	30
Banda 6 – SWIR 1	1,57 – 1,65	30
Banda 7 – SWIR 2	2,11 – 2,29	30
Banda 8 – Panchromatic	0,50 – 0,68	15
Banda 9 – Cirrus	1,36 – 1,38	30
Banda 10 – Thermal Infrared (TIRS) 1	10,60 – 11,19	100
Banda 11 – Thermal Infrared (TIRS) 2	11,50 – 12,51	100

Fonte: USGS, 2016.

Com dois novos sensores, o sensor espectral OLI e o sensor termal TIRS, os avanços no aumento de resolução espectral são muito positivos. Foram adicionadas duas bandas espectrais: a *new coastal* (banda 1), projetada especificamente para os recursos hídricos e investigação da zona costeira, e um novo canal de infravermelho (banda 9), para a detecção de nuvens. Tais adições provocaram mudanças nos intervalos dentro do espectro dos

canais de todas as bandas. Há também uma nova banda de Garantia de Qualidade (Banda QA), que fornece informações sobre a presença de nuvens, água e neve.

A partir do sensor termal TIRS, foram criadas duas bandas espectrais para o comprimento de onda antes coberto por uma única banda nos sensores TM e ETM (USGS, 2016). Algumas bandas apresentam largura menor no espectro, principalmente as do infravermelho.

3.2 Processamento digital de imagens

O campo do processamento digital de imagens refere-se ao processamento de dados, na forma de imagens digitais, por meio de um computador digital. O processamento digital de imagens abrange processos cujas entradas e saídas são imagens e, além disso, engloba processos que extraem atributos de imagens, incluindo o reconhecimento de objetos individuais (GONZALEZ, WOODS, 2010).

Para Queiroz e Gomes (2001), o processamento digital de imagens consiste de um conjunto de tarefas conectadas. Dentre tais tarefas, destacam-se a captura da imagem, a digitalização ou amostragem, filtragem de ruído, correção de distorções e segmentação.

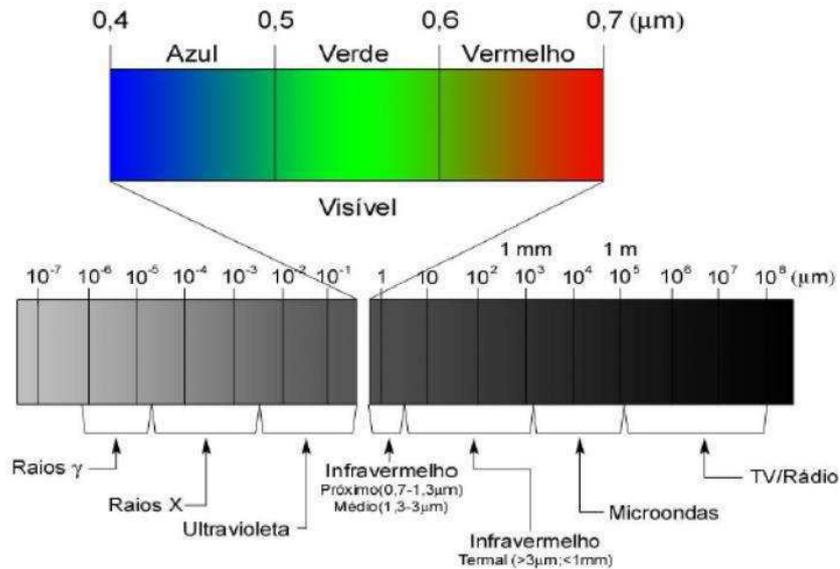
Atualmente, a utilização do processamento digital de imagens impacta a maioria, senão todas as áreas de empreendimentos técnicos. Alguns exemplos são medicina nuclear, observações astronômicas, diagnóstico médico ou industrial por imagens de raio X, litografia, inspeção industrial, microscopia, policiamento, sensoriamento remoto, dentre muitos outros usos (GONZALEZ, WOODS, 2010).

Sendo radiação eletromagnética, a luz apresenta um comportamento ondulatório caracterizado por sua frequência (f) e comprimento de onda (λ). A faixa do espectro eletromagnético à qual o sistema visual humano é sensível se estende aproximadamente de 400 a 770 nm e denomina-se luz visível (ACHARYA; RAY, 2005). A radiação eletromagnética com comprimentos de onda fora desta faixa não é percebida pelo olho humano. No espectro visível, o olho percebe comprimentos de onda diferentes como cores distintas, sendo que fontes de radiação com um único comprimento de onda denominam-se monocromáticas e a cor da radiação denomina-se cor espectral pura (GONZALEZ, WOODS, 2010).

O espectro eletromagnético é formado pelo conjunto de todas as radiações, desde os raios cósmicos e gama, com alta frequência e estreitos comprimentos de ondas, até as ondas de rádio, com baixa frequência e comprimentos de onda mais extensos (Figura 2). O

espectro eletromagnético é a ordenação destas radiações em função do comprimento de onda e da frequência (MOREIRA, 2007).

Figura 2 - Espectro Eletromagnético



Fonte: INPE, 2011 *apud* ARAÚJO, 2015.

Objetos que emitem luz visível são percebidos em função da soma das cores espectrais emitidas. Tal processo de formação é denominado aditivo. O processo aditivo pode ser interpretado como uma combinação variável em proporção de componentes monocromáticas nas faixas espectrais associadas às sensações de cor verde, vermelho e azul, as quais são responsáveis pela formação de todas as demais sensações de cores registradas pelo olho humano. Assim, as cores verde, vermelho e azul são ditas cores primárias. Este processo de geração suscitou a concepção de um modelo cromático denominado RGB (*Red, Green and Blue*) (QUEIROZ; GOMES, 2001).

Uma imagem pode ser definida como uma função bidimensional, $f(x,y)$, na qual x e y são coordenadas espaciais (planas), e a amplitude de f em qualquer par de coordenadas (x , y) é chamado de intensidade ou nível de cinza da imagem naquele ponto. Quando os valores de x , y e da amplitude f são todos finitos e quantidades discretas, denomina-se a imagem de imagem digital. O campo do processamento digital de imagens refere-se ao processamento de imagens digitais por meio de um computador (GONZALEZ; WOODS, 2010).

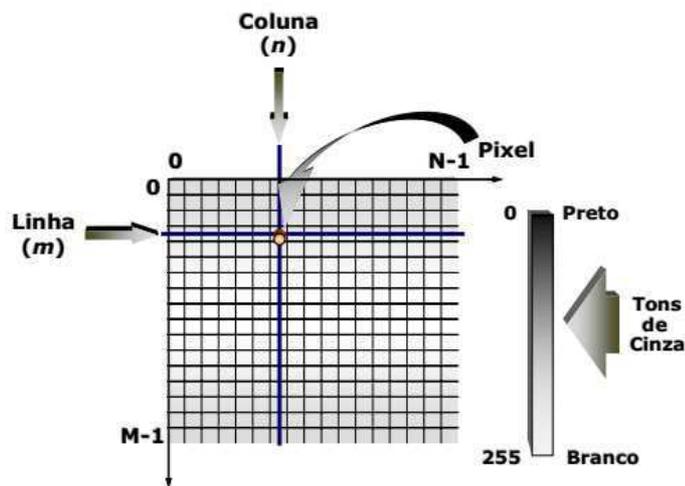
Cada ponto da grade bidimensional que representa a imagem digital é chamado de elemento de imagem ou pixel. A Figura 3 apresenta a notação utilizada usualmente para localização de pixels em um arranjo de imagem bidimensional.

A função $f(x,y)$ pode ser caracterizada por dois componentes: (1) a quantidade de iluminação da fonte que incide na cena que está sendo vista ou iluminação, representada por $i(x,y)$; e (2) a proporção do fluxo de radiação eletromagnética refletida pelos objetos da cena ou refletância, denotada por $r(x,y)$ (GONZALEZ, WOODS, 2010; QUEIROZ; GOMES, 2001). O produto dessas funções (Equação 1) forma a função que denota a imagem digital

$$f(x, y) = i(x, y) \cdot r(x, y) \quad (1)$$

na qual $0 < i(x,y) < \infty$ e $0 < r(x,y) < 1$, sendo $i(x,y)$ dependente das características da fonte de iluminação, enquanto $r(x,y)$ dependente das características das superfícies dos objetos.

Figura 3 - Representação de uma imagem digital



Fonte: QUEIROZ; GOMES, 2001.

Considerando-se uma imagem digital colorida no sistema RGB, um pixel pode ser interpretado como um vetor com componentes monocromáticas de vermelho, verde e azul de sua cor. A imagem colorida pode ser vista como a composição de três imagens monocromáticas (Equação 2):

$$f(x, y) = f_R(x, y) + f_G(x, y) + f_B(x, y), \quad (2)$$

em que $f_R(x,y)$, $f_G(x,y)$ e $f_B(x,y)$ representam as intensidades (ou níveis de cinza) das componentes vermelha, verde e azul, respectivamente, no ponto (x,y) .

3.2.1 Transformações de intensidade em imagens

Podem ser realizados testes computacionais aplicando-se diferentes métodos de realce de contraste nas imagens de satélite da área de estudo. Os métodos de realce no domínio espacial, ou filtragem espacial, manipulam diretamente as intensidades dos pixels constituintes da imagem e são denotados pela Equação 3 (GONZALEZ; WOODS; EDDINS, 2004):

$$g(x,y)=T[f(x,y)] \quad (3)$$

em que $f(x,y)$ é a imagem de entrada, $g(x,y)$ é a imagem processada ou filtrada e T é um operador em f , definido na vizinhança do ponto (x,y) .

A mais simples forma assumida pelo operador T ocorre quando é definida a vizinhança em torno de cada posição (x,y) de tamanho 1×1 pixel, isto é, com um único pixel. Neste caso, o valor da função g em (x,y) depende apenas da intensidade de f naquele ponto, isto é, do nível de cinza do pixel, e T torna-se um operador de transformação de intensidade ou de nível de cinza, considerando-se cada componente monocromática de uma imagem no formato RGB.

3.2.2 Classificação de imagens

Segundo Meneses e Sano (2012), a classificação de imagens digitais consiste em rotular cada pixel da imagem a um número finito de classes individuais representativas dos objetos no mundo real, com base em suas intensidades monocromáticas. Uma vez que o pixel satisfaça determinado conjunto de critérios, normalmente avaliados por medidas estatísticas, o pixel é atribuído a uma classe vencedora, isto é, a classe mais provável, segundo as métricas adotadas. Para tal, são aplicados algoritmos de classificação, também denominados classificadores. Dependendo do algoritmo utilizado no procedimento, a classificação é dita supervisionada ou não-supervisionada, envolvendo duas fases distintas: o treinamento e a classificação propriamente dita (MOREIRA, 2007).

Na classificação não-supervisionada é necessária pouca ou nenhuma interação do analista na classificação da imagem. Esse tipo de classificador é indicado quando o analista não possui, em um primeiro momento, conhecimento da área de estudo. Na fase de treinamento, os classificadores não supervisionados utilizam algoritmos nos quais o reconhecimento de padrões espectrais se faz sem o treinamento tradicional, ou seja, sem a necessidade de fornecer parâmetros espectrais das classes contidas na cena (MENESES; MANO, 2012; MOREIRA, 2007).

