

**UNIVERSIDADE FEDERAL DE UBERLÂNDIA – CAMPUS MONTE
CARMELO
ENGENHARIA DE AGRIMENSURA E CARTOGRÁFICA**

ALEXANDRE FLEURY DE SIQUEIRA E GOMES

**DETECÇÃO DE MUDANÇAS NA MANCHA URBANA DE MONTE CARMELO -
MG UTILIZANDO IMAGENS MULTIESPECTRAIS.**

MONTE CARMELO

2018

ALEXANDRE FLEURY DE SIQUEIRA E GOMES

**DETECÇÃO DE MUDANÇAS NA MANCHA URBANA DE MONTE CARMELO -
MG UTILIZANDO IMAGENS MULTIESPECTRAIS.**

Trabalho de Conclusão de Curso apresentado ao curso de Engenharia de Agrimensura e Cartográfica da Universidade Federal de Uberlândia para obtenção do grau de Engenheiro Agrimensor e Cartografo.

Orientador: Prof. Dr. George Deroco Martins

MONTE CARMELO

2018

RESUMO

Monte Carmelo é um município brasileiro do estado de Minas Gerais, que tem tradicionalmente a atividade econômica ligada à produção de telhas, tijolos, artefatos cerâmicos e na produção de café. Em 2011, o campus avançado da Universidade Federal de Uberlândia se instalou na cidade, onde hoje já são ministrados cinco cursos de bacharelado. Devido a estes fatores ocorreu um crescimento na mancha urbana do município, que já é uma realidade para os moradores, porém precisa ser monitorada e analisada as necessidades de infraestrutura urbana, equipamentos sociais, serviços, entre outros componentes que compõe o plano diretor municipal. Neste sentido, estudar a intensidade da expansão é fundamental para o planejamento e articulação de políticas públicas. Dentro desta conjuntura, o uso de imagens orbitais com alta resolução espacial é uma alternativa viável e eficiente, sendo uma opção estratégica que economiza recursos financeiros, pois a partir delas é possível estimar o crescimento da mancha urbana de forma precisa. As imagens de satélites cobrem áreas extensas com uma resolução temporal regular, possibilitando obter informações espaciais e temporais de diversos alvos, muito utilizado nos estudos de detecção de mudanças. Sendo assim, o objetivo deste trabalho é analisar e quantificar o crescimento da malha urbana de Monte Carmelo, utilizando uma série temporal de imagens RapidEye, de 2011 até 2018. Para tanto foram utilizadas técnicas de pré-processamento dos dados multiespectrais, tais como: correção geométrica, correção atmosférica e calibração radiométrica. Após as influências dos erros serem minimizados e modeladas a próxima etapa foi a de classificação das imagens, sendo que o objetivo era buscar uma maneira de destacar a mancha urbana dos demais elementos da imagem, utilizou-se dois métodos de classificação: Segmentação de imagens e Redes Neurais Artificiais. No processo de segmentação de imagens foi criado uma equação, através das análises dos histogramas, que consegue segmentar a parte urbana da imagem.

Palavras-chave: mancha urbana do município, sensoriamento remoto, imagens de alta resolução espacial, detecção de mudanças, segmentação, redes neurais artificiais.

ABSTRACT

Monte Carmelo is a Brazilian municipality of the state of Minas Gerais, which traditionally has economic activity linked to the production of tiles, bricks, ceramic artifacts and coffee production. In 2011, the advanced campus of the federal university of Uberlandia settled in the city, where today five baccalaureate courses are already taught. Due to these factors, there has been a growth in the municipal, which is already a reality for residents, but needs to be monitored and analyzed the needs of urban infrastructure, social facilities, services, among other components that make up the municipal directorial plan. In this sense, studying the intensity of the expansion is fundamental for the planning and articulation of public policies. Within this context, the use of orbital images with high spatial resolution is a viable and efficient alternative, being a strategic option that saves financial resources, since from them it is possible to estimate the growth of the urban spot precisely. Satellite images cover large areas with a regular temporal resolution, providing spatial and temporal information of several targets, widely used in change detection studies. Thus, the objective of this work is to analyze and quantify the growth of the Monte Carmelo urban network, using a time series of RapidEye images, from 2011 to 2018. For this purpose, pre-processing techniques of multispectral data were used, such as: correction geometric, atmospheric correction and radiometric calibration. After the influences of the errors were minimized and modeled the next step was to classify the images, and the objective was to find a way to highlight the urban stain of the other elements of the image, using two methods of classification: Segmentation of images and Artificial Neural Networks. In the image segmentation process, an equation was created, through histograms analysis, that can segment the urban part of the image.

Keywords: Urban Spot of The Municipality, Remote Sensing, High Spatial Resolution Images, Detection of Changes, Segmentation, Artificial Neural Networks.

LISTA DE FIGURAS

Figura 1: Aumento das Universidades Federais.	7
Figura 2: Evolução da resolução espacial das imagens orbitais.....	10
Figura 3: Localização da área de estudo. (A) O Estado de Minas Gerais em destaque no mapa do Brasil. (B) A mesorregião do Triângulo Mineiro e Alto da Paranaíba em destaque no Estado de Minas Gerais. (C) O Município de Monte Carmelo em destaque na mesorregião do Triângulo Mineiro e Alto da Paranaíba. (D) A mancha urbana de Monte Carmelo em destaque no Município de Monte Carmelo.	22
Figura 4: Metodologia desenvolvida no experimento.....	24
Figura 5: Registro da imagem. Em vermelho, destaca-se os seis pontos de apoio definidos para o registro “interimagem”.....	25
Figura 6: Correção atmosférica no software ENVI. Em destaque a interface do FLAASH, onde se insere parâmetros para adaptar o modelo de correção a qualquer área de estudo.....	26
Figura 7: Imagem da área urbana de Monte Carmelo no ano de 2017, a esquerda a imagem está em seu estado bruto e na direita já com a correção FLAASH.	27
Figura 8: Imagem da área urbana de Monte Carmelo no ano de 2012, a esquerda a imagem no estado bruto, centralizado a imagem com a correção atmosférica e a direita após o processo de normalização radiométrica.	28
Figura 9: Etapas de classificação utilizando RNA no software ENVI. Interface para definição dos parâmetros “gatilhos” para classificação.	30
Figura 10: Imagem da área urbana de Monte Carmelo no ano de 2018, a esquerda é a imagem após o pré-processamento e a direita após a aplicação da equação de segmentação.	32
Figura 11: Imagem do pré-processamento da área urbana de Monte Carmelo no ano de 2011 a 2018. (A) Imagem RapidEye de 2011 no estado bruto. (B) Imagem RapidEye de 2011 após a correção atmosférica. (C) Imagem RapidEye de 2011 após a normalização radiométrica. (D) Imagem RapidEye de 2012 no estado bruto. (E) Imagem RapidEye de 2012 após a correção atmosférica. (F) Imagem RapidEye de 2012 após a normalização radiométrica. (G) Imagem RapidEye de 2013 no estado bruto. (H) Imagem RapidEye de 2013 após a correção atmosférica. (I) Imagem RapidEye de 2013 após a normalização radiométrica. (J) Imagem RapidEye de 2014 no estado bruto. (K) Imagem RapidEye de 2014 após a correção atmosférica. (L) Imagem RapidEye de 2014 após a normalização radiométrica. (M) Imagem RapidEye de 2015 no estado bruto. (N) Imagem RapidEye de 2015 após a correção atmosférica. (O) Imagem RapidEye de 2015 após a normalização radiométrica. (P) Imagem RapidEye de 2016 no estado bruto. (Q) Imagem RapidEye de 2016 após a correção atmosférica. (R) Imagem RapidEye de 2016 após a normalização radiométrica. (S) Imagem RapidEye de 2017 no estado bruto. (T) Imagem RapidEye de 2017 após a correção atmosférica. (U) Imagem RapidEye de 2017 após a normalização radiométrica. (V) Imagem RapidEye de 2018 no estado bruto. (W) Imagem RapidEye de 2018 após a correção atmosférica. (X) Imagem RapidEye de 2018 após a normalização radiométrica.	34
Figura 12: Mosaico das imagens classificadas por RNA.....	35
Figura 13: Confusão do classificador RNA, a esquerda a imagem classificada como branco a área urbana e a direita a imagem na composição RGB.	36
Figura 14: Gráfico de porcentagem de crescimento da área urbana de Monte Carmelo utilizando RNA, no eixo X está a subtração das imagens ano a ano e no eixo Y a porcentagem de crescimento da área urbana.	36
Figura 15: Gráfico de crescimento da área urbana de Monte Carmelo em metros quadrados utilizando RNA, no eixo X está a subtração das imagens ano a ano e no eixo Y o crescimento da área urbana em metros quadrados.	37
Figura 16: Mosaico de 2011 a 2018 das imagens segmentadas.....	38
Figura 17: Densificação urbana nos arredores do Campus Araras, a esquerda a segmentação da área próximo ao Campus Araras no ano de 2011 e a direita esquerda a segmentação da área próximo ao Campus Araras no ano de 2018.	38
Figura 18: Gráfico de porcentagem de crescimento da área urbana de Monte Carmelo utilizando Segmentação, no eixo X está a subtração das imagens ano a ano e no eixo Y a porcentagem de crescimento da área urbana.....	39
Figura 19: Gráfico de crescimento da área urbana de Monte Carmelo em metros quadrados utilizando segmentação, no eixo X está a subtração das imagens ano a ano e no eixo Y o crescimento da área urbana em metros quadrados.....	39
Figura 20: População de Monte Carmelo de 2011 a 2018.	40
Figura 21: Equação do crescimento da área urbana de Monte Carmelo- MG.	40

SUMÁRIO

1 CARACTERIZAÇÃO DO PROBLEMA	7
1.1 INTRODUÇÃO.....	7
1.2 HIPÓTESE E OBJETIVOS	11
1.3 JUSTIFICATIVA.....	11
2 FUNDAMENTAÇÃO TEÓRICA	12
2.1 SENSORIAMENTO REMOTO DE ÁREAS URBANAS	12
2.2 PRÉ-PROCESSAMENTO DOS DADOS MULTIESPECTRAIS	14
2.2.1 <i>Calibração Radiométrica</i>	14
2.2.2 <i>Correção Atmosférica</i>	15
2.2.3 <i>Correção Geométrica</i>	17
2.2.4 <i>Normalização Radiométrica</i>	18
2.2.5 <i>Classificação de imagens</i>	19
2.2.5.1 <i>Redes Neurais Artificiais</i>	20
2.2.5.2 <i>Segmentação</i>	21
3 METÓDO	22
3.1 ÁREA DE ESTUDO	22
3.2 MATERIAL	23
3.2.1 <i>Equipamento de laboratório</i>	23
3.2.1 <i>Imagens Multiespectrais</i>	23
3.2.3 <i>Softwares para processamento de dados e das imagens</i>	24
3.3 DESENVOLVIMENTO METODOLÓGICO	24
3.3.1 <i>Pré-Processamento de dados multiespectrais</i>	24
3.3.1.1. <i>Registro das imagens</i>	25
3.3.1.2. <i>Correção Atmosférica</i>	26
3.3.1.3. <i>Normalização Radiométrica</i>	27
3.3.2.1 <i>Redes Neurais Artificiais</i>	28
3.3.2.2 <i>Segmentação</i>	31
3.3.2 <i>Deteção de Mudanças: Representação dos Resultados</i>	32
4 RESULTADOS E DISCUSSÃO	33
4.1 DETECÇÃO DE MUDANÇAS E ANÁLISE DO CRESCIMENTO	35
4.1.1 <i>Redes Neurais Artificiais</i>	35
4.1.2 <i>Segmentação</i>	37
5 CONCLUSÃO	41
REFERÊNCIAS	42

1 CARACTERIZAÇÃO DO PROBLEMA

1.1 Introdução

O REUNI é um programa iniciado em 2003 que significa Reestruturação e Expansão das Universidades Federais, que tem como principal objetivo ampliar o acesso e a permanência na educação superior. Esse programa do governo adotou medidas para retomar o crescimento do ensino superior público, promovendo sua expansão física, acadêmica e pedagógica. O número de municípios atendidos pelas universidades federais passou de 114 em 2003 para 237 em 2010, sendo criadas 14 novas universidades e mais de 100 novos *campi*, aumentando o número de vagas para ensino superior público e novos cursos de graduação (MEC – Ministério da Educação, 2010). A Figura 1 ilustra o aumento de universidades federais ao longo do tempo.

Figura 1: Aumento das Universidades Federais.



Fonte – MEC (2010).

Segundo dados do MEC (2010), foram criados 2.428 cursos com aumento global de docentes de 49,8 mil em 2003 para 71,2 mil em 2010, dobrando o número de matrículas de graduação e pós-graduação de 596,2 mil para mais de um milhão neste mesmo período. Somente em Minas Gerais, foram criados doze *campi* neste mesmo período, sendo o campus da Universidade Federal de Uberlândia em Monte Carmelo – MG um desses doze.

Em 2011, o campus avançado da Universidade Federal de Uberlândia se instalou na cidade de Monte Carmelo, onde hoje já são ministrados cinco cursos de bacharelado. Devido a estes fatores ocorreu um crescimento na mancha urbana do município, que já é uma

realidade para os moradores, porém precisa ser monitorada e analisada as necessidades de infraestrutura urbana, equipamentos sociais, serviços, entre outros componentes que compõe o plano diretor municipal. Principalmente considerando que a cidade de Monte Carmelo é de pequeno porte e dependente da produção cafeeira, há de se esperar que a instalação de uma Universidade Federal no município cause um impacto em vários aspectos como: social, econômico e cultural.