Nos classificadores supervisionados é necessário o conhecimento prévio das classes de alvos, a fim de classificar regiões da imagem nas classes de interesse pré-fixadas pelo analista. O reconhecimento dos padrões espectrais na imagem é realizado com base em amostras da área de treinamento, fornecidas ao sistema de classificação pelo analista. Os classificadores supervisionados mais comuns são: Máxima Verossimilhança (*Maxver*), o método do paralelepípedo e a distância euclidiana ou mínima distância (MENESES; MANO, 2012; MOREIRA, 2007).

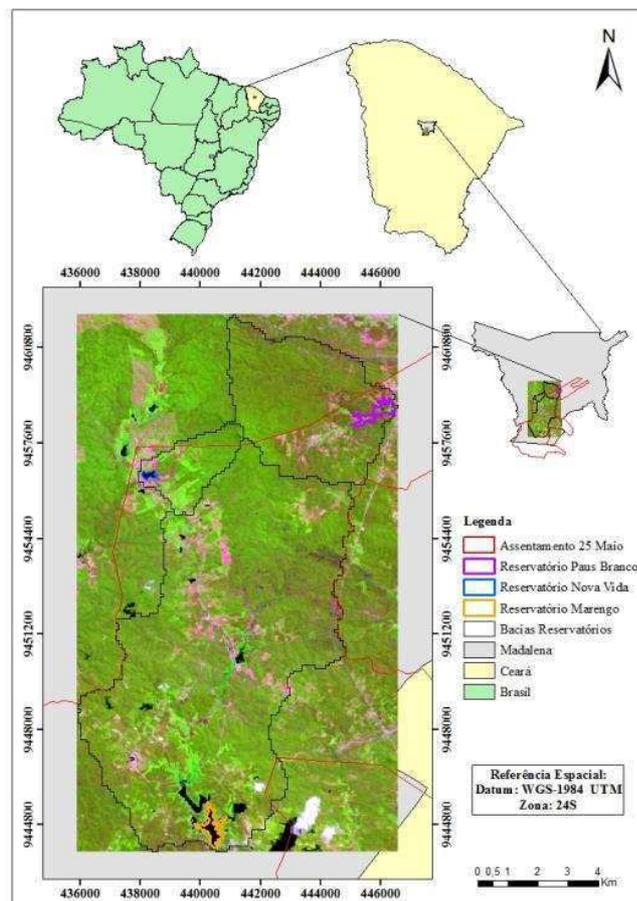
4 MATERIAL E MÉTODOS

4.1 Caracterização da área de estudo

As áreas consideradas neste trabalho foram os entornos dos reservatórios Nova Vida, Paus Branco e Marengo, todos localizados no assentamento 25 de Maio (25M). O assentamento, que possui uma área total de 22992 ha e se encontra inserido nos limites de três municípios, Madalena, Boa Viagem e Quixeramobim, localizado a 187 km da capital Fortaleza.

No assentamento 25 de Maio vivem 425 famílias com cerca de 2.000 habitantes, organizadas em 13 comunidades com 18 associações comunitárias e uma cooperativa (ARAÚJO, 2015). Os açudes localizados no território são de pequeno e médio porte, dispostos em duas sub-bacias hidrográficas que são afluentes da bacia hidrográfica do rio Banabuiú. A Figura 4 apresenta a localização do assentamento 25 de Maio

Figura 4 - Localização do assentamento 25 de Maio no estado do Ceará



Fonte: ARAÚJO, 2015.

Algumas características dos açudes Nova Vida, Paus Branco e Marengo, tais como volume, área da bacia e do espelho d'água e porte do reservatório, encontram-se listadas na Tabela 2.

Tabela 2 - Características físicas dos reservatórios no assentamento 25 de maio

Reservatório	Volume (hm³)	Área da bacia (km²)	Área do espelho d'água (km²)	Capacidade de armazenamento
Nova Vida	1,3	6	0,23	Pequeno
Paus Brancos	5,5	21	0,57	Pequeno
Marengo	18	75	3,1	Médio

Fonte: ARAÚJO, 2015.

O assentamento encontra-se localizado no Polígono das Secas, com predominância de clima quente e semiárido, segundo classificação de Köppen. Tal clima é caracterizado por um período seco e quente, e um inverno mais ameno e chuvoso. As temperaturas são altas durante todo o ano, com média anual acima de 18 °C e grandes amplitudes térmicas diárias e anuais. As temperaturas médias estão entre 26 a 28 °C, com período chuvoso, concentrado entre os meses de janeiro a maio. A pluviosidade média é de 692 mm anuais e a taxa potencial de evapotranspiração é superior a 2000 mm anuais devido à elevada temperatura ambiente e à intensa radiação solar que é característica da região (IPECE, 2009).

4.2 Realce de imagens

Os diferentes métodos apresentados a seguir foram implementados no ambiente computacional MATLAB e aplicados nas imagens da área de estudo. É utilizado como ambiente de desenvolvimento o programa Matlab ©, versão 8.0.0.783 R2012b (MATLAB, 2012).

As imagens utilizadas no trabalho de pesquisa são cenas do Landsat-8 de setembro de 2014, obtidas no sítio eletrônico do Serviço de Levantamento Geológico Americano (USGS, 2016). Consideraram-se imagens de setembro de 2014 devido à correspondência com a data das campanhas de coleta de pontos geográficos, para validação dos dados, que

ocorreram no mês de setembro de 2014. Foram usadas as bandas 4, 5 e 6 do Landsat-8, respectivamente como as componentes monocromáticas B (*Blue*), G (*Green*) e R (*Red*).

4.2.1 Transformação por *contrast-stretching*

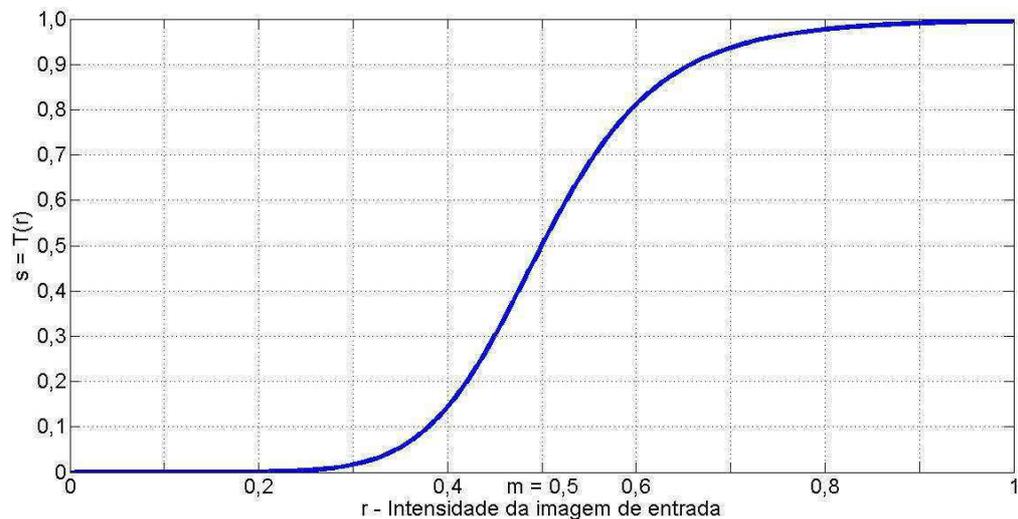
A transformação por *contrast-stretching* é dada pela Equação 4 (GONZALEZ; WOODS; EDDINS, 2004):

$$s = T(r) = \frac{1}{1 + (m/r)^E}, \quad (4)$$

em que r denota a intensidade (nível de cinza) da imagem f (imagem de entrada), e s a intensidade da imagem g (imagem de saída), ambas em qualquer ponto (x,y) nas imagens.

A Figura 5 apresenta a forma de mapeamento da função *Contrast-Stretching*, considerando-se os valores de intensidade na imagem de entrada escalonados no intervalo $[0,1]$ e o valor de $m = 0,5$.

Figura 5 - Comportamento da função *Contrast-Stretching* ($E = 8$)



Fonte : autor.

Essa função comprime os níveis de intensidade na imagem de entrada abaixo do valor m em uma banda estreita de tons escuros na imagem de saída; de forma similar, comprime os níveis de intensidade acima do valor m em uma estreita faixa de tons claros. O

resultado é uma imagem com maior contraste. O parâmetro E da equação é variado nos testes computacionais para se analisar o impacto dessa variação sobre a classificação das imagens estudadas.

Quanto maior o valor do parâmetro E , mais íngreme é a inclinação da curva $s = T(r)$, e a função *contrast-stretching* se aproxima, no limite de E tendendo a valores muito altos, da função limiar, a qual possui apenas dois valores de saída: 0, se $r < m$, e 1, se $r > m$.

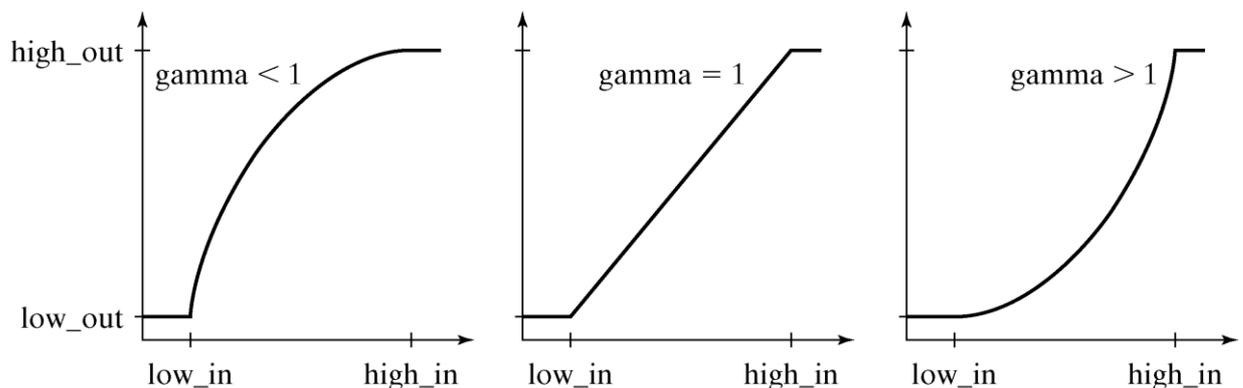
4.2.2 Função *ImAdjust* – MATLAB

A função *ImAdjust*, integrante do pacote *Image Processing Toolbox* do software MATLAB, é uma ferramenta básica de transformação de intensidade para imagens em escala de cinza (MATLAB, 2012). A sintaxe da função é mostrada na Equação 5.

$$G = \text{ImAdjust}(f, [\text{low_in } \text{high_in}], [\text{low_out } \text{high_out}], \text{gamma}) \quad (5)$$

A função mapeia os níveis de intensidade da imagem f em novos valores na imagem G , de modo que intensidades entre os níveis low_in e high_in são transformadas em valores dispostos entre low_out e high_out . O parâmetro gamma define a forma como a transformação ocorre. Se gamma é inferior a 1, o mapeamento é ponderado para valores de saída mais elevados (níveis mais claros), tal como ilustra a Figura 6. Se gamma é maior do que 1, o mapeamento é ponderado para valores de saída mais baixos (níveis mais escuros).

Figura 6 - Formas de mapeamento disponíveis na função *ImAdjust*



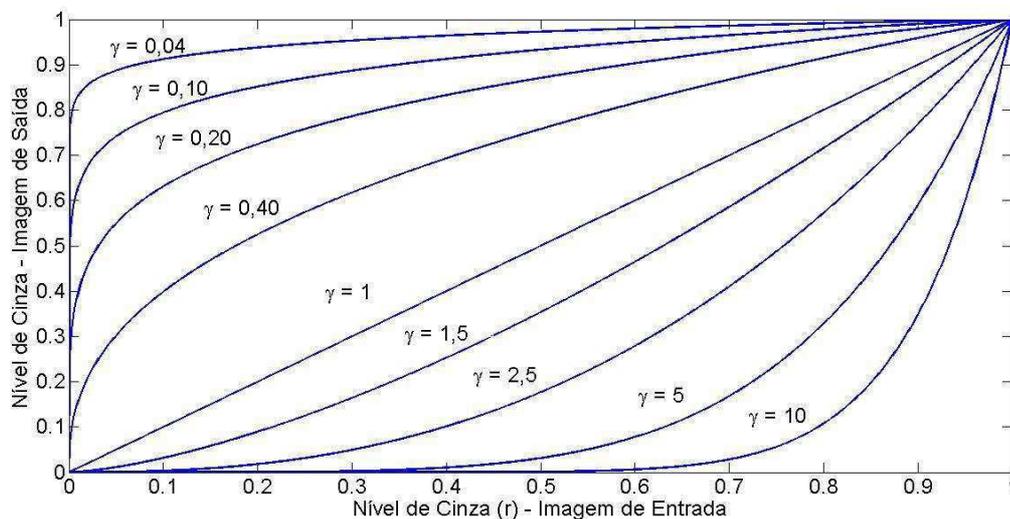
Fonte: GONZALEZ; WOODS; EDDINS, 2004.

A função *Imadjust* é equivalente às transformadas de potência, que se apresentam na forma da Equação 6 (GONZALEZ; WOODS, 2010):

$$s = cr^\gamma \quad (6)$$

Na Equação 6, c e γ são constantes. A Figura 7 apresenta o comportamento da transformação de potência para diversos valores de γ , considerando a constante c igual a 1.

Figura 7 - Resposta da transformação de potência para diferentes valores da constante γ
($c = 1$)



Fonte: autor. Baseado em GONZALEZ; WOODS, 2002.

Observa-se que, para valores fracionários de γ (menores que 1), a transformação faz com que uma estreita faixa de tons escuros de entrada seja expandida para uma faixa larga de valores de saída. Já para valores de γ maiores que 1, uma faixa estreita de tons claros de entrada é expandida para uma faixa larga de valores de saída, havendo compressão dos níveis de intensidade de tons escuros.

4.3 Classificação de alvos em imagens

Neste trabalho, foram aplicados algoritmos de classificação supervisionada de alvos em imagens após a aplicação de pré-processamento por realce pelos métodos citados anteriormente. Foram utilizados os classificadores de Mínima Distância (Distância

Euclidiana) e de Máxima Verossimilhança (Maxver), ambos implementados na linguagem de *scripts* disponível no ambiente MATLAB. A versão do MATLAB (R2012b) utilizada para as classificações foi a mesma usada para aplicação dos realces. Para os dois classificadores, foi considerado um universo amostral de 10 elementos por classe para o treinamento dos algoritmos e de 20 elementos por classe para a validação. A escolha do número de elementos para o conjunto de treinamento e para o conjunto de validação foi definida com base no estudo de Araújo (2015). Os pontos geográficos para os conjuntos de treinamento e validação foram obtidos em campo, na região de estudo, em setembro de 2014, utilizando um GPS de navegação.

Em seguida, foram comparados os resultados das combinações entre métodos de realce e classificadores por meio do coeficiente de concordância *kappa*.

4.3.1 Classificador de Mínima Distância

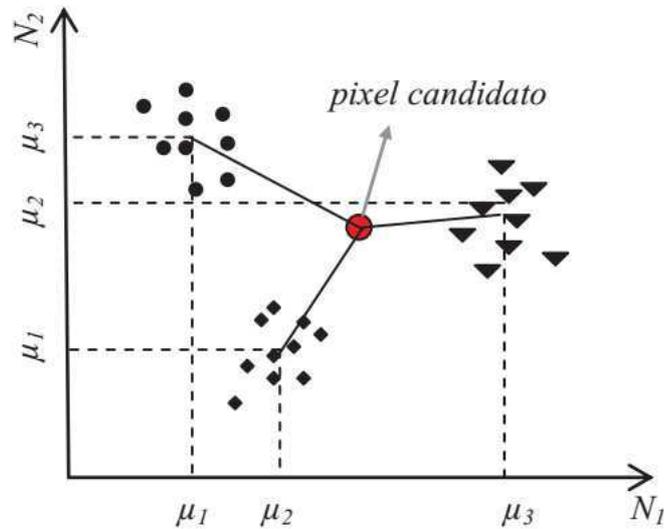
O classificador de mínima distância tem como regra de decisão a distância mínima entre o vetor de componentes RGB do pixel que se deseja classificar e os vetores com valores médios de componentes RGB das classes espectrais contidas na área de estudo. Segundo Moreira (2007), considerando um espaço n-dimensional, o cálculo é feito por meio da Equação 7:

$$d(x, m/w) = \sqrt{\sum_{i=1}^n (x_i - m_i)^2} \quad (7)$$

em que $d(x, m/w)$ é a distância mínima (euclidiana) entre o pixel x e o centroide da classe w ; x_i e m_i são, respectivamente, as componentes do vetor x , que fornecem a posição do ponto no espaço de atributos, e do centroide da classe w ; e n , a dimensão do espaço de atributos (número de bandas espectrais).

Dessa forma, o treinamento busca caracterizar cada pixel de forma que as distâncias entre os atributos dos pixels de um agrupamento (classe) sejam mínimas e, porém, entre agrupamentos sejam as maiores possíveis. Assim, é equivalente afirmar que o critério para se realizar o agrupamento dos dados em torno das classes é o de minimizar a soma dos erros quadráticos (MOREIRA, 2007). A Figura 8 ilustra o classificador de mínima distância. As linhas cheias indicam as medidas da distância mínima para um pixel candidato às classes.

Figura 8 - Classificador de mínima distância



Fonte: MENESES; SANO, 2012.

4.3.2 Classificador de Máxima Verossimilhança

O classificador de máxima verossimilhança considera a ponderação das distâncias entre as médias dos valores dos pixels das classes, utilizando parâmetros estatísticos. Assume que todas as bandas têm distribuição normal e calcula a probabilidade de um dado pixel pertencer a uma classe específica (INPE, 2008).

Segundo Moreira (2007), na formulação estatística do problema, assume-se uma densidade de probabilidade condicional $P(x/w_j)$, em que x é o conjunto de valores, nas diversas características, e w_j representa a j -ésima classe. Esta densidade de probabilidade condicional define a característica da classe.

Dado um objeto x_0 , pode-se utilizar como regra de decisão a atribuição de x_0 a uma classe w_j , cuja probabilidade condicional $P(w_j/x_0)$ é máxima. Pela regra de Bayes tem-se então (Equação 8) (MOREIRA, 2007):

$$P(\omega_j / x) = \frac{P(\omega_j)P(x / \omega_j)}{P(x)} \quad (8)$$

em que $P(x/w_j)$ é a função de densidade de probabilidade condicional referida a a w_j ; $P(x)$ é a probabilidade de ocorrência de cada amostra; e $P(w_j/x)$ e $P(w_j)$ são as probabilidades da classe w_j , condicionada e incondicionada aos valores das características, respectivamente.

Para proceder ao cálculo de $P(w_j/x)$ de forma simplificada, é possível calcular somente $P(x/w_j)P(w_j)$, pois $P(x)$ é o denominador de todas as classes. A quantidade $P(x/w_j)$, que é uma densidade de probabilidade, é chamada verossimilhança de w_j em relação a x . Dessa maneira, uma regra de decisão simplificada é classificar o objeto x_o como pertencente à classe w_j de maior valor de $P(x_o/w_j)$, ou seja, de máxima verossimilhança.

Uma vez que o Maxver considera a distribuição espectral das classes como sendo uma distribuição normal, a probabilidade da distribuição normal multi-dimensional é dada pela Equação 9 (MOREIRA, 2007):

$$P(x) = \frac{1}{(2\pi)^{n/2} |C|^{1/2}} \exp\left[-\frac{1}{2}(x-m)C^{-1}(x-m)^T\right] \quad (9)$$

Sendo x um vetor n -dimensional; m o vetor média (também n -dimensional); C uma matriz quadrada $n \times n$, chamada matriz de covariância; $|C|$ o determinante de C e C^{-1} sua inversa.

A distribuição normal multivariável estará completamente especificada se forem determinados o vetor média m e a matriz de covariância C .

4.3.3 Análise de concordância – Matriz de confusão e κ (*kappa*)

O método padrão para avaliação da precisão temática geralmente utiliza índices derivados da matriz de confusão. A matriz de confusão fornece a base para descrever a precisão da classificação e caracterizar os erros, ajudando a refinar a classificação. De uma matriz de confusão podem ser derivadas várias medidas de precisão da classificação, sendo a exatidão global uma das mais conhecidas (FOODY, 1992 *apud* FIGUEIREDO, VIEIRA, 2007).

Para verificar a acurácia dos dados obtidos com a classificação, utilizou-se o índice κ (*kappa*). A análise de κ é uma técnica multivariada discreta usada na avaliação da precisão temática e utiliza todos os elementos da matriz de confusão no seu cálculo. O coeficiente κ é uma medida da concordância real (indicado pelos elementos diagonais da matriz de confusão) menos a concordância por chance (indicado pelo produto total da linha e coluna, que não inclui entradas não reconhecidas), ou seja, é uma medida do quanto à classificação está de acordo com os dados de referência. O coeficiente *Kappa* pode ser calculado através da Equação 10 (FIGUEIREDO, VIEIRA, 2007):

$$K = \frac{n \sum_{i=1}^c x_{ii} - \sum_{i=1}^c x_{i+} x_{+i}}{n^2 - \sum_{i=1}^c x_{i+} x_{+i}} \quad (10)$$

na qual K é uma estimativa do coeficiente κ ; x_{ii} é o valor na linha i e coluna i ; x_{i+} é a soma da linha i e x_{+i} é a soma da coluna i da matriz de confusão; n é o número total de amostras e c o número total de classes.

A partir do valor do coeficiente é possível determinar o desempenho da classificação com base na Tabela 3.

Tabela 3 - Coeficiente κ e desempenho de classificação

Índice Kappa	Desempenho
< 0	Péssimo
$0 < \kappa \leq 0,2$	Ruim
$0,2 < \kappa \leq 0,4$	Razoável
$0,4 < \kappa \leq 0,6$	Bom
$0,6 < \kappa \leq 0,8$	Muito bom
$0,8 < \kappa \leq 1,0$	Excelente

Fonte: FIGUEIREDO, VIEIRA, 2007.