Segundo Stephan e Latini (2014), a universidade e a cidade interagem entre si e não se pode ignorar o contexto no qual o campus está inserido, sendo que todos os aspectos físicos da universidade imprimem uma marca na estrutura, tecido e dinâmica urbana. Essa marca está nos mais diversos setores, como: fluxo de mobilidade, dinâmica social, aumento das atividades econômicas (moradia estudantil, livraria, copiadora, bares, restaurantes, hotelaria, aluguel e compra de imóvel). Sendo assim, o impacto de uma universidade pública de grande envergadura em uma cidade pequena produz efetivos econômicos imediatos, demandas de capital humano e infraestrutura antes ausentes, sendo essas condições ideais para uma transformação em um polo de crescimento regional, mas exige um planejamento a nível público e privado para absorver da melhor maneira esse impacto.

Para evitar inflação nos preços de moradia, transformação de áreas rurais em urbanas e uma queda na qualidade de vida no município, deve se estabelecer regras a essa expansão, implantando assim um sistema de planejamento e gestão urbano, que contenha uma base cartográfica que possibilite a criação de: planta genérica de valores, mapa de vetor de crescimento da cidade e mapa de quantificação do crescimento da cidade para resultar em um projeto de zoneamento para o crescimento sustentável do município. Todos esses aspectos de planejamento devem ser amplamente discutidos com diversas esferas da sociedade e estar incluídos no plano diretor do município. Para realizar esse sistema de planejamento, existe um custo envolvido para obtenção dessas informações, por isso deve ser escolhido uma estratégia de obter esses dados de maneira confiável e o mais barato possível. Deste modo, o Sensoriamento Remoto é uma alternativa viável para estudos no espaço urbano, devido a acurácia dos dados, flexibilidade temporal, cobertura espacial e adequação a modelagem e custo benefício (MESEV; LONGLEY, 1999).

Essas demandas de informações acuradas sobre a infraestrutura urbana são requisitadas por pessoas profissionais. Esse interesse acontece pelo alto valor monetário do espaço urbano. Sendo assim, não é uma surpresa o alto investimento de cidades, estados, países e empresas privadas na obtenção de informações confiáveis como fotografias aéreas e

imagens de satélites. Grande parte das informações requisitadas nesse espaço urbano não pode ser obtida simplesmente por pesquisa em loco (JENSEN, 2000).

O espaço urbano é composto por diversos materiais (concreto, asfalto, metal, plástico, vidro, água, grama, árvores e solos). Esses materiais são misturados e rearranjados em maneiras de construir casas, sistemas de transporte, espaço de recreação, espaços comerciais e industriais. O objetivo destas construções é aumentar a qualidade de vida, porém em vários casos, a urbanização aconteceu de maneira rápida e não planejada, esse crescimento desordenado pode gerar problemas ambientais recorrentes em vários municípios brasileiros, como: degradação da paisagem, sistema de transporte não compatível com a demanda, ocupação humana em áreas inadequadas, contaminação hídrica, formação de ilhas de calor, entre outros.

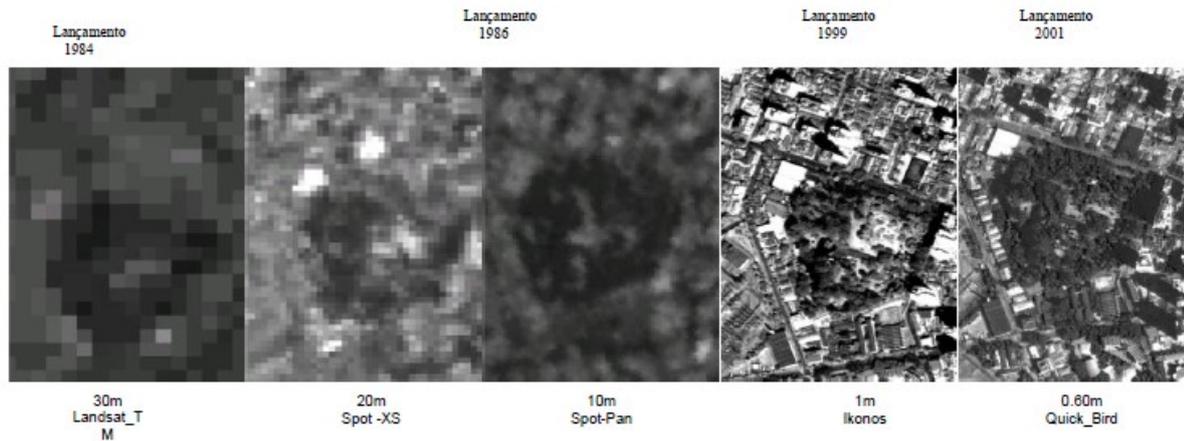
Segundo Jensen (2000), um número significativo de pessoas no âmbito privado e público, requerem constantemente informações sobre a infraestrutura urbana, por exemplo:

- Seguimento do governo que legislam sobre regulação do zoneamento urbano para melhorar a qualidade de vida na cidade.
- Seguimento do governo que legislam sobre a estimulação do comércio para estimular o desenvolvimento e aumentar impostos.
- Seguimento do governo encarregados do transporte, para manter a estrutura existente e construir de acordo com as demandas do país.
- Empresas públicas e privadas que fazem serviço ao público como: água, esgoto, eletricidade, internet, gás. Que precisam planejar um método mais eficiente e com o melhor custo benefício de disponibilizar os seus serviços.
- Seguimento do governo encarregado de emergências, responsáveis de mitigar a destruição e alocar recursos no caso de desastres.
- Seguimento no âmbito privado que precisam planejar o local ideal para indústrias, comércio e desenvolvimento residencial.

Por meio de sensores orbitais informações acuradas sobre o espaço urbano podem ser obtidas. Os sensores evoluíram em diversos aspectos, mas o aspecto de resolução temporal foi o que mais influenciou o uso de imagens orbitais em âmbitos urbanos. A Figura 2 ilustra a potencialidade desses sensores no âmbito urbano e a evolução deles ao longo do tempo, em 1984 quando foi lançado o Landsat-TM, com resolução de trinta metros, não se podia

distinguir nenhum elemento urbano na imagem, já em 1999, com o lançamento do Ikonos, com resolução de um metro, já se pode destacar diversos elementos urbanos, como: parques, sistema viário, residências e comércio. Vale destacar também que em 2009 foi lançado o sensor Worldview-2, que abriu uma nova perspectiva de estudos urbanos, no pancromático o sensor possui uma resolução espacial de 0.46 metros.

Figura 2: Evolução da resolução espacial das imagens orbitais.



Fonte – Souza (2012).

A utilização do sensoriamento remoto em estudos no meio urbano não é nenhuma novidade, existem diversos trabalhos de estudos neste sentido a nível nacional e internacional, é possível notar que com a melhoria da resolução espacial a discriminação de objetos no meio urbano ficou melhor e por consequência o detalhamento dos estudos do meio urbano aumentou.

É possível destacar alguns trabalhos de sensoriamento remoto em meio urbano que serviram de base para este trabalho: Em Pereira et al. (1984), foi utilizado imagens Landsat para mapear o crescimento urbano de São José dos Campos de 1978 a 1984, em Luchiari (2001), foi utilizado imagens do sensor Landsat para identificação de cobertura vegetal em áreas urbanas, em Pinho et al. (2005), foi utilizado imagens do sensor orbital Ikonos para classificação da cobertura do solo na cidade de São José dos Campos em São Paulo, em Wang et al. (2012) foi utilizado o Landsat para mapear o crescimento urbano da China de 1990 a 2010, em Souza e Kux (2013), foi utilizado imagens do satélite Worldview-2 para classificação da cobertura do solo no município de São Luiz do Maranhão.

1.2 Hipótese e objetivos

Considerando que a cidade de Monte Carmelo é de pequeno porte e dependente da produção cafeeira, há de se esperar que a instalação de uma Universidade Federal no município cause um impacto em vários aspectos como: social, econômico e cultural.

Sendo assim esse estudo espera responder a seguinte questão:

- A partir de técnicas de Sensoriamento Remoto, é possível mensurar o crescimento da mancha urbana em virtude da instalação da Universidade Federal de Uberlândia no município de Monte Carmelo?

Neste contexto, este trabalho tem como objetivo geral quantificar o crescimento urbano no município de Monte Carmelo, localizado no estado de Minas Gerais, utilizando imagens de sensores multiespectrais de alta resolução espacial RapidEye. Este estudo será realizado para detectar mudanças na mancha urbana do município nos anos de 2011 a 2018. Inseridos nesse contexto estão os seguintes objetivos específicos:

- Avaliar o potencial dos sensores em questão para detecção do crescimento da mancha urbana;
- Quantificar o crescimento urbano do município ao longo do tempo;

1.3 Justificativa

Devido ao alto investimento para a instalação da Universidade Federal de Uberlândia em Monte Carmelo, em conjunto com mais de 1000 vagas de alunos para graduação, técnicos e professores, que atuam diretamente na instituição de ensino, existe um potencial de gerar crescimento populacional e um impacto econômico em pequeno espaço de tempo. Devido a esse crescimento é necessário um planejamento na instalação de equipamentos públicos, rede de abastecimento, esgoto e etc. De maneira a receber essa nova demanda que se estabelece na cidade e tende a crescer ao longo do tempo.

Um estudo urbano do impacto da UFU em Monte Carmelo pode ser uma ferramenta eficiente para tomada de decisões na esfera pública e privada. Sendo assim, o estudo se justifica pela quantificação e valorização deste impacto e pode ser utilizado para estratégias de ordenamento territorial e garantir o bem-estar coletivo da população como um todo.

Existem diversas ferramentas para realizar estudos urbanos, seja por aerofotogrametria tradicional, VART (Veículo Aéreo Remotamente Tripulado) ou imagens orbitais de alta

resolução. O uso de VART apresenta um grande potencial na geração de imagens em estudos urbanos, pois possuem alta resolução temporal, alta resolução espacial, sobrevoo abaixo de nuvens, fácil aquisição das imagens aéreas, entre outros. Porém, vários fatores devem ser empregados para a utilização dessa técnica, como: alto custo de equipamentos e softwares, baixa área de sobrevoo devido autonomia da bateria, uma vez que para sobrevoar grandes áreas há necessidade de vários dias de campo, aumentando o custo do planejamento de voo. A aerofotogrametria tradicional é uma boa ferramenta para estudos urbanos, porém o alto custo pode ser um empecilho para os municípios contarem com essa técnica.

Um dos fatores que viabiliza este estudo de áreas urbanas e torna as imagens provenientes de sensores orbitais como a solução de maior custo benefício é a disponibilização gratuita das imagens *RapidEye* pelo Ministério do Meio Ambiente para servidores públicos. Esses dados podem ser utilizados para diversas aplicações, como: análise da vegetação, água, urbano, solos, minerais, geomorfológicos e outros. Desta maneira, avaliar esses dados para detecção de mudanças no espaço urbano e estudar o impacto do fluxo universitário e de servidores dentro da cidade Monte Carmelo - MG é necessário e viável para o estabelecimento de políticas direcionadas a instalação de um plano diretor municipal.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Sensoriamento remoto de áreas urbanas

A tecnologia do sensoriamento remoto moderno começou com a invenção da câmara, mais de 150 anos atrás, e agora uma grande variedade de sistemas de sensoriamento remoto já foram desenvolvidas para detectar e mensurar porções de energia de diferentes regiões do espectro eletromagnético. Segundo Yang (2011), o sensoriamento remoto pode nos ajudar a entender diversos aspectos das áreas urbanas, com a capacidade de obter imagens que cobrem uma grande área, possibilitando identificar objetos e entender melhor a interação do homem com a terra no espaço urbano.

O sensoriamento remoto é uma alternativa viável para não depender de dados de levantamentos que são morosos e custam mais, as imagens podem detectar coisas que os olhos humanos não podem, por coletar energia do infravermelho, ultravioleta e micro-ondas, ajudando assim a ter um conhecimento que vai além da percepção humana. A capacidade de revisita dos sensores possibilita construir uma série temporal para comprar e detectar as

mudanças ao longo do espaço e tempo, ajudando a analisar os processos antrópicos e naturais no espaço urbano (YANG, 2011).

Para avaliar se uma imagem de sensoriamento remoto pode ser utilizada no espaço urbano é necessário estudar as características temporais, espectrais e espaciais da imagem. Existem variáveis há se considerar quando vai se determinar a resolução temporal adequada para o estudo em questão, o progresso do espaço urbano e sua velocidade é uma delas. Segundo Jensen (2000), os estágios de desenvolvimento de áreas residenciais são:

- Limpeza parcial ou completa da terra da vegetação nativa;
- Divisão territorial;
- Estradas de terra ou pavimentadas;
- Construções;
- Paisagismo.

Com isso, a presença ou ausência desses fatores indicam o estágio de desenvolvimento de áreas residenciais, portanto, o analista deve entender esse ciclo de desenvolvimento para analisar se o sistema/sensor em questão possui um tempo de revisita adequado de modo a acompanhar o desenvolvimento urbano. Sensores que podem ser apontados para off-nadir possuem um tempo de revisita significativamente menor do que sensores que só apontam para o nadir. Porém, a dinâmica do crescimento urbano não é tão alta, somente em situações especiais, que é necessário um tempo de revisita menor como nos estudos de contagem de tráfego e emergências. Deste modo, a maioria dos estudos urbanos em sensoriamento remoto podem ser feitos com a revisita em um prazo de um ano (JENSEN, 2000).

Geralmente quanto maior a resolução espacial de dados de sensoriamento remoto, maior será o detalhamento da informação que pode ser obtida de ambientes urbanos. Porém, é preciso adotar critérios específicos para cada tipo de estudo urbano. Existem vários tipos de critérios que podem ser utilizados, alguns mais usuais e outros não, como: critério NIIRS (*National image interpretation rating scales*), média ponderada de resolução de área, resolução espacial nominal, entre outros. O critério de resolução espacial nominal é bastante usual por civis, devido a seu conceito de fácil compreensão, estabelecendo uma relação entre o tipo de extração que pode ser extraído e a resolução espacial da imagem em questão. O tamanho mínimo do pixel que pode ser trabalhado deve ser metade do menor objeto de interesse, ou seja, para identificar um objeto de 5 metros, a resolução espacial mínima para

identificar esse objeto é 2,5 metros. Para mais detalhes sobre os critérios para definição de resolução espacial, consultar Jensen (2000).