5 RESULTADOS E DISCUSSÃO

Para o desenvolvimento deste trabalho foram definidas nove classes: água, macrófitas, solo exposto, vegetação nativa, agricultura, vegetação rala, vazante, nuvem e sombra de nuvem.

Durante a fase de aplicação dos métodos de pré-processamento às imagens da área de estudo foram realizados diversos testes, variando-se os parâmetros de controle dos métodos de realce para observar seu impacto no resultado da classificação dos dados de validação. Os parâmetros citados foram o *gamma* (Equações 5 e 6), no caso do realce por *ImAdjust*; e *E* (Equação 4), para o caso de realce por *Contrast Stretching*. Os valores de ambos os parâmetros foram analisados no intervalo de 0,1 a 10 com um passo de 0,1. Para cada uma das variações, foi observado o valor do coeficiente de concordância obtido após a aplicação dos métodos de classificação, buscando-se maximizar esse valor de κ . Dessa maneira, foram utilizados quatro conjuntos de métodos de realce combinados a métodos de classificação.

A Tabela 4 explicita as combinações citadas e os valores máximos de κ obtidos em cada caso e o parâmetro de controle da transformada de realce correspondente.

Tabela 4 - Valores de κ e parâmetros de controle (*E* e *gamma*) para combinações de métodos de realce e classificadores

Combinação	Método de realce	Classificador	Valor do Parâmetro	κ
1	Sem realce	Mínima distância	-	0,49
2	Sem realce	Máxima verossimilhança	-	0,62
3	<i>ImAdjust</i>	Mínima distância	3,5	0,53
4	<i>ImAdjust</i>	Máxima verossimilhança	0,9	0,63
5	<i>Contrast Stretching</i>	Mínima distância	0,1	0,53
6	<i>Contrast Stretching</i>	Máxima verossimilhança	2,3	0,63

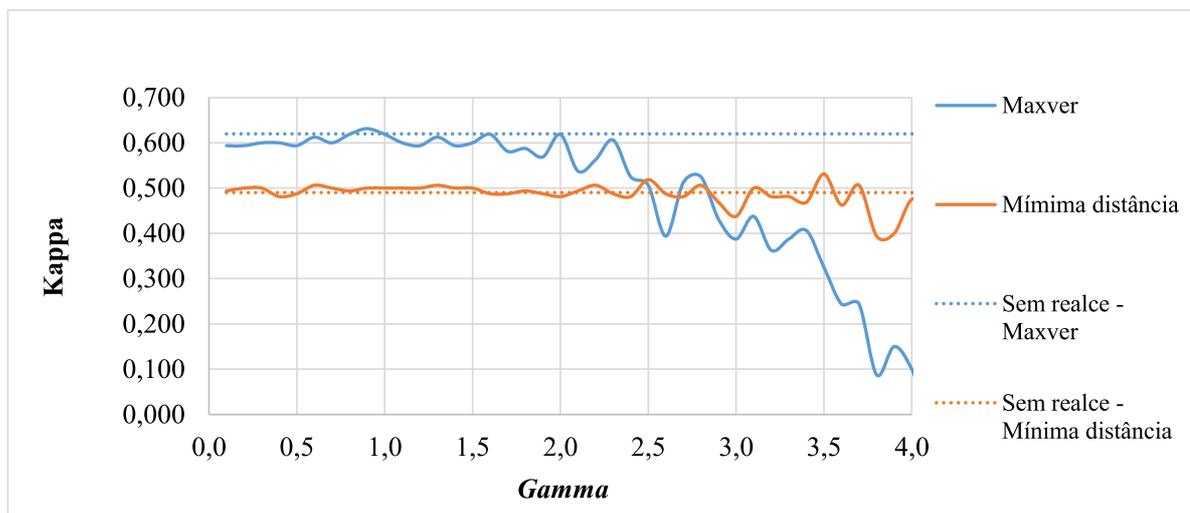
Fonte: autor.

Observa-se que, com a aplicação de métodos de pré-processamento, em todas as combinações, é possível elevar os valores de *kappa*, considerando-se o caso sem realce e com realce para um mesmo classificador. Nota-se também que, para um mesmo classificador, independentemente do método de realce utilizado, o valor máximo de *kappa* obtido é igual, considerando-se a precisão de 2 casas decimais. Ainda observando-se apenas o valor máximo do coeficiente *kappa*, pode-se afirmar que o classificador de máxima verossimilhança obtém o maior coeficiente de concordância global.

5.1 Análise de concordância global

A Figura 9 apresenta um gráfico da evolução dos valores de *kappa* para cada variação do parâmetro *gamma* da função *ImAdjust*, observado para os dois classificadores utilizados. A figura destaca também os valores de *kappa* obtidos para cada classificador sem o uso de pré-processamento nas imagens.

Figura 9 - Valores de *kappa* em função de *gamma* para classificadores de mínima distância e máxima verossimilhança



Fonte: autor.

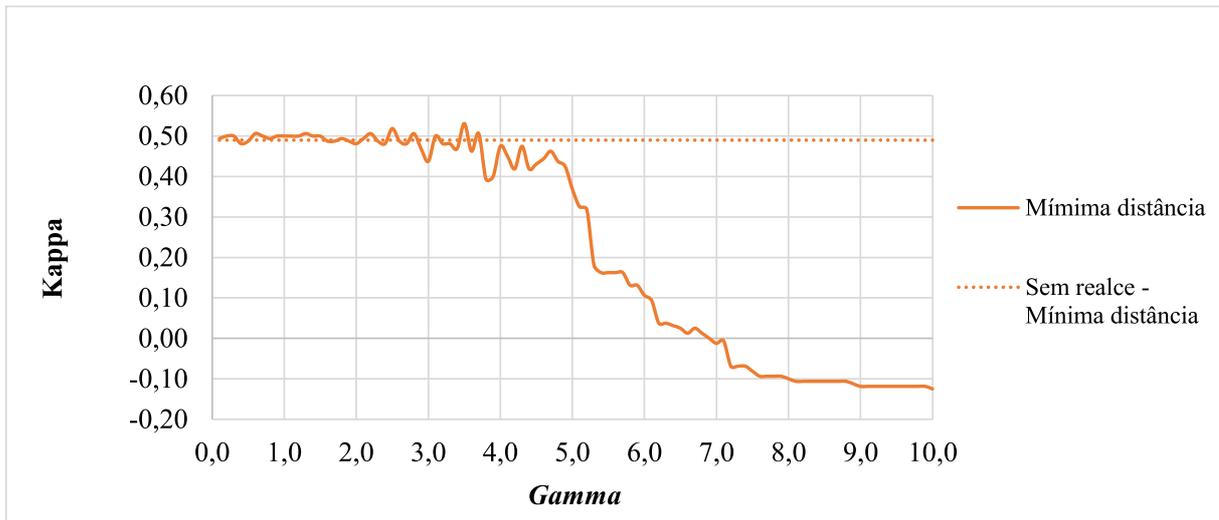
Evidencia-se pela Figura 9 que o classificador de máxima verossimilhança, para uma larga faixa de valores de *gamma* (0,1 a 2,4), produz valores de κ maiores que os obtidos pelo classificador de mínima distância. A partir de determinado valor de *gamma*, em torno de 2,5, a concordância obtida pelos resultados do classificador de mínima distância passa a ser maior.

Observou-se que a combinação entre realce por *ImAdjust* com o classificador de máxima verossimilhança apresenta limitações computacionais. Observa-se pela Figura 9 que a partir de determinado ponto (*gamma* igual a 2,8) o valor de *kappa*, nessa situação, começa a decrescer rapidamente com o avanço do valor de *gamma*. Isso ocorre porque, com o aumento do valor de *gamma*, a imagem passa a ser comprimida em direção a valores de intensidade mais baixos (tons mais escuros) de níveis de cinza (como explicado na Figura 6), o que diminui a variabilidade entre os valores dos pixels. Essa variabilidade torna-se tão pequena

que a matriz de covariância torna-se aproximadamente nula e o algoritmo classificador de máxima verossimilhança não calcula a inversa da matriz de covariância. Inviabiliza-se, assim, nessa situação, o processamento dos dados por esse método. A partir dos testes, observou-se que para valores de γ maiores que 4, o algoritmo Maxver utilizado não calculou resultados, motivo pelo qual a Figura 9 não apresenta a variação dos valores de γ até 10, valor máximo descrito anteriormente para os parâmetros de controle.

Por outro lado, o algoritmo classificador de mínima distância ainda retorna resultados após este ponto. A Figura 10 apresenta o desenvolvimento completo da evolução dos valores de κ com o aumento de γ para o classificador de mínima distância.

Figura 10 - Gráfico dos valores de κ em função de γ para classificadores de mínima distância



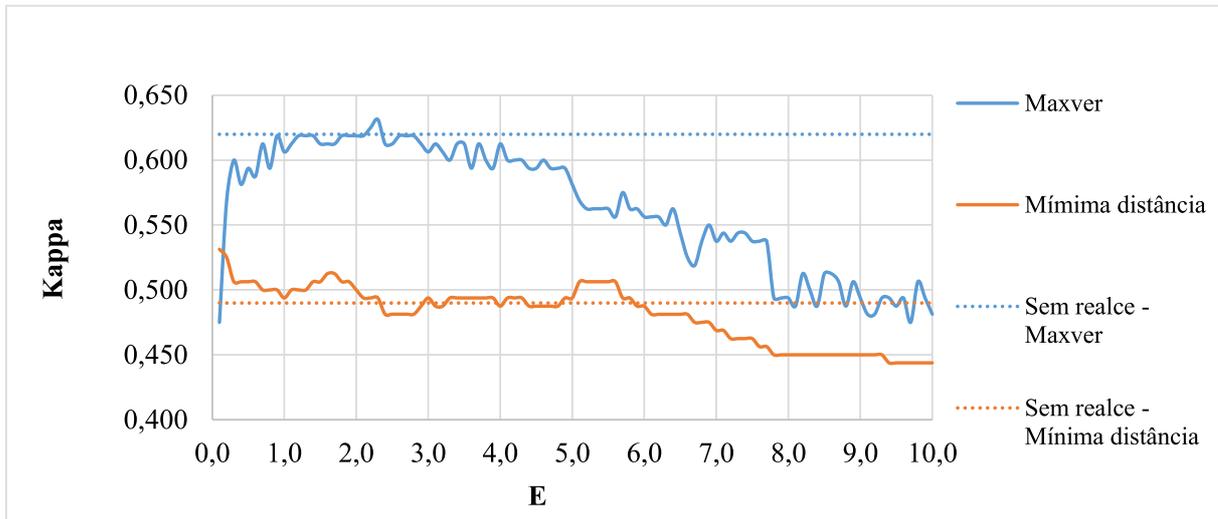
Fonte: autor.

Nesse caso, para valores de γ maiores que 5, observa-se também uma queda dos valores de κ . Essa diminuição dos valores de κ se dá devido ao mesmo fato de que, com o aumento de γ , a imagem se torna mais escura, e a partir de determinado ponto, os pixels se tornam tão parecidos que o algoritmo não consegue classificar com exatidão. Nesse caso, a distância entre os pixels e as médias das classes vai diminuindo, uma vez que a distância entre seus valores diminui. Em determinado momento, o algoritmo não mais consegue distinguir atributos entre as classes e a concordância da classificação começa a cair, inclusive para valores negativos.

A Figura 11 apresenta um gráfico da evolução dos valores de κ para cada variação do parâmetro E da transformada de realce por *Contrast Stretching*, observado para os

dois classificadores analisados. Assim como na Figura 9, estão destacados os valores de *kappa* obtidos para cada classificador sem o uso de pré-processamento nas imagens.

Figura 11 - Valores de *kappa* em função de E para classificadores de mínima distância e máxima verossimilhança



Fonte: autor.

Analisando-se os valores do coeficiente de concordância para os classificadores de mínima distância e máxima verossimilhança, com aplicação em imagens após o pré-processamento por *Contrast Stretching*, observa-se que quase a totalidade dos melhores resultados são obtidos para o classificador Maxver. Apenas para poucos valores iniciais, a acurácia do classificador de mínima distância supera a do classificador de máxima verossimilhança. Ao contrário do observado pelas aplicações do realce com *ImAdjust*, para a faixa de variação de parâmetros 0,1 a 10, obtiveram-se resultados para toda a faixa de valores, em ambos os classificadores.

Observando-se isoladamente o caso do classificador de mínima distância, nota-se que para valores de E superiores a 6, o coeficiente de concordância é inferior ao caso em que não se utiliza o realce. Por sua vez, o classificador de máxima verossimilhança só apresenta valores de *kappa* superiores ao caso sem realce em uma estreita faixa de valores de E que vai de 2 a 2,3.

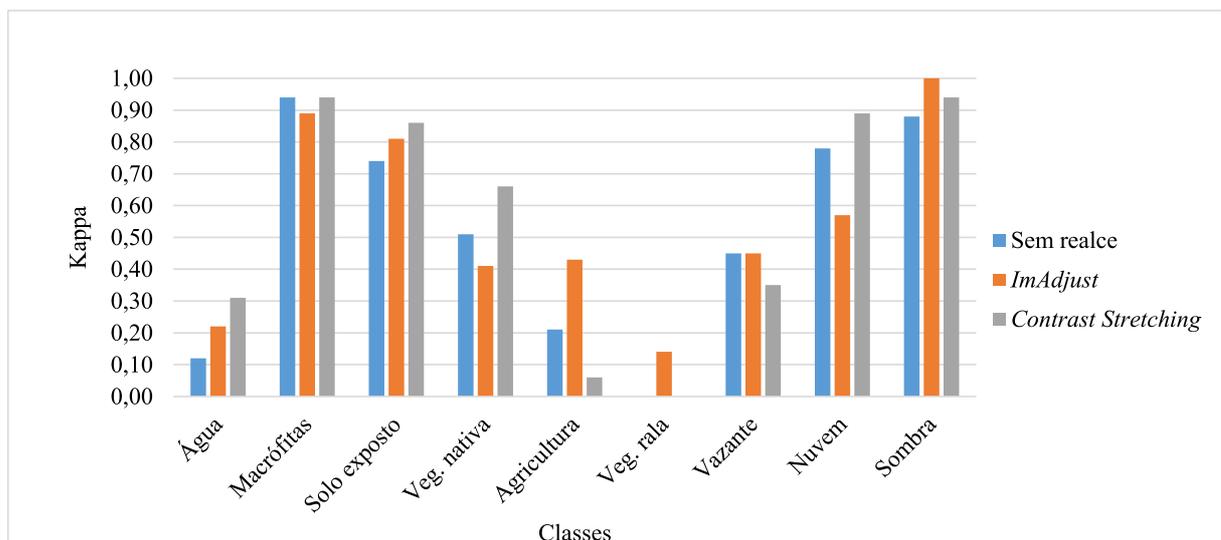
Grondona (2009), que comparou a aplicação dos algoritmos de máxima verossimilhança e de mínima distância para a região do Pantanal, também obteve taxas de acerto mais altas com a aplicação do algoritmo de máxima verossimilhança. Entretanto, os resultados de *kappa* global para mínima distância e máxima verossimilhança obtidos por

Grondona (2009) foram de, respectivamente, 0,85 e 0,92. Embora tais resultados sejam numericamente superiores aos obtidos neste trabalho, deve-se considerar o fato de que Grondona (2009) reuniu as classes água e sombra de nuvem, as quais possuem similarmente baixos níveis de refletância, em uma única classe, o que reduz as taxas de confusão do algoritmo. Pereira *et al.* (2011), aplicando os dois referidos métodos de classificação na região do Alto Araguaia, obteve resultados que também indicam maior desempenho para o classificador de máxima verossimilhança.

5.2 Análise de concordância local

A Figura 12 apresenta a variação do coeficiente *kappa* por classe para o classificador de mínima distância, considerando os casos de classificação sem realce, com realce por *ImAdjust* e com realce por *Contrast Stretching*. Nos dois últimos casos, a classificação se refere à utilização do realce com os parâmetros ótimos apresentados na Tabela 3.

Figura 12 - Variação de *kappa* por classe e por método de pré-processamento para o classificador de mínima distância – *ImAdjust* com $\gamma = 3,5$ e *Contrast Stretching* com $E = 0,1$



Fonte: autor.

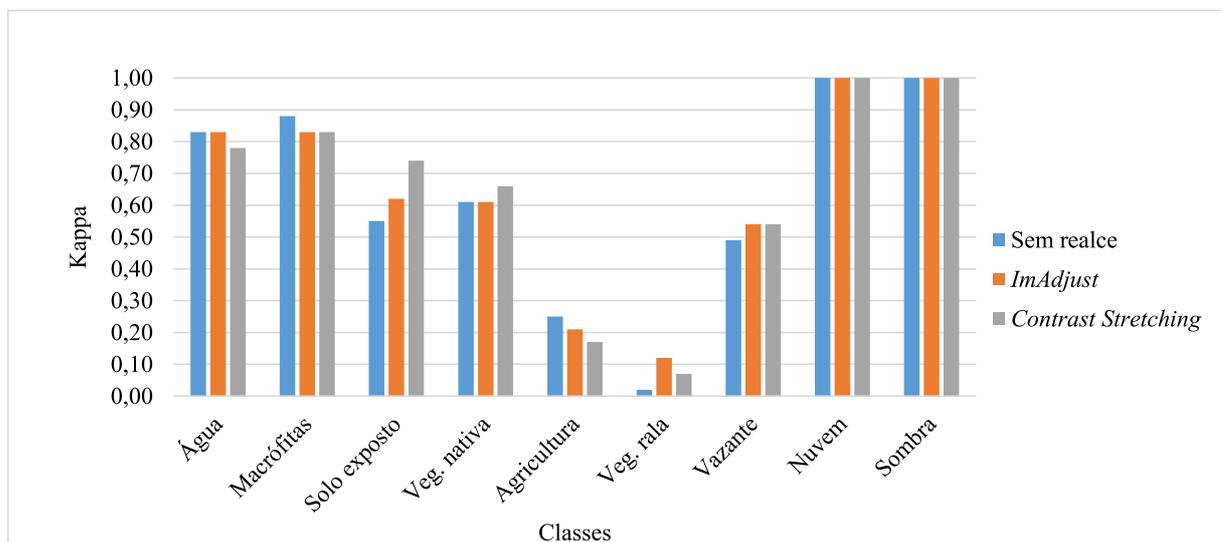
De acordo com o classificador de mínima distância, as classes com mais altas taxas de concordância são macrófitas, solo exposto, vegetação nativa, nuvem e sombra de nuvem. Pode-se observar, por exemplo, o contraste entre a acurácia da classificação da classe

macrófitas, com $kappa$ entre 0,8 e 1,0, com a acurácia da classificação da classe água com valores entre 0,1 e 0,4. Os resultados das classes macrófitas, solo exposto e sombra de nuvem, nos três casos de realce apresentaram valores de $kappa$ maiores que 0,7.

Para as classes água, solo exposto, macrófitas, vegetação nativa e nuvem, observa-se maior concordância para o pré-processamento por Contrast-Stretching em relação ao realce por *ImAdjust*. Para nenhuma das classes, o $kappa$ obtido da imagem sem realce foi maior que os casos de imagem com realce, ocorrendo empates apenas nas classes macrófitas e vazantes.

A Figura 13 apresenta a variação do coeficiente $kappa$ por classe para o classificador de máxima verossimilhança, considerando os casos de classificação sem pré-processamento, com pré-processamento por *ImAdjust* e por *Contrast Stretching*. Assim como reportado para a Figura 12, nos casos em que a classificação se refere à utilização de pré-processamento, os parâmetros utilizados foram aqueles apresentados na Tabela 3.

Figura 13 - Variação de $kappa$ por classe e por método de pré-processamento para o classificador de máxima verossimilhança – *ImAdjust* com $\gamma = 0,9$ e *Contrast Stretching* com $E = 2,3$



Fonte: autor.

Em comparação com a Figura 12, observa-se que a aplicação do classificador de máxima verossimilhança proporciona maiores valores de $kappa$ nas classes água, macrófitas, vegetação nativa, vegetação rala, vazante, nuvem e sombra de nuvem. O aumento dos $kappas$ individuais nessas classes implica no aumento do $kappa$ global, o que justifica o melhor resultado de acurácia global para o classificador de máxima verossimilhança.

O maior índice global de concordância obtido para o classificador de máxima verossimilhança e os altos valores de *kappa* individualizados obtidos nas classes água, nuvem e sombra de nuvem, com este classificador, fazem das combinações classificador de máxima verossimilhança e pré-processamento por ImAdjust ou classificador de máxima verossimilhança e pré-processamento por Contrast-Stretching técnicas eficientes para utilização como ferramenta de diferenciação de usos do solo via sensoriamento remoto.

5.3 Classificação do entorno dos reservatórios

Definidos os parâmetros de pré-processamento que produzem os maiores valores de *kappa* para cada combinação de realce e classificador, procedeu-se à classificação da área do entorno dos reservatórios em estudo: Paus Branco, Marengo e Nova Vida. Para distinguir as classes foi utilizado o código de cores apresentado na Tabela 5.

Tabela 5 - Cores utilizadas na classificação do entorno dos reservatórios

Classe	Descrição	Cor
1	Água	Azul
2	Macrófita	Amarelo
3	Solo Exposto	Vermelho
4	Vegetação Nativa	Verde
5	Agricultura	Laranja
6	Vegetação rala	Marrom
7	Vazante	Lilás
8	Nuvem	Cinza
9	Sombra de Nuvem	Preto

Fonte: autor.

As Figuras 14 a 16 apresentam o conjunto de resultados das combinações de classificações e métodos de realce aplicados para os três reservatórios estudados: Paus Branco (Figura 14), Marengo (Figura 15) e Nova Vida (Figura 16). Nos casos em que houve aplicação de realce, foram utilizados os valores de parâmetros descritos na Tabela 4.

Na Figura 14, observa-se que, considerando o classificador de mínima distância, há uma alta incidência de confusão na classificação da classe água em relação à classe sombra de nuvem. Em virtude de similaridade dos níveis de refletância de corpos hídricos e sombra de nuvens, o algoritmo confundiu alguns dos pixels de água com sombra de nuvem. Por outro lado, ao utilizar a classificação por máxima verossimilhança esse problema é reduzido.