Quando se trata de extrair informação do espaço urbano com dados de sensoriamento remoto, a resolução espacial é mais importante do que a resolução espectral. Para estimar a população, baseado em unidades de construções, requer usualmente uma resolução espacial de 0,25m a 5m. Nessa resolução espacial seria suficiente para detectar praticamente qualquer banda do visível (0,4 – 0,7 μm). Porém, deve haver um contraste espectral suficiente entre o objeto de interesse e seu entorno para detectar. Enquanto dados hiperespectrais não são requisitos para estudos na área urbana, existem espaços do espectro eletromagnético que são extremamente úteis para extrair informações urbanas. Por exemplo, informações sobre a cobertura terrestre urbana são melhor adquiridas utilizando o visível, infravermelho próximo (0,7 – 1,1 μm) e/ou regiões pancromáticas (0,5 - 0,7 μm) do espectro. Cálculo de área, perímetro de construções e informações de altura são melhor adquiridas utilizando o preto e branco pancromático (0,5 - 0,7 μm) ou o visível (0,4 – 0,7 μm). Sensores ativos de micro-ondas podem obter imagens de áreas urbanas nubladas (JENSEN, 2000).

2.2 Pré-Processamento dos dados multiespectrais

Os erros são inerentes ao processo de aquisição de imagens, esses erros podem ser geométricos ou radiométricos, afetando os valores digitais dos pixels, propagando erros ao produto caso não sejam corrigidos ou modelados, seja na distribuição de níveis digitais da imagem e/ou variação relativa de nível digital de um dado pixel que não condiz com o alvo da cena. Esses erros podem ser resultantes de influência atmosférica ou/e dos instrumentos utilizados na tomada de imagem (NOVO, 2010). Desta maneira, esses erros devem ser estudados, conhecidos e minimizados pelo analista que vai tratar as mesmas, para de acordo com a aplicação do estudo, realizar as calibrações e correções necessárias para tornar a imagem mais próxima de representar a realidade.

2.2.1 Calibração Radiométrica

A imagem no seu estado bruto contém deteriorações radiométricas, por causa de erros de transmissão, influência atmosférica e de inadequações na calibração de detectores. Sendo assim, a calibração radiométrica de imagens tem como objetivo corrigir essas degradações, consistindo em uma das etapas mais importantes do pré-processamento de dados

multiespectrais, pois, a não remoção destes erros, influência no produto final (D'ALGE, 2001).

Existem vários erros radiométricos no processo de obtenção da imagem, os principais são: *Stripping*, o desajuste de calibração dos sensores pode gerar um padrão sistemático de linhas horizontais, e o *dropedlines*, que consiste na falta de informações em linhas das imagens devido a transmissão e/ou gravação defeituosa (NOVO, 2010).

Quando se trabalha com uma imagem multiespectral, os números digitais (ND) devem ser convertidos em parâmetros físicos, como a radiância e reflectância, pois cada sensor, em cada banda, possui um critério próprio para discretizar os valores de radiância medidos na escala específica de sua resolução radiométrica. Essa característica gera uma incompatibilidade entre os NDs registrados, tornando inviável a comparação entre NDs de bandas diferentes e impossibilitando a caracterização espectral de objetos (MARTINS, 2016).

O processo utilizado para correção da incompatibilidade é converter os números digitais de uma imagem em valores de radiância aparente. Segundo Novo (2010), a equação que corresponde ao processo é a equação 1:

$$L_0(\lambda) = (Lmin(\lambda) + \frac{(Lmax(\lambda) + Lmin(\lambda))}{2^x}) + ND(\lambda) \quad (1)$$

Onde:

- x = número de bits;
- $Lmax(\lambda)$ = valor máximo de radiância;
- $Lmin(\lambda)$ = valor mínimo de radiância;
- $L_0(\lambda)$ = valor de radiância aparente;
- ND = Números digitais.

Depois de realizar o processo de conversão de números digitais para valores de radiância aparente, assume-se que os dados de diferentes bandas de um mesmo sensor ou de sensores diferentes, podem ser comparados entre si (MARTINS, 2016).

2.2.2 Correção Atmosférica

Segundo Novo (2010), os efeitos atmosféricos sobre as imagens se devem à redução de contraste entre os objetos de uma dada cena e na dificuldade de detecção de pequenos objetos dentro de uma cena, principalmente entre objetos que possuem pequenas variações na

intensidade do sinal. A correção dos efeitos atmosféricos é importante em três casos específicos, sendo eles:

- Quando se deseja conhecer a reflectância, emitância ou retroespalhamento do objeto em estudo;
- Quando se utiliza algoritmos que se baseiem em operações aritméticas entre bandas;
- Quando se compara imagens de diferentes datas, em termos das propriedades dos objetos na cena.

No caso de o estudo em questão não se encaixar nesses casos acima, é melhor não corrigir os dados, sendo que, ao invés de remover os erros atmosféricos, existe a possibilidade de introduzir erros ao conjunto de dados (NOVO, 2010).

Em geral, são desconhecidos os parâmetros atmosféricos necessários para correção de forma completa, somente com todos os dados é possível estimar a influência de espalhamento e absorção da camada atmosférica em todos os comprimentos de onda, permitindo assim relacionar o número digital de um pixel em cada banda aos valores reais de reflectância do alvo (NOVO, 2010).

A atmosfera degrada as imagens dependendo do comprimento de onda, comprometendo assim a análise e interpretação das mesmas. A sua correção pode ser feita por um modelo matemático, porém, os parâmetros atmosféricos necessários para aplicar o modelo geralmente são desconhecidos. Sendo assim, outras estratégias podem ser aplicadas, gerando bons resultados. Uma delas é o método do Mínimo Histograma, este método pode ser resumido em identificar nas imagens, áreas de corpos d'água, áreas com sombras de relevo ou sombras de nuvens, ou seja, pontos nas imagens onde a radiância possui valor igual a zero, os valores encontrados nesses alvos são considerados influência do espalhamento atmosférico e subtraído dos valores digitais de toda cena, na respectiva banda (D'ALGE, 2001).

Outro método que pode ser aplicado para correção atmosférica de imagens é o *FLAASH* (Análise atmosférica rápida da linha de visão de Hipercubos), que consiste em um algoritmo baseado no MODTRAN4, que executa a correção devido ao espalhamento de superfície e também calcula a visibilidade média da cena (aerossol/névoa) (ENVI, 2003), esse método é utilizado apenas em sensores multiespectrais e hiperespectrais, devido a utilização dos comprimentos de onda do infravermelho (até 3 μm) para corrigir as ondas da região do visível. O *FLAASH* pode corrigir imagens tomadas do nadir e inclinadas. Vale destacar, que

só é possível recuperar as imagens de influências de vapor d'água e aerossóis quando a imagem possui os comprimentos de ondas apropriados (HARRIS, 2017).

2.2.3 Correção Geométrica

A existência de distorções sistemáticas adquiridas na tomada das imagens é a principal motivação para se realizar a correção geométrica (D'ALGE, 2001). Por esse motivo a importância de corrigir geometricamente uma imagem é de remover erros sistemáticos presentes na mesma. A correção geométrica é recomendada principalmente em estudos multi-temporais para que se possa interpretar a resposta de ambas imagens para uma certa posição no espaço (NOVO, 2010).

Segundo D'Alge (2001) os fatores mais relevantes que afetam a geometria das imagens são:

- Rotação terrestre, o movimento relativo entre a terra e o satélite desloca as imagens, sendo imprescindível compensar o posicionamento das varreduras;
- Distorções panorâmicas, originada pela variação do IFOV (*instantaneous field of view*), devido a inclinação os pixels situados a nadir são menores em relação aos pixels das bordas laterais, porque o IFOV é um ângulo fixo;
- Curvatura Terrestre intensifica a distorção panorâmica, comprimindo os dados nas bordas das imagens;
- Variações de efemérides e atitude da plataforma, no sentido longitudinal, transversais e nas linhas.

Uma transformação geométrica abundantemente utilizada é o registro, que consiste em relacionar coordenadas da imagem com coordenadas geográficas, esse procedimento é utilizado para eliminar distorções existentes na imagem, sendo indicado no caso de integração de imagens provenientes de sensores diferentes, imagens obtidas em tempos diferentes, imagens tomadas em posições diferentes e mosaico de imagens (INPE, 2017).

Dentro do âmbito de utilização de várias imagens de um mesmo local, para fazer uma análise temporal, é preciso assegurar que a justaposição dos pixels seja feita. Mesmo utilizando somente um sensor, a bordo de um satélite, a justaposição dos pixels não pode ser ignorada, devido a distorções ligados a movimentação do satélite. Sendo assim, antes de realizar uma análise temporal, se faz necessário o registro entre as imagens. Existem duas maneiras de registrar imagens: manual e automático (D'ALGE, 2001).

O modo automático consiste em um algoritmo de análise de similaridade entre imagens, essa análise é feita com base no deslocamento relativo entre as mesmas. Já o registro manual, se baseia em pontos de controle no terreno, encontrar pontos homólogos nas imagens de interesse.

Dentro do âmbito da correção geométrica da imagem, um dos processos importantes é o georreferenciamento da imagem. Segundo Queiroz (2003), esse processo é fundamental para várias situações práticas dentro da área de sensoriamento remoto, tais como: integração de uma imagem à base de dados existente num SIG; aplicação na área de cartografia, uso da terra, geografia, fusão de imagens adquiridas por sensores diferentes, aplicações relacionadas com a combinação de imagens sobre uma grande área (mosaico) e na análise de imagens tomadas em épocas diferentes.

De uma maneira geral, o processo de georreferenciamento de imagens compreende três grandes etapas. Começa-se com uma transformação geométrica, também denominada mapeamento direto, que estabelece uma relação entre coordenadas de imagem (linha e coluna) e coordenadas geográficas (latitude e longitude). Em seguida faz-se o mapeamento inverso, que inverte a transformação geométrica usada no mapeamento direto, permitindo que se retorne à imagem original para que se definam os níveis de cinza que comporão a imagem corrigida. Esta definição de níveis de cinza ocorre na última etapa, chamada de reamostragem, que nada mais é que uma interpolação sobre os níveis de cinza da imagem original.

2.2.4 Normalização Radiométrica

Uma das etapas do pré-processamento das imagens é a normalização radiométrica, que tem como objetivo uniformizar a resposta espectral dos alvos considerados invariantes ao longo do tempo, essa etapa deve ser realizada antes da geração de mosaicos, monitoramento ao longo do tempo de alvos e outras aplicações (ESCOBAR, 2015).

A normalização radiométrica minimiza discrepâncias radiométricas entre imagens, essas discrepâncias ocorrem devido a inconsistências de condições de aquisição da imagem e não devido a mudanças reais de cobertura na terra. O princípio dessa técnica parte do pressuposto de uma linearidade entre a radiância do sensor adquirido em dois momentos diferentes de regiões com reflectância constante. O processo de normalização radiométrica inicia com a aquisição de um conjunto de dados de controle composto por valores de reflectância invariantes ao longo do tempo. A partir deste conjunto de dados são calculadas funções de transformação linear que, posteriormente, são utilizadas na geração de uma nova

imagem que apresenta compatibilidade espectral com aquela que foi definida como de referência (RAMIREZ; ANDERSON; FORMAGGIO, 2015).

Para realizar essa normalização é feito uma regressão linear entre as imagens multiespectrais em uma série temporal, utilizando uma imagem como referência. Os Pontos pseudo-invariantes (PIFs), são pixels que pouco variam na série temporal, utilizados como pontos de controle no processo de normalização radiométrica (MALUF et al., 2015). Através da aplicação da normalização radiométrica pretende-se obter um produto que fique próximo de ser adquiridos pelo mesmo sensor e com as mesmas condições atmosféricas e de iluminação da imagem de referência.

A equação utilizada para normalização radiométrica das imagens é a Equação 2:

$$IR = \frac{(Br_i - Dr_i)}{(Bs_i - Ds_i)} * IN + \frac{(Dr_i * Bs_i - Ds_i * Br_i)}{(Bs_i - Ds_i)} \quad (2)$$

Onde:

- IR = Imagem de Referência;
- IN = Imagem Normalizada;
- Br = pixel mais claro da imagem de referência;
- Dr = pixel mais escuro da imagem de referência;
- Bs = pixel mais claro da imagem a ser normalizada.
- Ds = pixel mais escuro da imagem a ser normalizada.

2.2.5 Classificação de imagens

O processo de rotular cada pixel em função de suas propriedades espectrais e/ou espaciais é chamado genericamente de “classificação”. O alvo de interesse possui um comportamento espectral, que pode ser associado ao seu brilho (nível digital) em cada uma das bandas (NOVO, 2010). Por isso é possível classificar pixels que possuem comportamento espectral semelhante e cataloga-los desta maneira.

Na classificação de imagens pode ter ou não a iteração humana no processo, a classificação não supervisionada não é necessário ter conhecimento prévio do que se está classificando, porém é necessário analisar e comparar o resultado desta classificação com dados levantados, mapas ou literatura sobre o comportamento espectral do alvo (NOVO, 2010).

A classificação não supervisionada pode ser utilizada para conhecer o número de classes espectrais existentes na área de estudo, existem diversos métodos de classificação não supervisionada, como: K-means, Isodata e ISOSEG. Para mais detalhes consultar Novo (2010), D'Alge (2001), Jensen (1986).