Para a classificação do entorno do açude Marengo observa-se de forma mais evidente a confusão durante a classificação entre pixels de água e sombra de nuvem (Figura 15). Entretanto, observando os resultados utilizando o realce por *Contrast Stretching* constata-se que esse problema é amenizado. Comparando esse aspecto com a classificação usando *ImAdjust* é evidente a melhoria do resultado, evidenciando que no caso do classificador de mínima distância a opção do realce por *Contrast Stretching* apresenta-se, em geral, como a melhor opção. Pelos resultados do classificador de máxima verossimilhança constata-se significativa diminuição na confusão entre as classes água e sombra de nuvem, observada para o classificador de mínima distância. Nota-se, visualmente, uma efetiva melhoria na diferenciação das áreas ocupadas por cada classe.

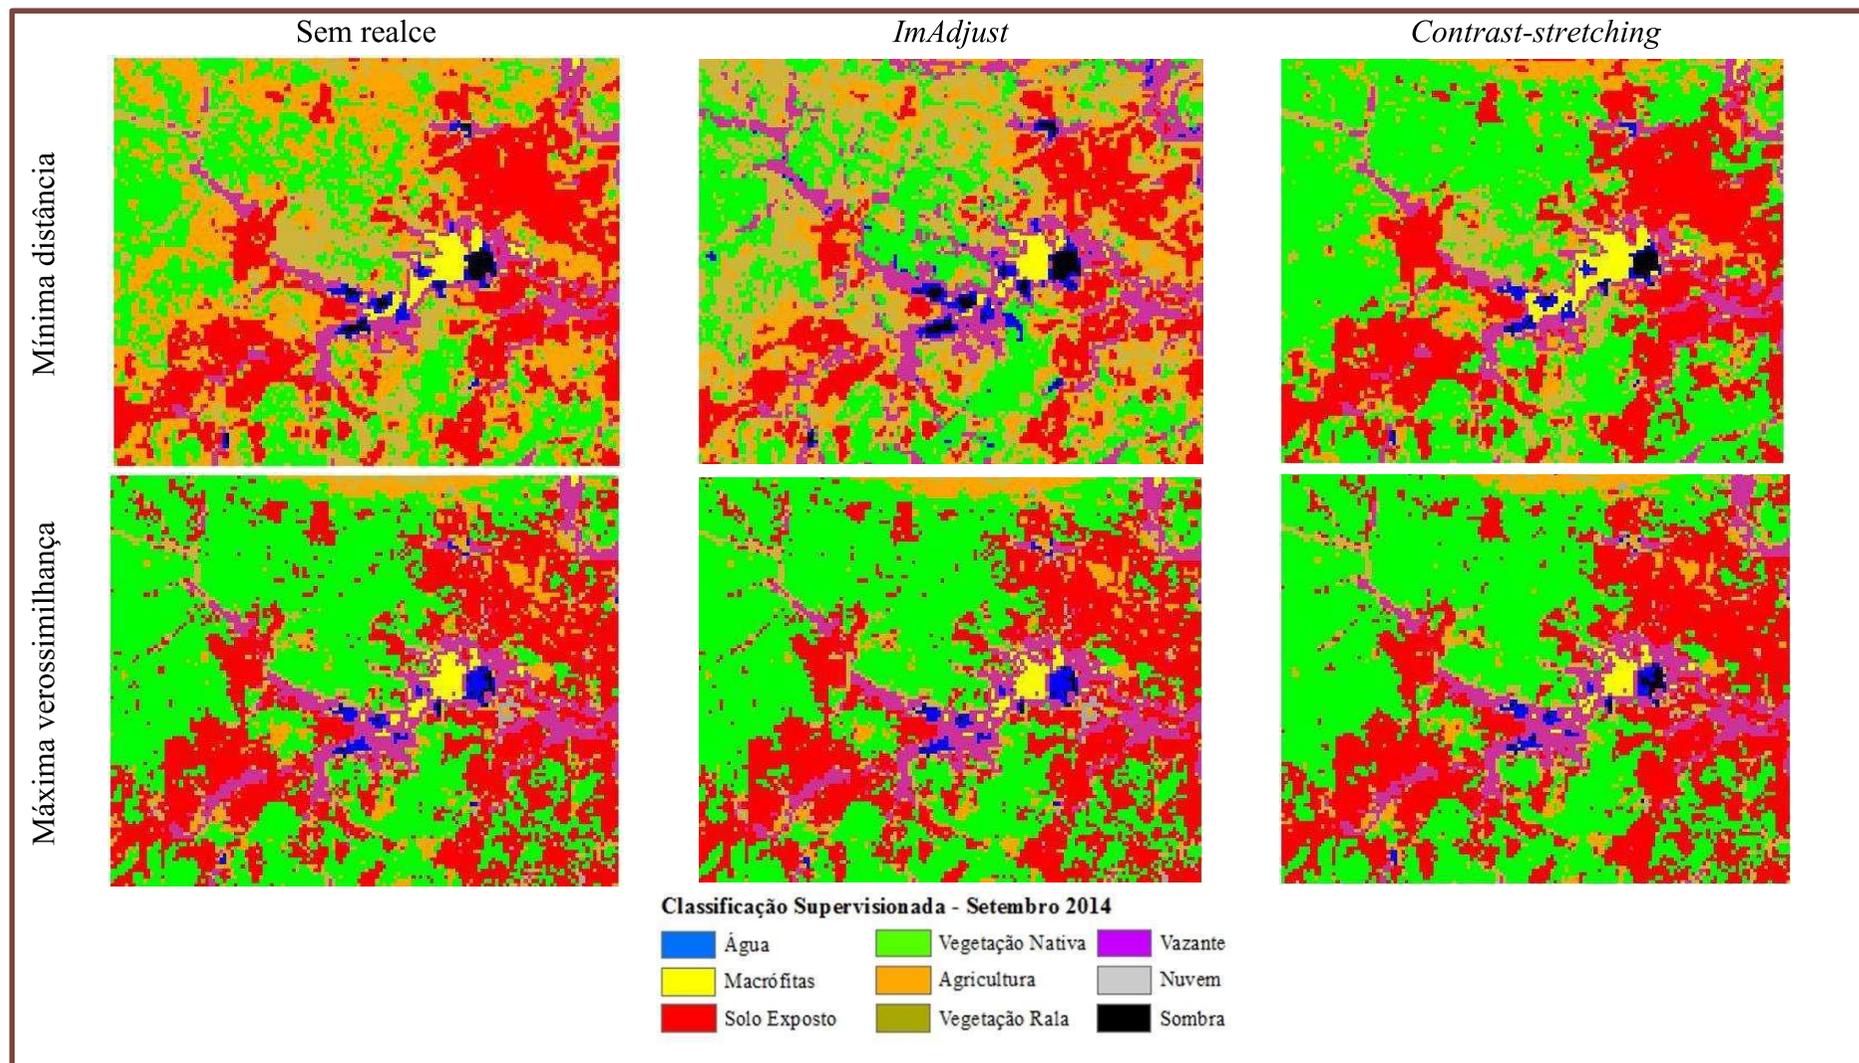
As Tabelas 6 a 8 apresentam a quantificação das áreas por classe para cada combinação de método de realce e classificador para o entorno dos reservatórios Paus Branco, Marengo e Nova Vida, respectivamente.

Por meio da Tabela 6, observa-se que as classes predominantes, no entorno do reservatório Paus Branco, são vegetação nativa e solo exposto. A classe vegetação nativa apresenta a maior área em todas as combinações, exceto para o caso do classificador de mínima distância sem aplicação de realce.

Com a Tabela 7, observa-se que no entorno do reservatório Marengo predominam também as classes vegetação nativa e solo exposto. Observa-se uma grande redução na área da classe sombra de nuvem e um aumento da classe água, considerando os resultados do classificador de máxima verossimilhança em relação ao classificador de mínima distância. Isso evidencia o fato de que o algoritmo Maxver reduz a confusão entre as classes água e sombra de nuvem.

Para o reservatório Nova Vida, a classe predominante é a de solo exposto, seguida pela classe vegetação nativa (Tabela 8). Analisando-se o efeito do algoritmo Maxver em relação ao de Mínima Distância, observa-se que as áreas das classes água e agricultura diminuem enquanto as áreas de classes como vazante e vegetação rala aumentam.

Figura 14 - Classificação do entorno do reservatório Paus Branco – resultados de todas as combinações



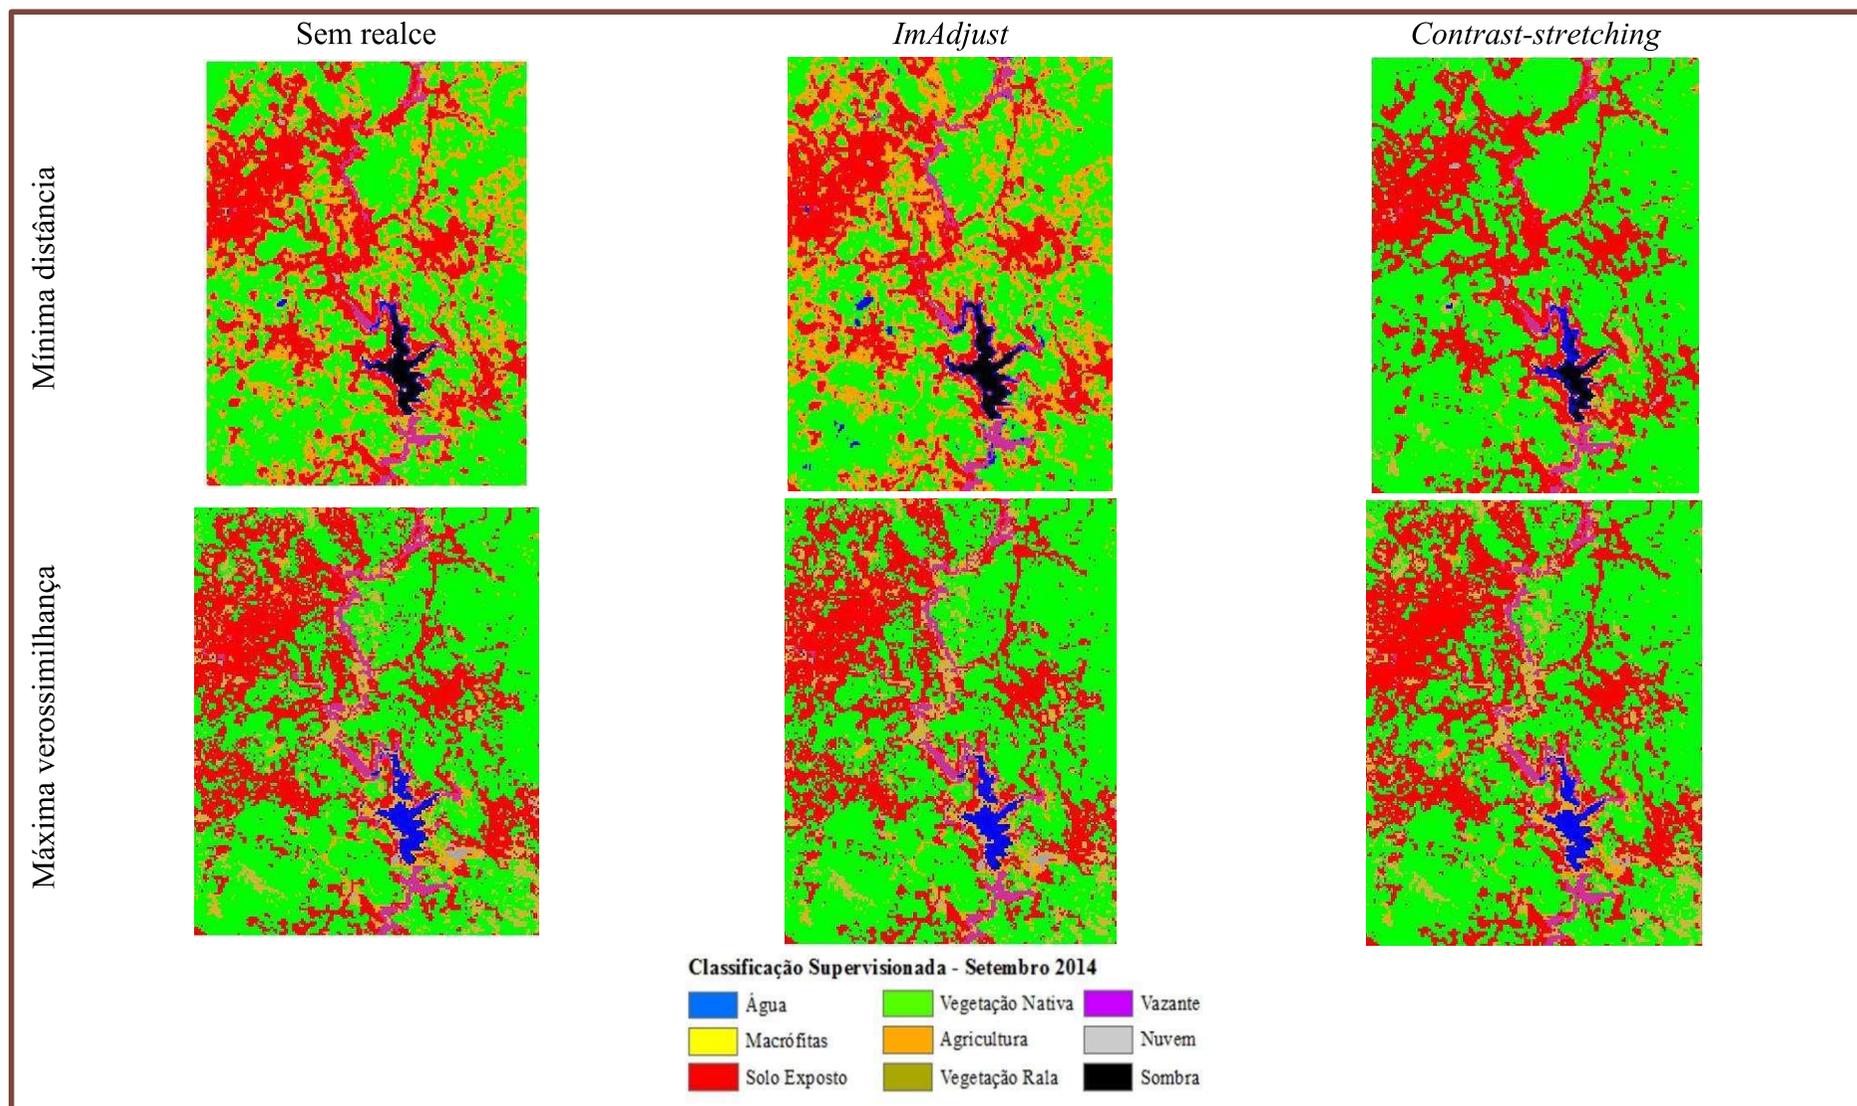
Fonte: autor.

Tabela 6 - Quantificação de áreas das classes (%) por combinação de método de realce e classificador – açude Paus Branco

Classes	Paus Branco					
	Minima Distância			Máxima verossimilhança		
	Sem realce	ImAdjust	Contrast Stretching	Sem realce	ImAdjust	Contrast Stretching
Água	0,85	1,62	0,82	0,90	0,89	0,73
Macrófita	1,44	0,98	1,88	1,06	0,95	0,86
Solo Exposto	23,46	16,52	28,66	32,79	32,16	33,82
Vegetação Nativa	22,51	21,02	42,14	44,48	46,70	45,68
Agricultura	32,68	17,51	12,64	7,33	6,19	5,55
Vegetação rala	11,43	28,32	6,81	5,03	4,62	4,92
Vazante	7,02	13,23	6,65	7,75	7,84	8,05
Nuvem	0,01	0,00	0,03	0,51	0,52	0,15
Sombra de Nuvem	0,59	0,80	0,37	0,15	0,12	0,23

Fonte: autor.

Figura 15 - Classificação do entorno do reservatório Marengo – resultados de todas as combinações



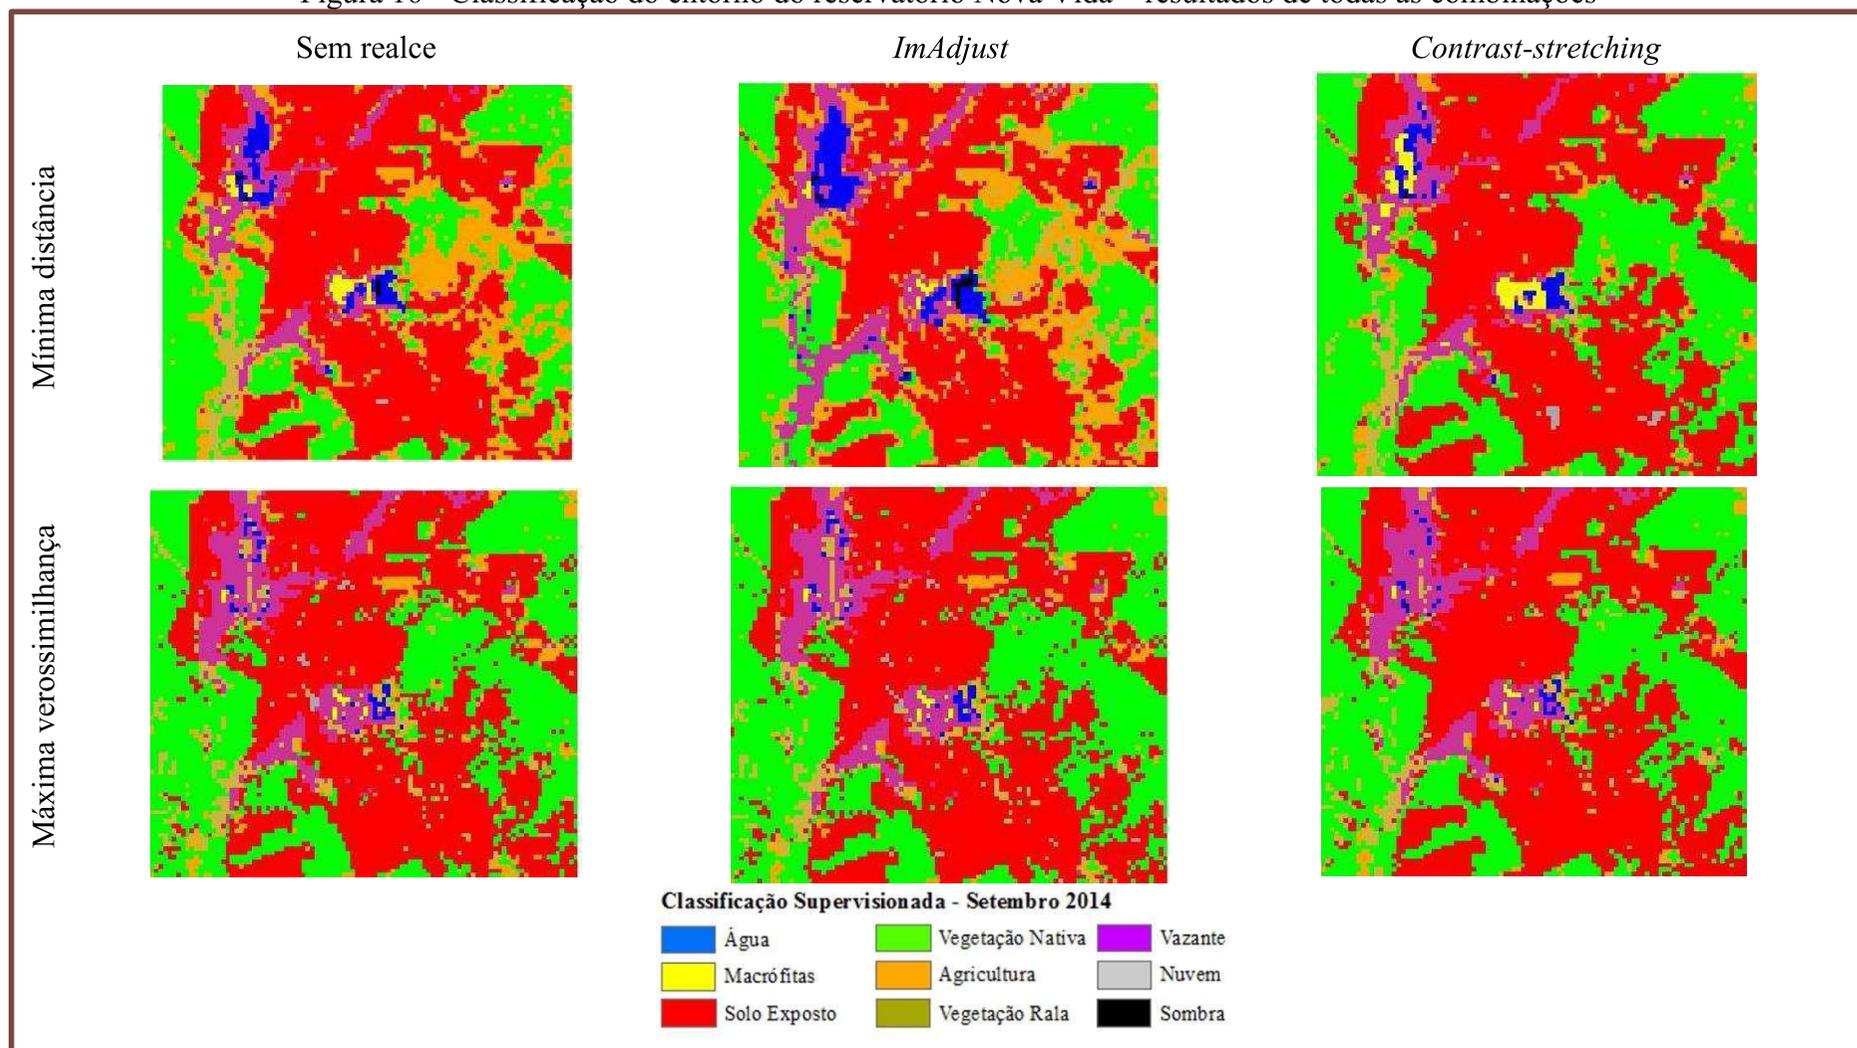
Fonte: autor.