Já a classificação supervisionada por um analista, se baseia no conhecimento prévio sobre a localização espacial de amostras de interesse, sendo este o principal pressuposto da classificação supervisionada, a descrição da classe espectral seja feita por amostras. Segundo Novo (2010), existem aspectos fundamentais que devem ser avaliados pelo analista para realizar a classificação supervisionada, sendo eles:

- Seleção de canais;
- Localização precisa das áreas de treinamento do algoritmo;
- Relação entre o tipo de objeto e seu nível digital em cada banda;
- Avaliação da classificação realizada.

A seleção de canais é utilizada para selecionar o melhor e menor conjunto de canais necessários para discriminar os alvos e que não comprometa a precisão da classificação, sendo assim, eliminar canais que não fornecem informações úteis, através de algoritmos ou correlação entre bandas (NOVO, 2010).

A seleção de amostras é uma parte fundamental do processo de classificação de imagens, pelo fato de estar treinando o algoritmo, o analista fornece amostras da classe de interesse para o algoritmo, para o mesmo procurar no resto da imagem, então a qualidade da amostra está diretamente relacionada com o produto gerado.

Após toda classificação de imagens, seja ela supervisionada ou não, é necessário realizar uma avaliação da exatidão da classificação, ou seja, comparar a classificação gerado com a realidade, sendo assim essa análise depende de dados de campo. Para mais detalhes sobre avaliação da exatidão da classificação consultar Fidalgo (1995).

2.2.5.1 Redes Neurais Artificiais

Segundo Carvalho (2011), Redes Neurais Artificiais (RNA), pode ser definido como técnicas computacionais que utilizam um modelo matemático inspirado na estrutura neural dos organismos inteligentes, que adquirem conhecimento através da experiência. Já no contexto da análise espacial, as RNA são técnicas de inferência que utilizam modelos empíricos para estabelecer relacionamentos espaciais entre as variáveis de estudo, sendo

implementadas a partir de um conjunto de dados observados e do conhecimento do especialista sobre o fenômeno estudado (GALO, 2010).

O algoritmo de treinamento mais utilizado no aprendizado supervisionado de Redes Neurais Artificiais é o *backpropagation*. Por meio deste algoritmo é possível ajustar os pesos de cada camada da rede e é projetado para minimizar o erro médio quadrático entre a saída calculada em uma arquitetura multicamadas e a saída desejada. O componente essencial do algoritmo é o método iterativo que propaga regressivamente o erro requerido para adaptar os pesos, a partir dos neurônios da camada de saída para os nós das camadas precedentes (GALO, 2010).

No treinamento de uma rede neural multicamadas, pode-se definir o erro total E_Q entre as respostas esperadas r_q e as respostas obtidas O_q em cada um dos nós da camada de saída Q, conforme descrito na equação 3:

$$E_Q = 1/2 \sum_{q=1}^{N_Q} (r_q - O_q)^2 \quad (3)$$

Após o treinamento da RNA a classificação de todos os padrões usando o conjunto de pesos ajustados é feita associando um dado padrão como pertencente a uma determinada classe, quando a saída para essa classe for “alta”, e “baixa” para as demais classes (GONZALES & WOODS, 1993).

2.2.5.2 Segmentação

A segmentação é um processo, de forma automática ou manual, que permite um agrupamento de pixels com características homogêneas (BRITES et al., 2012). Esse processo permite segregar a imagem em regiões com propriedades espectrais semelhantes (FLORENZANO, 2011). Assim, a segmentação prepara a imagem para uma classificação posterior com base nas regiões que apresentam características semelhantes e não com valores individuais dos pixels (BRITES et al., 2012).

Para Brites et al. (2012), esse procedimento foi desenvolvido devido à evolução dos sensores imageadores, uma vez que com o aumento da resolução espacial, os componentes da imagem passaram a ser melhores identificados. Dessa maneira, na prática, a segmentação segue dois limiares. O primeiro chamado de similaridade, onde são definidos os valores de pixels a serem agrupados em uma única região, sendo “o valor máximo para a Distância

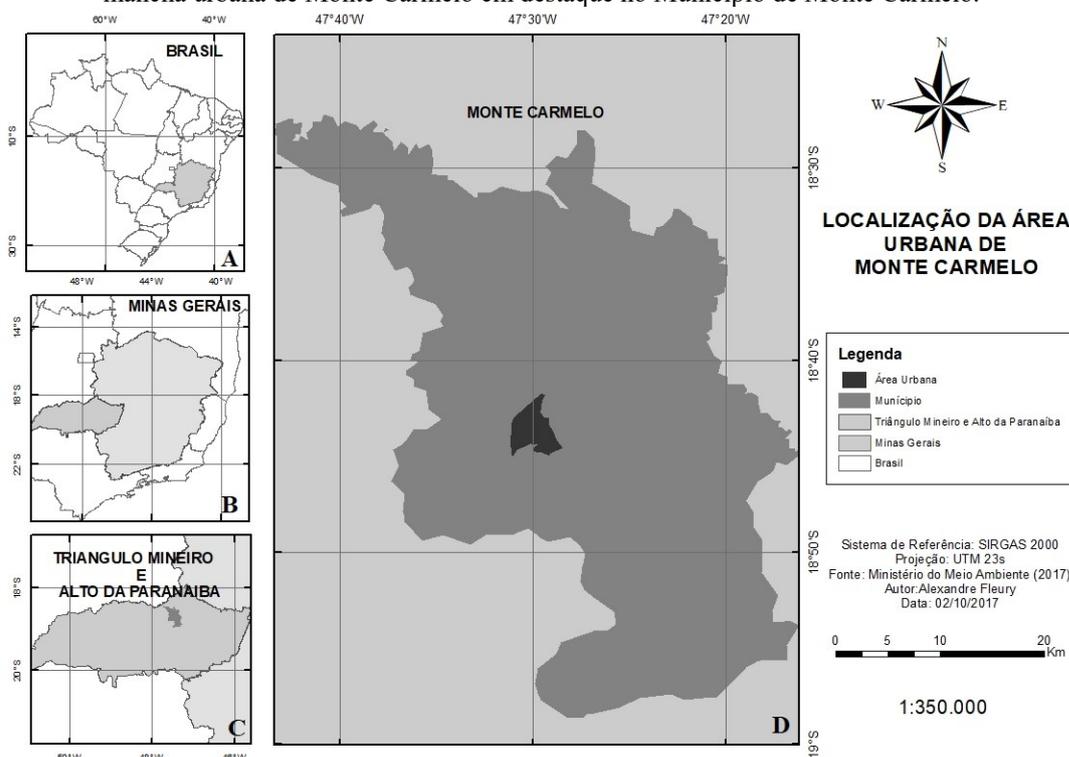
Euclidiana entre a média dos pixels componentes do segmento e qualquer pixel candidato”. O segundo é definido de área, sendo esse representado pelo valor de área mínima para que a região seja individualizada (FLORENZANO, 2011). Esse processo se torna mais difícil em imagens que apresentam diversos objetos com características distintas, como é o caso na segmentação de áreas urbanas, onde fatores como uso do solo, construções, lagos, vegetação, resultam na utilização de vários processos de classificação, gerando diversos limiares de similaridade (BRITES et al., 2012).

3 METÓDO

3.1 Área de Estudo

A área de estudo (Figura 3) é a mancha urbana do município de Monte Carmelo situado no estado de Minas Gerais. Segundo o Instituto Brasileiro de Geografia e Estatística (IBGE) em 2016 o município contava com 48.096 habitantes, com a principal atividade econômica ligada a telhas, tijolos e produção de café. A área urbana de Monte Carmelo - MG tem uma área de aproximadamente 50 quilômetros quadrados.

Figura 3: Localização da área de estudo. (A) O Estado de Minas Gerais em destaque no mapa do Brasil. (B) A mesorregião do Triângulo Mineiro e Alto da Paranaíba em destaque no Estado de Minas Gerais. (C) O Município de Monte Carmelo em destaque na mesorregião do Triângulo Mineiro e Alto da Paranaíba. (D) A mancha urbana de Monte Carmelo em destaque no Município de Monte Carmelo.



3.2 Material

3.2.1 Equipamento de laboratório

O processamento das imagens digitais foi realizado em um *Notebook Dell Inspiron 15*, Intel Core i7-7500U, 8GB de memória RAM, 1TB HD e sistema operacional de 64 bits;

3.3.1 Imagens Multiespectrais

As imagens multiespectrais do sensor *RapidEye* foram obtidas anualmente, de 2011 a 2018, adquiridas no Nadir. O sistema *RapidEye* foi lançado em 2008, composto por uma constelação de cinco satélites de observação terrestre, cada um destes satélites está posicionado em órbita síncrona com o sol, com igual espaçamento entre eles e efetuando 15 voltas por dia em torno do planeta cada um, juntos conseguem coletar imagens de aproximadamente 4,5 milhões de km² por dia. O sensor é do tipo *pushbroom*, scanner de linha, capaz de capturar imagens em cinco bandas espectrais, descrito no Quadro 1, possui uma resolução espacial original de 6,5m e após a ortorretificação as bandas são reamostradas para uma resolução de 5m, possui também uma resolução radiométrica de 12 bits, a precisão do sensor é compatível com escala 1:25.000, tempo de revisita no nadir é de 5,5 dias e off-nadir o tempo de revisita é diário (FELIX; KAZMIERCZAK; ESPINDOLA, 2009).

Quadro 1 – Resolução Espectral do Sensor RapidEye.

Resolução Espectral	
Azul (nm)	440 -510
Verde (nm)	520 - 590
Vermelho (nm)	630- 690
Red Edge (nm)	690 - 730
Infravermelho próximo (nm)	760 - 880

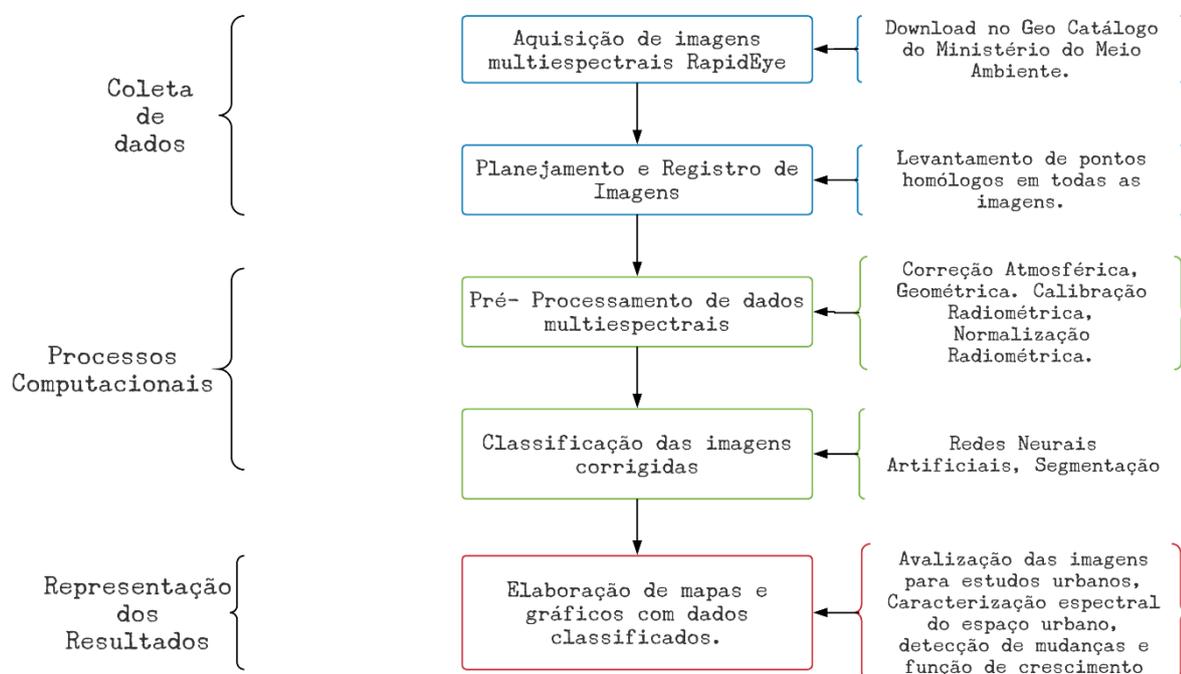
3.2.3 Softwares para processamento de dados e das imagens

Os *softwares* utilizados foram: ENVI 5.0 (*Environment for Visualizing Images*) utilizado para o pré-processamento e classificação das imagens multiespectrais; ArcGis 10 utilizado para organização dos mapas temáticos.

3.3 Desenvolvimento metodológico

A sequência da metodologia aplicada neste estudo está ilustrada na Figura 4, assim as etapas foram divididas em três partes, sendo: Coleta de dados em azul, Processos Computacionais em verde e Representação dos Resultados em vermelho.

Figura 4: Metodologia desenvolvida no experimento.



3.3.1 Pré-Processamento de dados multiespectrais

As imagens multiespectrais RapidEye foram obtidas a partir das plataformas online: Geo Catálogo do Ministério do Meio Ambiente (cinco imagens: 2011 a 2015) e *PlanetLabs* (três imagens: 2016 a 2018). A etapa de pré-processamento foi estabelecida de forma que fosse possível transformar as imagens em estado “bruto” (números digitais) para o formato “físico” (reflectância de superfície). Deve-se ressaltar que esta etapa é de suma importância, uma vez que se remove parte dos erros sistemáticos envolvidos na aquisição da Imagem

como: geometria da imagem, influência atmosférica (absorção e espalhamento) e deteriorações radiométricas.

3.3.1.1. Registro das imagens

Como objetivo era realizar uma análise temporal de imagens, a primeira etapa foi o registro de imagens, onde houve a correção geométrica dos dados multitemporais. O registro das imagens foi feito adotando uma imagem como referência. Neste caso, a imagem de 2017 foi escolhida e as outras imagens foram registradas em função dela, onde foram determinados pontos homólogos entre o dado *Raster* de referência e os a serem registrados.

Para garantir um processo preciso, o registro foi realizado a partir da equivalência de 6 pontos homólogos entre a imagem de referência e as registradas utilizando a transformação afim, os pontos foram distribuídos espaçados para garantir o escalonamento da imagem, conforme a Figura 5. Deve-se ressaltar que se definiu uma acurácia (Erro Médio Quadrático) submétrica para que a transformação entre os sistemas fosse possível.

Figura 5: Registro da imagem. Em vermelho, destaca-se os seis pontos de apoio definidos para o registro “interimagem”.



3.3.1.2. Correção Atmosférica

Na etapa de correção atmosférica, as imagens foram submetidas ao processo de correção atmosférica do software ENVI. A metodologia escolhida para a correção foi a implementada na rotina FLAASH, a qual é indicada para corrigir imagens multiespectrais de média e alta resolução espacial.

Para utilização deste método foi necessário conhecer o comprimento de onda de cada banda da imagem e indicá-los no cabeçalho da imagem. Após esse procedimento foi necessário converter a imagem para o formato Bil, o qual é definido como formato padrão para ativar o módulo de correção FLAASH, conforme descrito na Figura 6.

Além da padronização de formatos de leitura, alguns parâmetros foram informados para ajustar o modelo “empírico” de correção atmosférica implementado no módulo FLAASH. Para tanto, empiricamente foi definido um fator de escala 1000 para todas as imagens corrigidas, especificado o tipo de sensor, a data e horário de aquisição da imagem, altitude do terreno, coordenada central da cena, tamanho do pixel e altitude do sensor.

Figura 6: Correção atmosférica no software ENVI. Em destaque a interface do FLAASH, onde se insere parâmetros para adaptar o modelo de correção a qualquer área de estudo.

FLAASH Atmospheric Correction Model Input Parameters

Input Radiance Image: C:\Users\Alexa\OneDrive\Documentos\ENVI\output\2011_bil

Output Reflectance File: C:\Program Files (x86)\ITT\IDL71\lib\hook\

Output Directory for FLAASH Files: C:\Program Files (x86)\ITT\IDL71\lib\hook\

Rootname for FLAASH Files:

Scene Center Location: DD <-> DMS

Sensor Type: RapidEye

Flight Date: Aug 30 2011

Lat: 7927551

Lon: 236476.0000000

Sensor Altitude (km): 630.000

Ground Elevation (km): 900.000

Pixel Size (m): 5.000

Flight Time GMT (HH:MM:SS): 14:21:32

Atmospheric Model: Tropical

Aerosol Model: Urban

Water Retrieval: No

Aerosol Retrieval: 2-Band (K-T)

Water Column Multiplier: 1.00

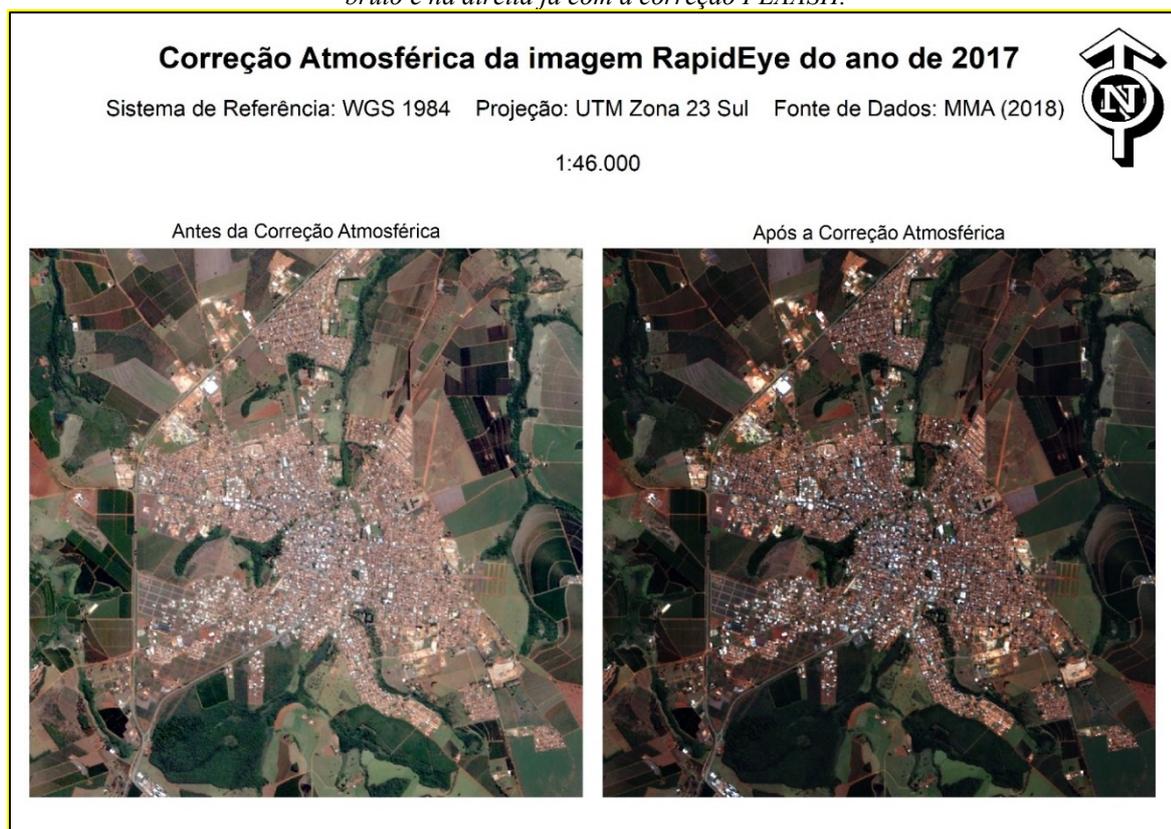
Initial Visibility (km): 40.00

Apply Cancel Help Multispectral Settings... Advanced Settings... Save... Restore...

Por ser um método empírico, este processo em diversas ocasiões pode não ser possível de ser aplicado em sensores disponíveis, porém, neste estudo esses procedimentos foram

feitos para todas as imagens com relativo sucesso pois as imagens não apresentaram valor de reflectância menor que zero (sujeito a avaliação em outros estudos). Sem um propósito físico, apenas para ilustração, visualmente é possível perceber uma nítida diferença de iluminação entre a imagem “bruta” (números digitais) e a “corrigida” e depois da correção FLAASH, conforme exposta na Figura 7.

Figura 7: Imagem da área urbana de Monte Carmelo no ano de 2017, a esquerda a imagem está em seu estado bruto e na direita já com a correção FLAASH.

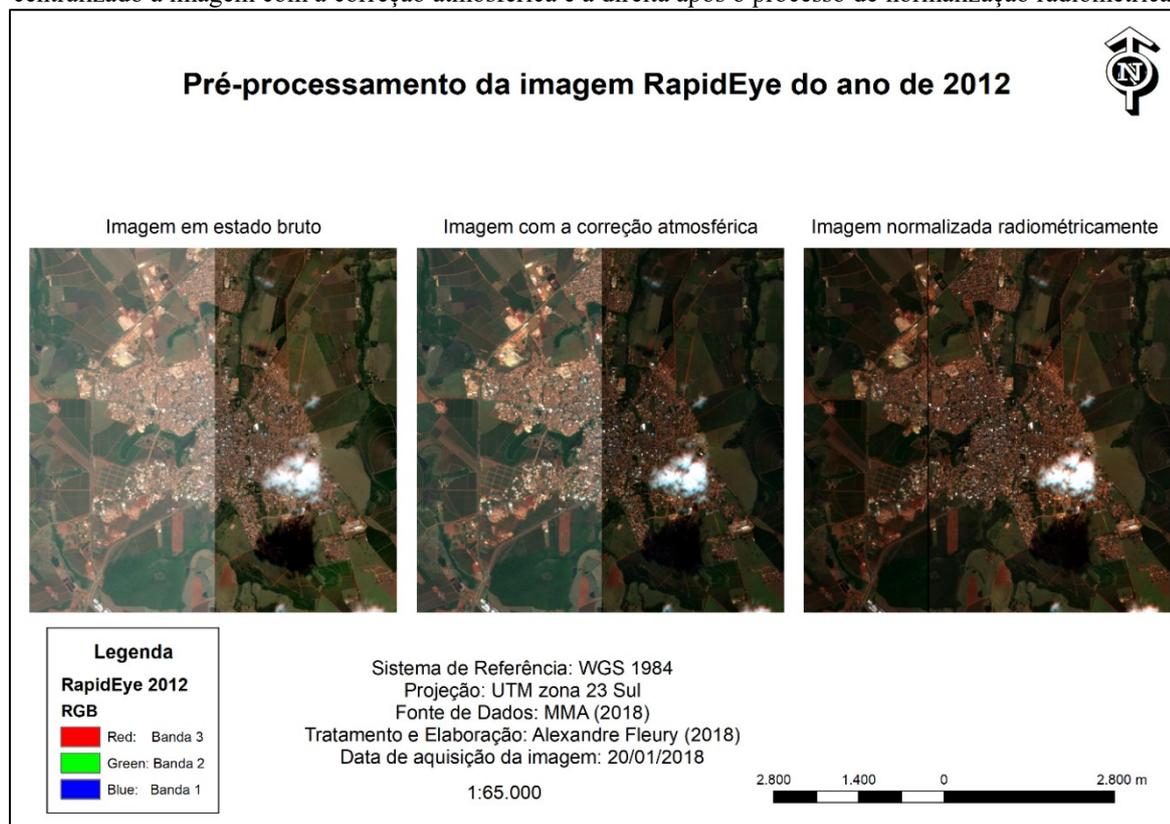


3.3.1.3. Normalização Radiométrica

Posteriormente a correção atmosférica, a próxima etapa do pré-processamento foi garantir a homogeneidade radiométrica do conjunto de imagens multitemporais. A homogeneização radiométrica foi realizada com uma metodologia multivariada de normalização de intervalos, tendo uma imagem como referência para a normalização das demais. Nesta ocasião a imagem de 2017 foi utilizada como referência, dada a uma superior qualidade radiométrica aferida visualmente a partir de espectros de reflectância.

. A normalização foi executada banda a banda em todas as imagens, onde foi necessário definir uma função individual de normalização para os distintos canais. Apenas para fins de demonstração, na Figura 8 é possível perceber a mudança visual de uma composição de “cor verdade” resultante de cada etapa de pré-processamento.

Figura 8: Imagem da área urbana de Monte Carmelo no ano de 2012, a esquerda a imagem no estado bruto, centralizado a imagem com a correção atmosférica e a direita após o processo de normalização radiométrica.



3.3.2.1 Redes Neurais Artificiais

Após as etapas de pré-processamento das imagens, duas estratégias foram definidas para separar ou mesmo discriminar a mancha urbana das demais classes de informação presentes na imagem. As duas estratégias foram à classificação da imagem por redes neurais artificiais (RNA) e a segmentação de pixels homólogos.

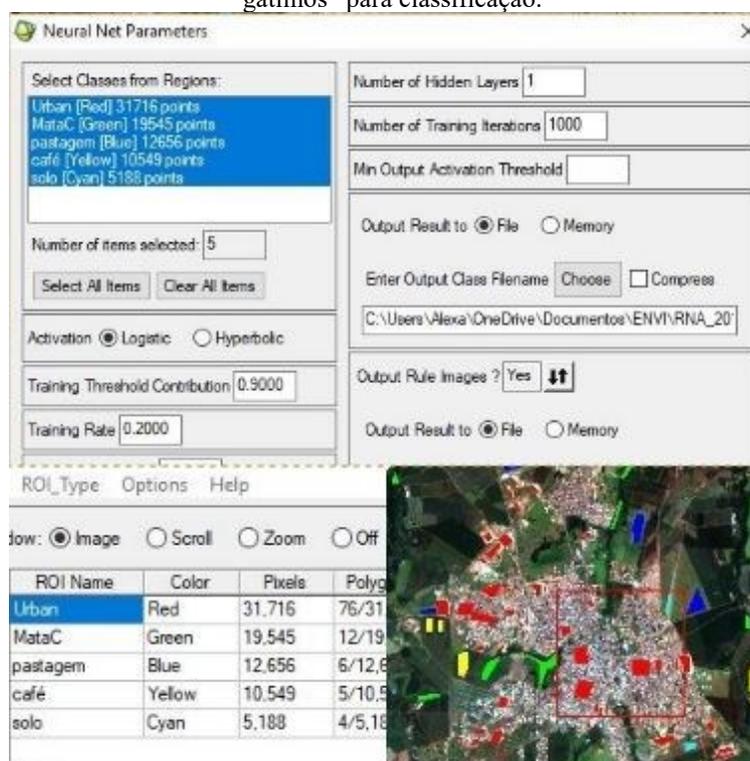
A RNA foi utilizada para discriminar cinco classes de informação nas imagens pré-processadas, sendo: Área Urbana (mancha urbana), Pastagem, Café, Solo Exposto e Mata Ciliar. Assim, foi realizado o treinamento rigoroso de amostras de cada uma das classes previamente definidas. Majoritariamente, para classe de área urbana foram definidos 30 mil pixels, pois era a classe de maior interesse, já em pastagem, café e mata ciliar foram

amostradas no mínimo 10 mil pixels ano a ano e por último o solo exposto no mínimo 5000. Existem parâmetros que devem ser definidos para definir como a rede neural artificial vai operar, cada um desses parâmetros deve ser analisado e definido de acordo com a aplicação em questão, abaixo será explicado um pouco de cada parâmetro:

- *Training Threshold Contribution Field*: um campo que varia de 0 a 1 e O limiar de treino contribuição determina o tamanho da contribuição do peso interno em relação ao nível de ativação do nó. Ele é usado para ajustar as alterações no peso interno de um nó. O treinamento algoritmo interativamente ajusta os pesos entre os nós e, opcionalmente, os limites do nó para minimize o erro entre a camada de saída e a resposta desejada. Definindo o valor do *Training Threshold Contribution* em 0 não ajusta os pesos internos do nó. Ajustes dos pesos internos dos nós podem levar a melhores classificações, mas um valor próximo de 1 pode levar a generalizações pobres. Na classificação deste trabalho foi adotado o valor 0,9, para que o ajuste dos pesos internos seja feitos e levar a uma melhor classificação.
- *Training Rate Field*: um campo que varia de 0 a 1 e determina a magnitude do ajuste dos pesos, uma taxa mais alta irá acelerar o treinamento, mas também aumentará risco de oscilações ou não convergência do resultado do treinamento. Na classificação deste trabalho foi adotado o valor 0,2, com esse valor a classificação fica mais demorada, porém garante que o resultado do treinamento vai convergir.
- *Training Momentum Field*: um campo que varia de 0 a 1, inserindo uma taxa de momentum maior do que zero permite que você defina uma taxa de treinamento mais alta sem oscilações. Uma maior taxa de momentum treina com passos maiores do que uma taxa de momentum menor. Seu efeito é incentivar mudanças de peso ao longo da direção atual. Na classificação deste trabalho foi adotado o valor 0,9, com o objetivo de obter uma taxa de treinamento alta e sem oscilações.