Tabela 7 - Quantificação de áreas das classes (%) por combinação de método de realce e classificador – açude Marengo

Classes	Marengo					
	Minima Distância			Máxima verossimilhança		
	Sem realce	ImAdjust	Contrast Stretching	Sem realce	ImAdjust	Contrast Stretching
Água	0,54	1,01	0,84	1,38	1,39	1,31
Macrófita	0,05	0,05	0,04	0,01	0,01	0,01
Solo Exposto	25,71	21,90	28,28	31,71	30,29	33,03
Vegetação Nativa	44,91	42,51	62,97	52,20	54,97	52,01
Agricultura	23,82	28,09	3,56	3,19	2,76	2,50
Vegetação rala	1,61	2,24	1,55	7,74	7,08	8,26
Vazante	1,98	2,75	1,65	3,01	2,74	2,65
Nuvem	0,19	0,08	0,36	0,71	0,72	0,20
Sombra de Nuvem	1,20	1,40	0,76	0,05	0,04	0,03

Fonte: autor.

Figura 16 - Classificação do entorno do reservatório Nova Vida – resultados de todas as combinações



Fonte: autor.

Tabela 8 - Quantificação de áreas das classes (%) por combinação de método de realce e classificador – açude Nova Vida

Classes	Nova Vida					
	Minima Distância			Máxima verossimilhança		
	Sem realce	ImAdjust	Contrast Stretching	Sem realce	ImAdjust	Contrast Stretching
Água	1,63	2,71	1,15	0,61	0,61	0,50
Macrófita	0,72	0,25	1,23	0,22	0,22	0,19
Solo Exposto	43,83	37,32	47,63	47,46	47,71	49,63
Vegetação Nativa	25,86	26,69	36,09	35,00	36,19	34,97
Agricultura	18,46	18,16	5,40	3,96	2,90	2,17
Vegetação rala	3,60	6,57	2,81	4,45	4,12	4,29
Vazante	5,75	8,07	5,35	7,82	7,76	8,18
Nuvem	0,06	0,00	0,32	0,48	0,49	0,06
Sombra de Nuvem	0,08	0,23	0,01	0,00	0,00	0,01

Fonte: autor.

6 CONCLUSÕES

Através do estudo realizado, foi possível elaborar e executar algoritmos classificadores de imagens para a área dos reservatórios em estudo, localizada entre os municípios de Madalena, Boa Viagem e Quixeramobim, no estado do Ceará, utilizando diferentes combinações de métodos de pré-processamento de imagens e algoritmos de classificação. O classificador de máxima verossimilhança apresentou as mais altas taxas de concordância em relação ao método de mínima distância, obtendo como melhor resultado um coeficiente de concordância (*kappa*) de 0,63, classificado como “muito bom”.

A aplicação dos métodos de realce, por *Contrast Stretching* e *ImAdjust*, às imagens elevou o valor de *kappa* global em relação à classificação das imagens sem realce. Entretanto, é possível que o emprego de outros métodos de realce gere valores superiores de *kappa*.

A partir da análise dos resultados das imagens produzidas nas classificações (classes segmentadas), observa-se que os métodos empregados permitem classificar os diferentes usos do solo na região estudada, mas necessitam de aprimoramentos para aumentar a acurácia em relação a determinadas classes como é o caso de vegetação rala, agricultura e vazante, classes nas quais observaram-se ocorrências mais frequentes de confusão por parte do classificador durante o processo.

Dessa maneira, propõe-se como sugestão para trabalhos futuros realizar estudos de outros métodos de pré-processamento e filtragem espacial além de outras técnicas de classificação, como os algoritmos KNN (K-Nearest Neighbors) e *Random Forest*, em busca de elevar os níveis de concordância e espacialização dos resultados da classificação na área de estudo.

REFERÊNCIAS

- ACHARYA, T., RAY, A. K. **Image Processing: Principles and Applications**. John Wiley & Sons, Inc. 2005.
- AGUIAR, L. S. G. **Estimativa do escoamento superficial a partir de testes da infiltração potencial na Bacia do Ribeirão Itaim, Taubaté – SP**. 2004. 104f. Dissertação (Mestrado em Ciências Ambientais) – Departamento de Ciências Agrárias, Universidade de Taubaté, Taubaté, 2004.
- AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA; AGÊNCIA NACIONAL DE ÁGUAS. **Introdução ao Gerenciamento de Recursos Hídricos**. 2. ed. ANEEL: Brasília, 2001. 328 p;
- ARAÚJO, Efraim Martins. **Utilização do sensoriamento remoto para detecção de diferentes alvos no entorno e na bacia hidráulica de reservatórios no semiárido**. 2015. 118 f. Qualificação (Doutorado) - Curso de Engenharia Agrícola, Departamento de Engenharia Agrícola, Universidade Federal do Ceará, Fortaleza, 2015.
- ARAÚJO, J. C. D. Assoreamento em Reservatórios do Semi-árido: Modelagem e Validação. **Revista Brasileira de Recursos Hídricos**, v. 8, n. 2, p. 13, 2003.
- CIRILO, J. A. ; MONTENEGRO, S.M.G.L. ; CAMPOS, J. N. B. A questão da água no semiárido brasileiro. In: BICUDO, C. E. de M.; TUNDISI, J.G.; SCHEUENSTUHL, M.C.B.. (Org.). **Águas do Brasil análises estratégicas**. 1. ed. São Paulo: Instituto de Botânica, 2010, v. 1, p. 81-91.
- COSTA, Alexandre Cunha *et al.* Analysis of channel transmission losses in a dryland river reach in north-eastern Brazil using streamflow series, groundwater level series and multi-temporal satellite data. **Hydrol. Process.**, [s.l.], v. 27, n. 7, p.1046-1060, 27 mar. 2012. Wiley-Blackwell.
- CREUTZFELDT, B. N. A. **Remote sensing based characterisation of land cover and terrain properties for hydrological modelling in the semi-arid Northeast of Brazil**. Dissertação de mestrado – Instituto de Geoecologia, Universidade de Potsdam, Alemanha, 2006. 104f.
- FIGUEIREDO, Geíza Coutinho; VIEIRA, Carlos Antonio Oliveira. Estudo do comportamento dos índices de Exatidão Global, *Kappa* e Tau, comumente usados para avaliar a classificação de imagens do sensoriamento remoto. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007, Florianópolis. **Anais...** . Florianópolis: Inpe, 2007. p. 5755 - 5762. Disponível em: <<http://marte.sid.inpe.br/col/dpi.inpe.br/sbsr@80/2006/11.13.17.35/doc/5755-5762.pdf>>. Acesso em: 20 out. 2016.
- FOODY, G. M. On the compensation for chance agreement in image classification accuracy assessment. **Photogrammetric Engineering and Remote Sensing**, v. 58, n. 10, p. 1459-1460, 1992.

GIBBS, Holly K et al. Monitoring and estimating tropical forest carbon stocks: making REDD a reality. **Environmental Research Letters**, [s.l.], v. 2, n. 4, oct. 2007. IOP Publishing. <http://dx.doi.org/10.1088/1748-9326/2/4/045023>.

GONZALEZ, Rafael C.; WOODS, Richard E.. **Processamento digital de imagens**. 3. ed. São Paulo: Pearson Prentice Hall, 2010.

GONZALEZ, Rafael C.; WOODS, Richard E.; EDDINS, Steven L.. **Digital Image Processing Using MATLAB**. New Jersey: Pearson Prentice Hall, 2004.

GRONDONA, Atilio Efrain Bica. Avaliação da acurácia dos classificadores de máxima verossimilhança, mínima distância euclidiana e isodata na classificação de imagens da região do Pantanal. In: SIMPÓSIO DE GEOTECNOLOGIAS NO PANTANAL, 2., 2009, Corumbá. **Anais...** . Corumbá: Embrapa/inpe, 2009. p. 433 - 442. Disponível em: <<https://www.geopantanal.cnptia.embrapa.br/2009/cd/p100.pdf>>. Acesso em: 07 dez. 2016.

INSTITUTO DE PESQUISA E ESTRATÉGIA ECONÔMICA DO CEARÁ – IPECE. **Perfil básico municipal de Madalena**. Fortaleza, 2009.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE) - **Manuais**: tutorial de geoprocessamento SPRING. 2008.

MALVEIRA, V. T. C. **Pequena açudagem e sustentabilidade hidrológica em grandes bacias semi-áridas**: estudo de caso da bacia do açude Orós. Dissertação de mestrado, (Engenharia civil, área de concentração recursos hídricos) Departamento de Engenharia Hidráulica e Ambiental. 2009.

MAMEDE, G. L. ; ARAUJO, J. C. ; MEDEIROS, P. H. A. . Modelagem hidrossedimentológica de pequenos reservatórios da bacia hidrográfica do Benguê. In: Carlos Nobuyoshi Ide; Luiz Augusto Araújo do Val; Maria Lúcia Ribeiro. (Org.). **Produção de sedimentos e seus impactos ambientais**, sociais e econômicos. Campo Grande: Editora Oeste, 2009, v. , p. 393-410.

MENESES, Paulo Roberto; SANO, Edson Eyji. Classificação Pixel a Pixel de Imagens. In: MENESES, Paulo Roberto; ALMEIDA, Tati de (Org.). **Introdução ao Processamento de Imagens de Sensoriamento Remoto**. Brasília: Unb, 2012. Cap. 12. p. 191-208. Disponível em: <<https://www.infoteca.cnptia.embrapa.br/infoteca/bitstream/doc/1038449/1/meneses01.pdf>>. Acesso em: 12 set. 2016.

MOREIRA, Maurício Alves. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. 3. ed. Viçosa: Ufv, 2007.

NOVO, E. M. L. M. **Sensoriamento remoto**: princípios e aplicações. 2 ed. São Paulo: Edgard Blucher, 1998. 308 p.

PEREIRA, Rodrigou Moura et al. Avaliação da acurácia dos classificadores de máxima verossimilhança, mínima distância euclidiana e isodata na classificação de imagens da região do Pantanal. In: SEMINÁRIO DE INICIAÇÃO CIENTÍFICA, 9., 2011, Goiás. **Anais...** . Goiás: Ueg, 2011. p. 123 - 234. Disponível em:

<http://www.prp2.ueg.br/sic2011/apresentacao/trabalhos/pdf/ciencias_exatas/sic/ce_sic_comparacao_entre_os.pdf>. Acesso em: 07 dez. 2016.

PONZONI, F.J. Comportamento Espectral da Vegetação. In: MENESES, P.R.; MADEIRA NETO, J.S., (Eds.). **Sensoriamento remoto: reflectância de alvos naturais**. Brasília: UNB/ EMBRAPA, 2001.

QUEIROZ, J. E. R.; GOMES, H. M. Introdução ao Processamento Digital de Imagens. **RITA**, Volume VIII, nº 1. 2001.

MATLAB. Version 8.0.0.783 R2012b. The Mathworks, Inc. August, 2012. Disponível em: <<http://www.mathworks.com>>.

USGS - United States Geological Survey. USA. Disponível em: <http://landsat.usgs.gov/Landsat8_Using_Product.php>. Acesso em: setembro de 2016.