- *Training RMS Exit Criteria Field*: insira o valor de erro do RMS no qual o treinamento deve ser interrompido. Na classificação deste trabalho foi adotado o valor 0,1, com um valor de saída baixo garante que as mil iterações do RNA sejam realizadas.
- *Number of Hidden Layers*: Para uma classificação linear, insira um valor de 0. Com camadas ocultas as diferentes regiões de entrada devem ser linearmente separáveis com um único hiperplano. Não linear as classificações são realizadas definindo o Número de Camadas Ocultas para um valor de 1 ou maior. Quando as regiões de entrada são linearmente inseparáveis e requerem dois hiperplanos para separar as classes você deve ter pelo menos uma camada oculta para resolver o problema. Duas camadas ocultas são usadas para classificar o espaço de entrada onde os diferentes elementos não são contíguos ou conectados. Na classificação deste trabalho foi adotado o valor 1, devido a não linearidade do objeto de estudo.

Figura 9: Etapas de classificação utilizando RNA no software ENVI. Interface para definição dos parâmetros “gatilhos” para classificação.



3.3.2.2 Segmentação

Após avaliar a resposta da área urbana nas cinco bandas presente no sensor RapidEye, a banda do vermelho, foi utilizado a mesma para desenvolver uma equação geral de segmentação de áreas urbanas. Deve-se ressaltar que esta escolha é oportuna, uma vez que, há alta resposta do concreto e do solo exposto e a baixa resposta da vegetação neste comprimento de onda (JENSEN, 2006).

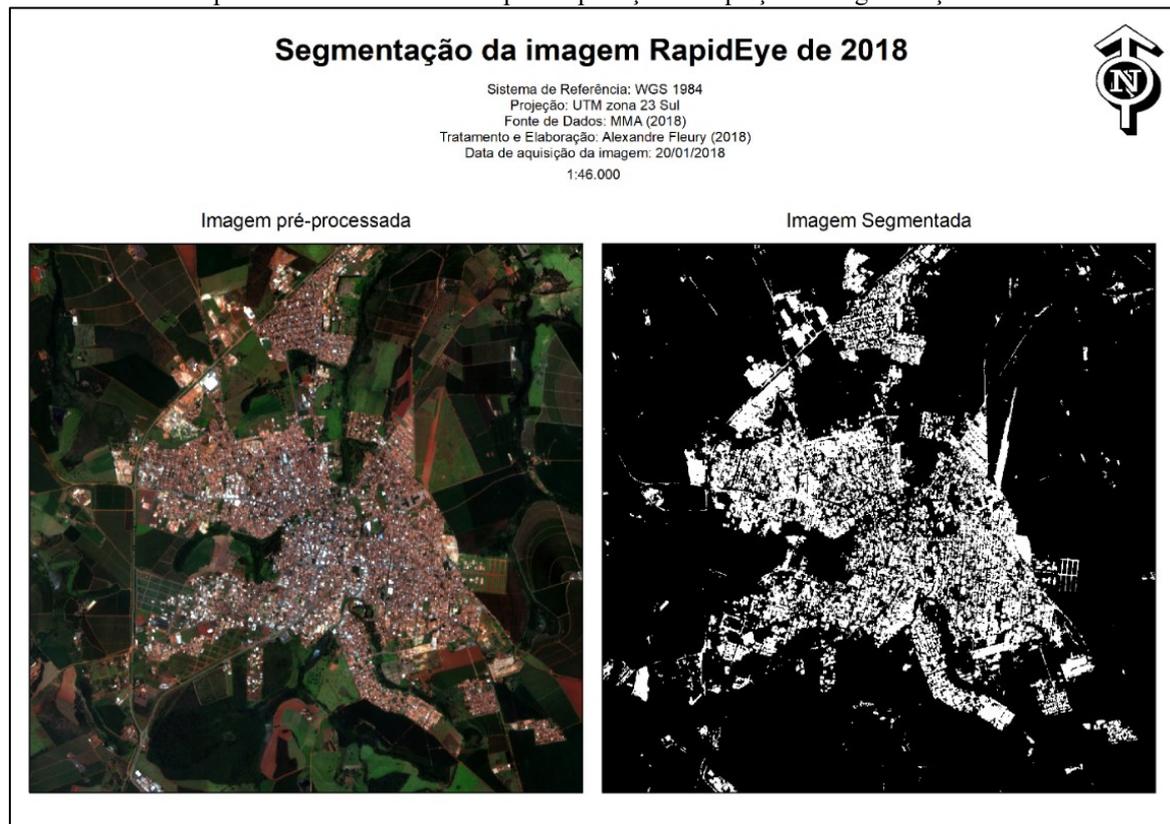
Através da análise dos histogramas da banda do vermelho foi possível observar uma tendência dos pixels conter área urbana a um sigma (desvio padrão) “positivo” da média da média dos valores de brilho. Assim, após essa constatação formalizou-se a segmentação para discriminação da área urbana, conforme a equação 4.

$$Es = \sum \frac{x_i}{n} + \sqrt{\sum \frac{(x_i - \bar{x})^2}{n - 1}} \quad (4)$$

Onde:

- x_i = i-ésimo pixel da banda vermelha;
- n = número de pixels;
- \bar{x} = média dos pixels da banda vermelha;
- Es = Equação geral de segmentação de áreas urbanas;
- Para representação da mancha urbana optou-se pela cor branca e os demais alvos como fundo preto conforme a Figura 10.

Figura 10: Imagem da área urbana de Monte Carmelo no ano de 2018, a esquerda é a imagem após o pré-processamento e a direita após a aplicação da equação de segmentação.



3.3.2 Detecção de Mudanças: Representação dos Resultados

Após a discriminação da mancha urbana pelas distintas técnicas de processamento de imagens, foi possível avaliar o potencial dos sensores *RapidEye* para estudos de detecção do crescimento da mancha urbana. Para tanto a discriminando das feições urbanas de interesse foi realizada com a detecção de mudança por subtração de imagens.

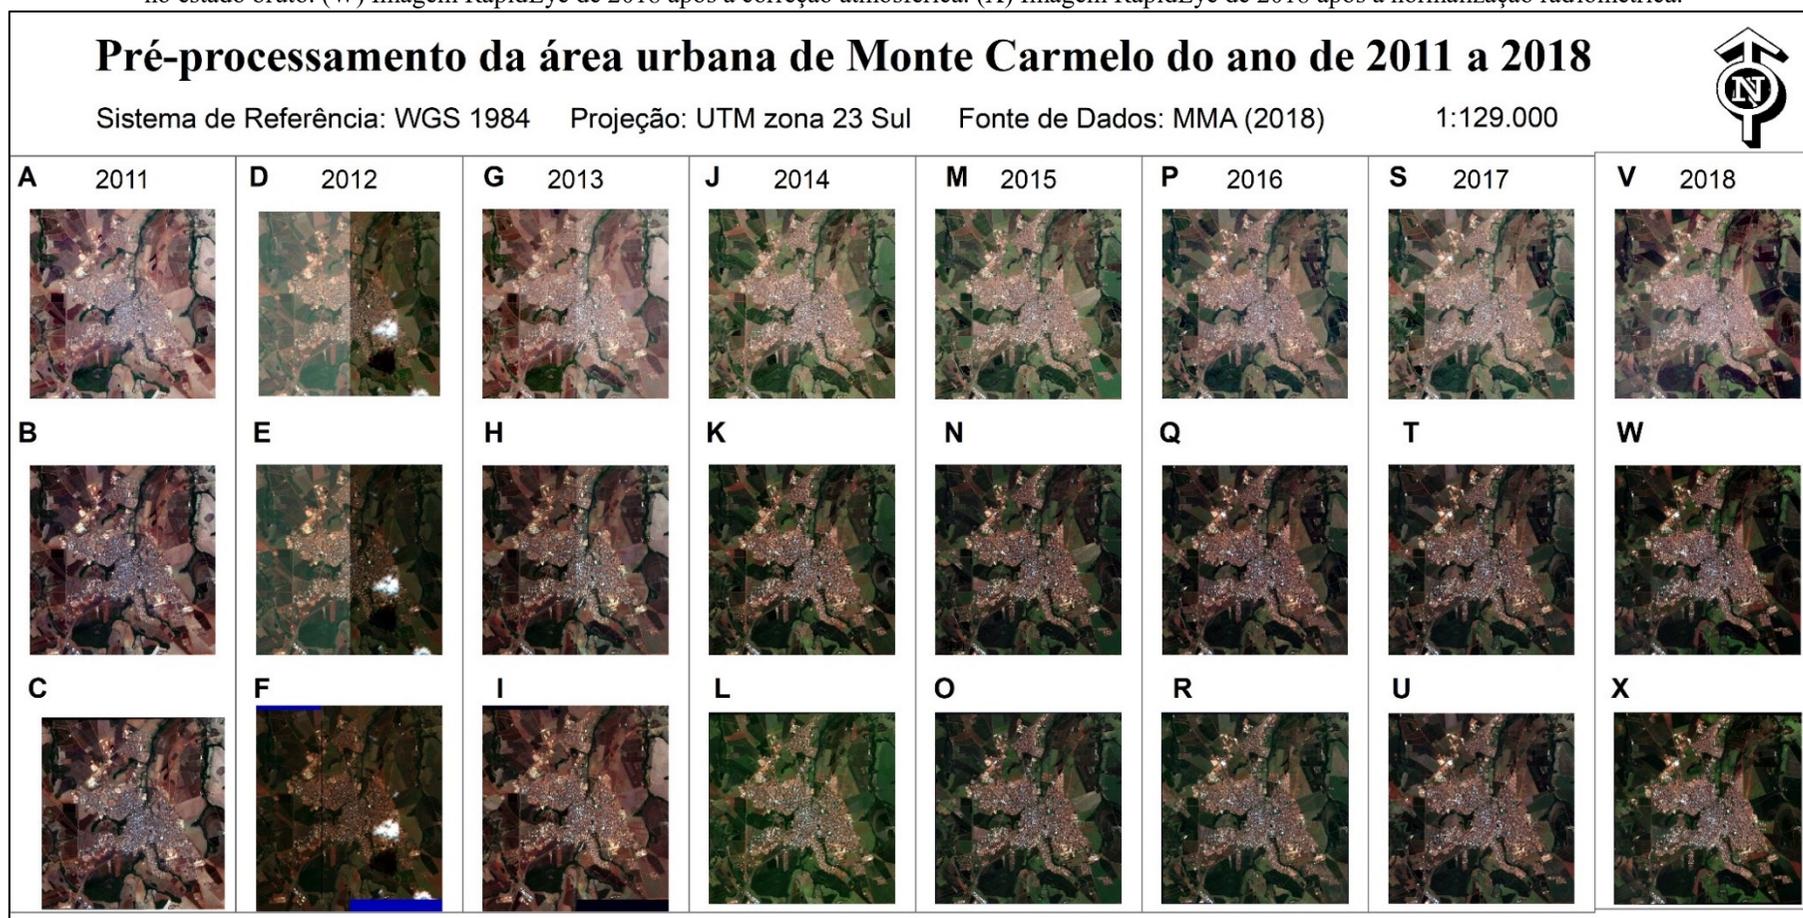
A subtração de imagens de imagens foi realizada aos pares, por exemplo, a imagem do ano de 2018 menos a de 2017, essa subtração resultava no crescimento urbano de um ano para o outro e esse processo foi realizado sucessivamente até a imagem do ano de 2012 menos a de 2011. Ressalta-se que essa subtração fora realizada tanto as pares de imagens classificadas e segmentadas, ou seja, foi possível avaliar extrair informações de crescimento a partir das duas técnicas. A representação do crescimento urbano do município ao longo dos anos, foram realizadas através de gráficos e mapas provenientes das imagens classificadas por RNA e segmentação, ambos representando o aumento da área urbana do município de 2011 para 2018

4 RESULTADOS E DISCUSSÃO

Após o pré-processamento das imagens, foi possível minimizar os erros inerentes a aquisição das imagens, para que sua influência não seja propagada para o produto gerado. Essa etapa foi necessária devido a finalidade do estudo, as calibrações e correções tornam a imagem mais próxima da realidade. O impacto deste pré-processamento é ilustrado nas Figuras 11.

A partir da Figura 11, é possível visualizar a deterioração radiométrica e a influência atmosférica que possuem nas imagens. Após as etapas de pré-processamento é notório a melhoria do contraste entre os objetos, principalmente nos objetos que possuem pequenas variações na intensidade do sinal. A utilização desta metodologia de correção viabilizou a classificação ser mais acurada e destacar o objeto de interesse deste estudo que é a área urbana. A imagem do ano de 2017 não possui a normalização, porque a mesma foi utilizada como referência para normalizar as imagens. Vale destacar que nos anos de 2012 e 2013 é visualmente nítido a importância da normalização radiométrica das imagens.

Figura 11: Imagem do pré-processamento da área urbana de Monte Carmelo no ano de 2011 a 2018. (A) Imagem RapidEye de 2011 no estado bruto. (B) Imagem RapidEye de 2011 após a correção atmosférica. (C) Imagem RapidEye de 2011 após a normalização radiométrica. (D) Imagem RapidEye de 2012 no estado bruto. (E) Imagem RapidEye de 2012 após a correção atmosférica. (F) Imagem RapidEye de 2012 após a normalização radiométrica. (G) Imagem RapidEye de 2013 no estado bruto. (H) Imagem RapidEye de 2013 após a correção atmosférica. (I) Imagem RapidEye de 2013 após a normalização radiométrica. (J) Imagem RapidEye de 2014 no estado bruto. (K) Imagem RapidEye de 2014 após a correção atmosférica. (L) Imagem RapidEye de 2014 após a normalização radiométrica. (M) Imagem RapidEye de 2015 no estado bruto. (N) Imagem RapidEye de 2015 após a correção atmosférica. (O) Imagem RapidEye de 2015 após a normalização radiométrica. (P) Imagem RapidEye de 2016 no estado bruto. (Q) Imagem RapidEye de 2016 após a correção atmosférica. (R) Imagem RapidEye de 2016 após a normalização radiométrica. (S) Imagem RapidEye de 2017 no estado bruto. (T) Imagem RapidEye de 2017 após a correção atmosférica. (U) Imagem RapidEye de 2017 após a normalização radiométrica. (V) Imagem RapidEye de 2018 no estado bruto. (W) Imagem RapidEye de 2018 após a correção atmosférica. (X) Imagem RapidEye de 2018 após a normalização radiométrica.

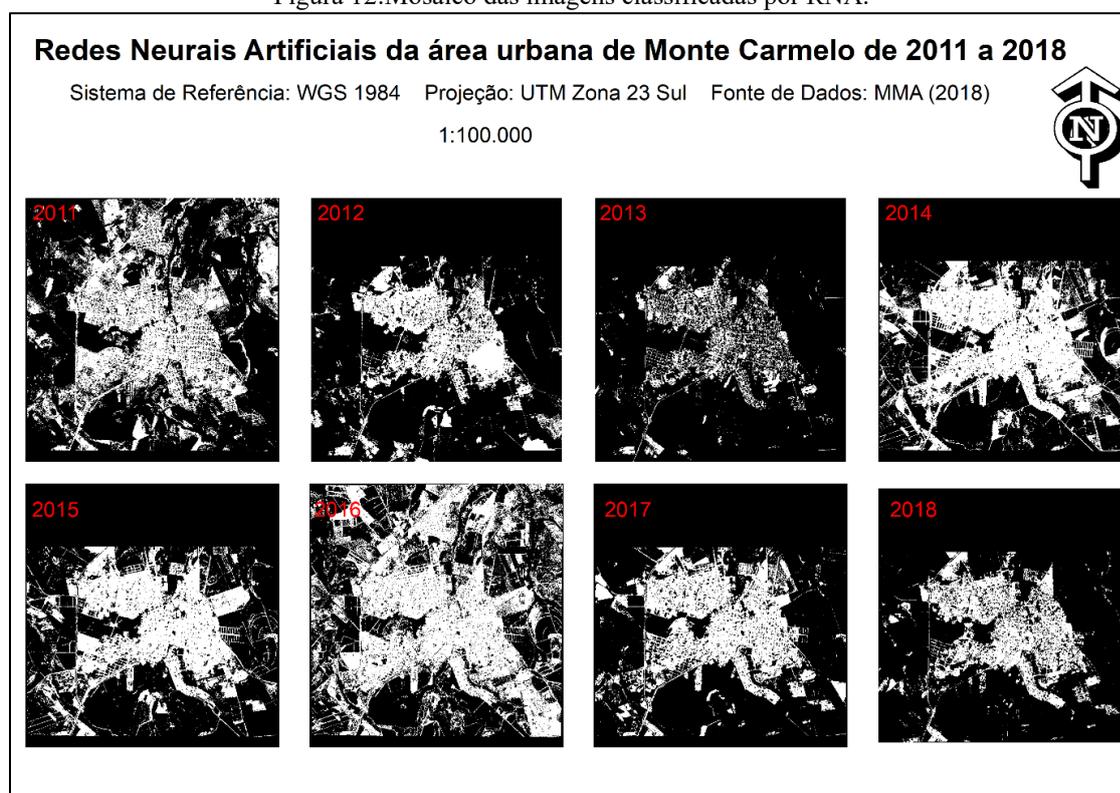


4.1 Detecção de mudanças e análise do crescimento

4.1.1 Redes Neurais Artificiais

A RNA foi aplicada para todas as imagens que foram pré-processadas, com o seu resultado foi possível gerar gráficos e mapas de detecções de mudanças, visando principalmente a malha urbana (Figura 12, 14 e 15). Na Figura 12 é possível ver o resultado das classificações por RNA de 2011 a 2018, destacando que não fica claro a densificação da malha urbana ao longo dos anos.

Figura 12: Mosaico das imagens classificadas por RNA.

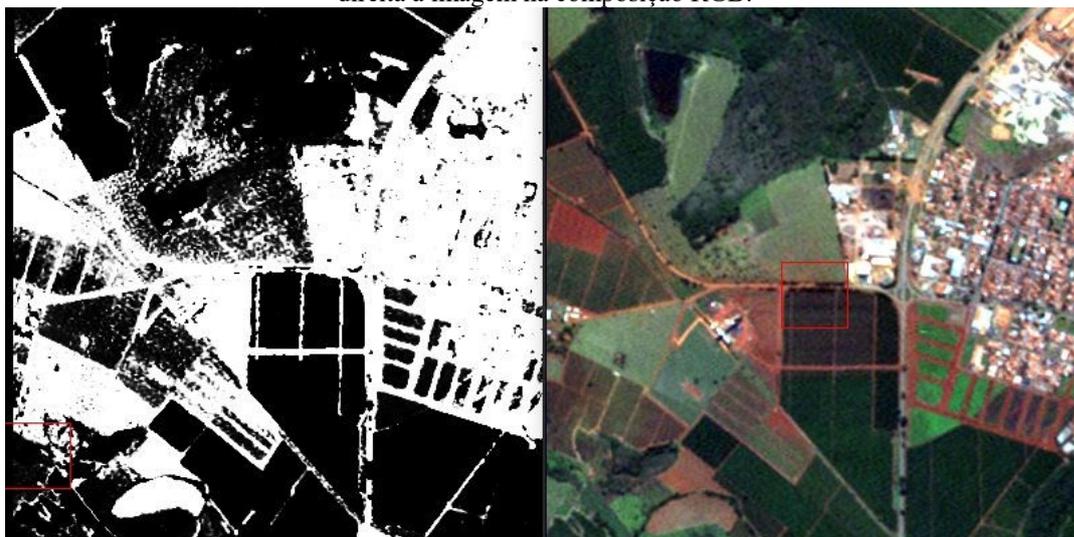


É notório que houve uma confusão de classes e que isso atrapalhou nos dados de crescimento gerados por esse método. A confusão de solo exposto com área urbana pode ser explicada devido a semelhança espectral do solo com os telhados das casas. Dentro da literatura é possível encontrar trabalhos que também encontraram problemas no momento de classificar classes com semelhança espectral utilizando classificadores pixel a pixel. Em Pinho et al. (2015), houve confusão em dois pares de classes que apresentam cobertura espectral semelhantes: Cobertura Cerâmica x Solo Exposto e Água Pavimentação x Concreto/Amianto Escuro. Neste mesmo trabalho foi sugerido a utilização de classificadores por regiões ou objetos para minimizar essa confusão. Sendo assim é importante frisar que a

imagem de alta resolução não é aconselhado utilizar classificadores pixel a pixel e sim por regiões.

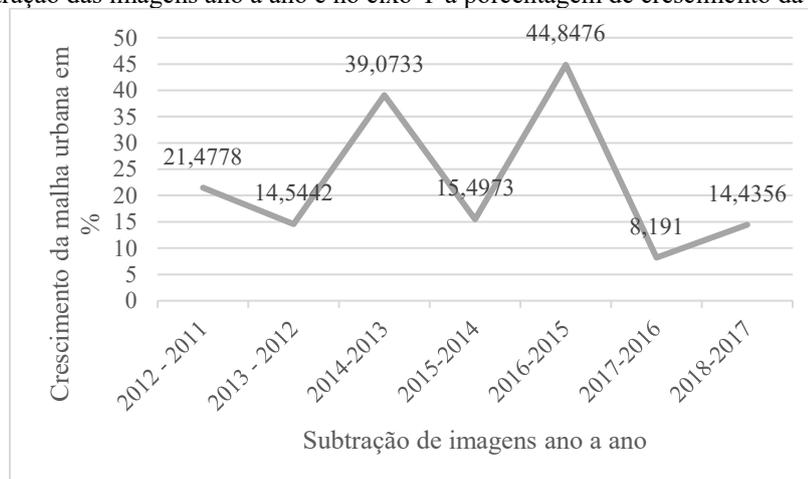
Na Figura 13, ao lado esquerdo está a imagem binária classificada por RNA, em branco é ilustrado o que o classificador entendeu como área urbana e de preto tudo que não é área urbana, é possível notar que existe confusão de regiões com solo exposto com área urbana comparando com a imagem a direita que é a imagem de entrada antes da classificação.

Figura 13: Confusão do classificador RNA, a esquerda a imagem classificada como branco a área urbana e a direita a imagem na composição RGB.



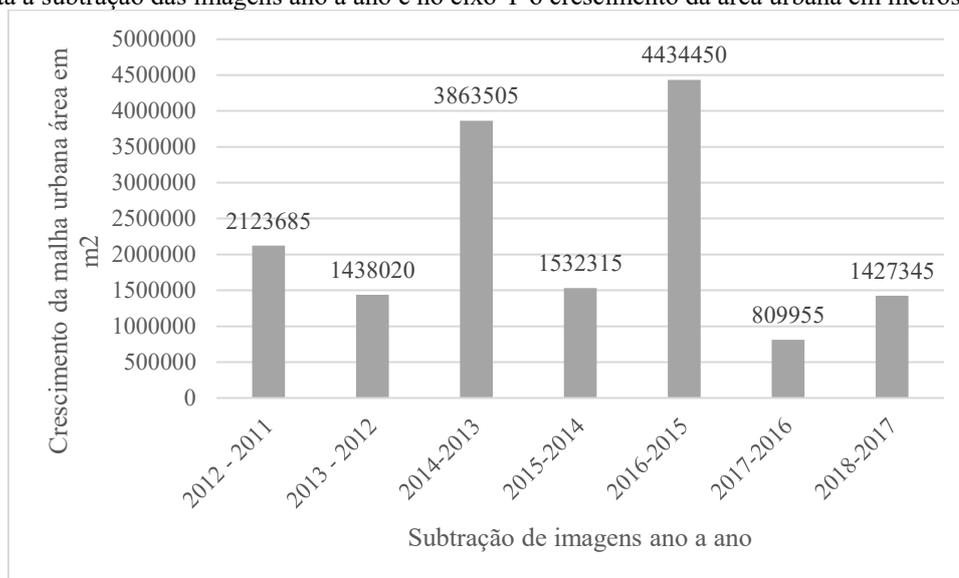
Devido a essa confusão do classificador para discriminar os alvos a detecção de mudanças apresenta valores atípicos, sendo assim, esse fator deve ser levado em consideração na hora de interpretar as taxas de crescimento em porcentagem ou em área apresentados na Figura 14 e 15 respectivamente.

Figura 14: Gráfico de porcentagem de crescimento da área urbana de Monte Carmelo utilizando RNA, no eixo X está a subtração das imagens ano a ano e no eixo Y a porcentagem de crescimento da área urbana.



Devido a confusão do classificador as taxas de crescimento da cidade em determinados anos são bastante altas, como de 2016 – 2015 que chega a 44% de aumento da manchar urbana. Apesar da confusão da classificação utilizando RNA, é possível comparar o comportamento da curva de crescimento com a obtida pela segmentação (Figura 17), ambas possuem um comportamento não linear, existindo assim uma oscilação entre um ano e outro.

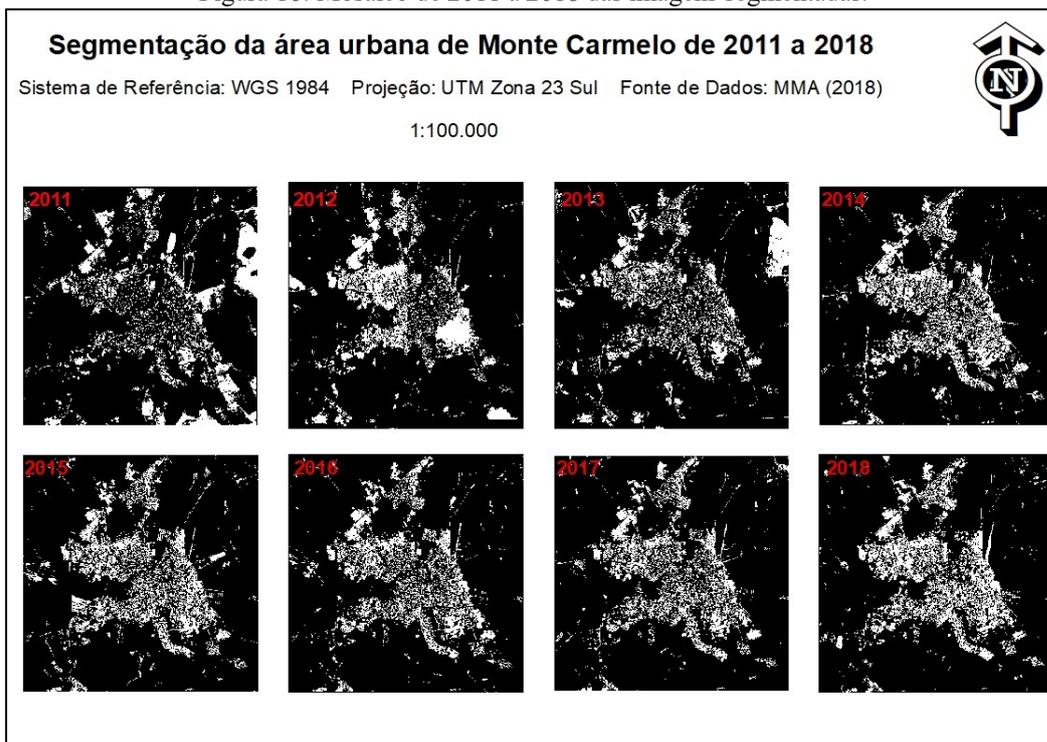
Figura 15: Gráfico de crescimento da área urbana de Monte Carmelo em metros quadrados utilizando RNA, no eixo X está a subtração das imagens ano a ano e no eixo Y o crescimento da área urbana em metros quadrados.



4.1.2 Segmentação

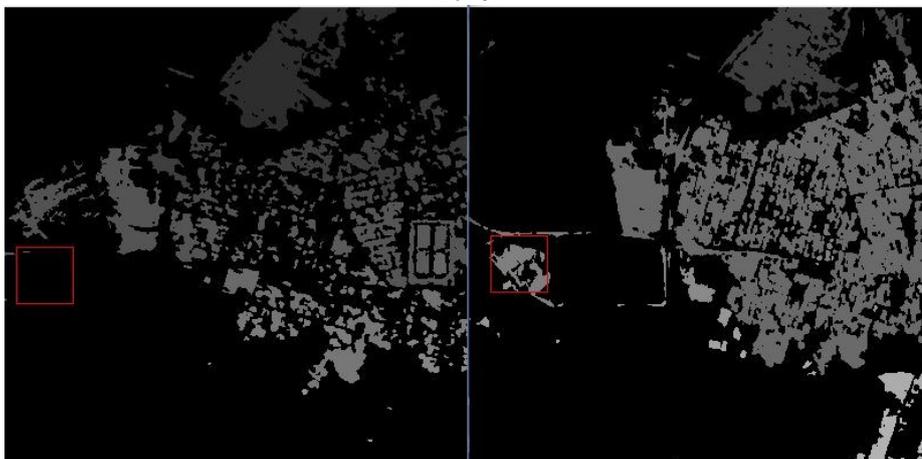
Com a aplicação da equação de segmentação para todas as imagens, foi possível destacar a área urbana e detectar as mudanças de uma imagem de um ano para outro. A Figura 16 é um mosaico das imagens segmentadas, através da equação de segmentação, ano a ano, podendo visualizar a densificação da área urbana ao longo do tempo na cidade de Monte Carmelo – MG.

Figura 16: Mosaico de 2011 a 2018 das imagens segmentadas.



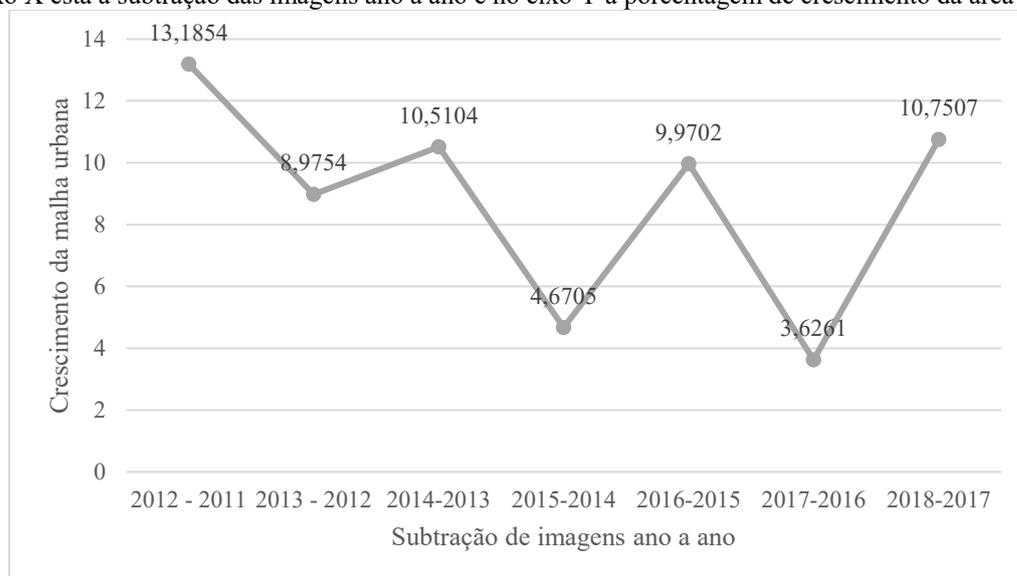
Na Figura 16, onde foi representado os resultados provenientes da equação de segmentação, é visualmente demonstrado a densificação da mancha urbana ao longo dos anos. Já na Figura 17 ilustra a região urbana próxima da UFU em dois tempos diferentes, a esquerda no ano de 2011 antes da construção do Campus Araras e a direita no ano de 2018 depois de quatro anos da construção do Campus, nas duas imagens possuem um retângulo vermelho que indica a localização da universidade, podendo destacar a densificação urbana consolidando uma região periférica da cidade devido a influência da UFU naquele local.

Figura 17: Densificação urbana nos arredores do Campus Araras, a esquerda a segmentação da área próximo ao Campus Araras no ano de 2011 e a direita a segmentação da área próximo ao Campus Araras no ano de 2018.



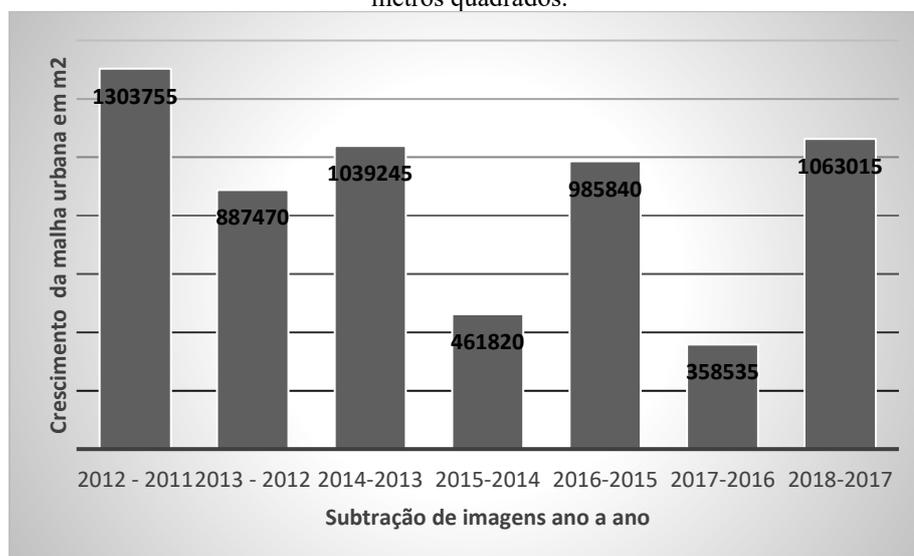
Já na Figura 18 possui um gráfico do crescimento da área urbana de Monte Carmelo em porcentagem, podendo destacar que no ano da chegada da UFU ao município foi o de maior crescimento urbano.

Figura 18: Gráfico de porcentagem de crescimento da área urbana de Monte Carmelo utilizando Segmentação, no eixo X está a subtração das imagens ano a ano e no eixo Y a porcentagem de crescimento da área urbana.



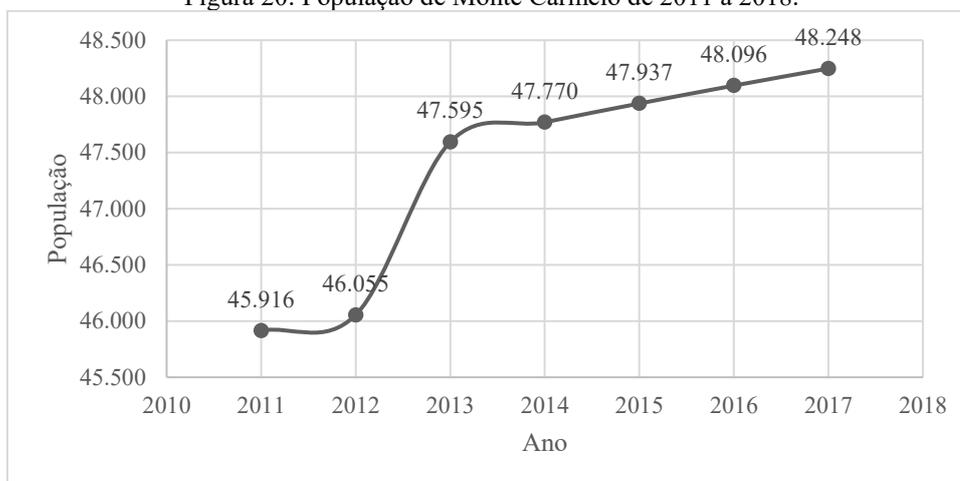
Através da detecção de mudanças é possível destacar que em todos os anos após a chegada da universidade a cidade teve crescimento significativo, em 4 anos consegui crescer próximo de 10 % de sua área urbana. A Figura 19 também é uma subtração de imagens, porém o crescimento ao longo do tempo é descrito por área, podendo assim evidenciar o crescimento da cidade.

Figura 19: Gráfico de crescimento da área urbana de Monte Carmelo em metros quadrados utilizando segmentação, no eixo X está a subtração das imagens ano a ano e no eixo Y o crescimento da área urbana em metros quadrados.



A Figura 20 expõe a população de Monte Carmelo de 2011 a 2018, a cidade ganhou nesse período 2332 habitantes, é possível afirmar que grande parte dos mesmos está relacionado com a UFU, diretamente ou indiretamente, devido aos cinco cursos de graduação ministrados na universidade, ao número de alunos, professores e técnicos, no mínimo 1000 pessoas estão ligadas diretamente a UFU. Deve se considerar também, as pessoas que já residiam na cidade e agora estudam na universidade, mas se antes para realizar um curso superior em uma universidade pública o monte carmelitano deveria sair da cidade, agora existe essa opção dentro do município.

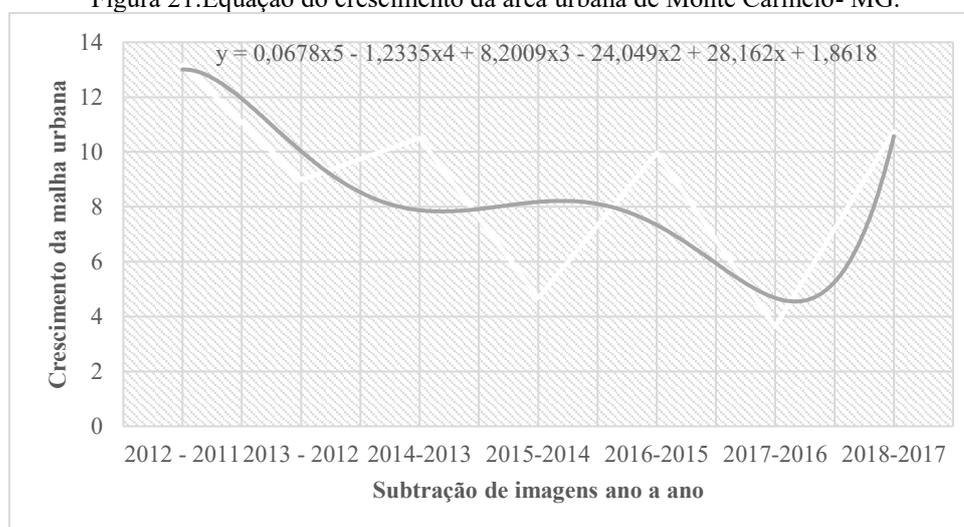
Figura 20: População de Monte Carmelo de 2011 a 2018.



Fonte: IBGE (2018).

Através dos dados de crescimento do município proveniente da segmentação de imagens foi possível equacionar esse crescimento, em uma função polinomial de quinta ordem exposta na Figura 21.

Figura 21: Equação do crescimento da área urbana de Monte Carmelo- MG.



5 CONCLUSÃO

Neste trabalho foram utilizadas duas abordagens diferentes para classificação de alvos urbanos em imagem de alta resolução espacial: RNA (pixel a pixel) e Segmentação (regiões). Os resultados obtidos comprovaram que a segunda abordagem é uma alternativa promissora para minimizar os problemas de sobreposição de classes, que geram confusão em uma classificação pixel a pixel.

A utilização da Rede Neural Artificial neste trabalho demonstrou algumas dificuldades do classificador em separar a malha urbana dos demais elementos presentes na imagem. Através dos resultados quantitativos e visuais é notório a confusão deste classificador pixel a pixel na hora de distinguir as classes, sendo que em vários momentos ele confundiu as classes de malha urbana com solo exposto, pastagem e mata ciliar. Assim os dados gerados por esse classificador devem ser analisados com cuidado, pelo fato de ele mostrar um crescimento aberrante em alguns anos e outros até um decréscimo. Quando é necessário classificar elementos que possuem comportamento espectral semelhante, geralmente os classificadores pixel a pixel como é o caso da RNA, confundem as classes semelhantes, como ocorrido neste trabalho.

Existem diversos desafios em utilizar imagens orbitais para estudos urbanos, porém, com um rigoroso processo de pré-processamento das imagens *RapidEye*, é possível estudar o meio urbano. Com a aplicação da Equação de Segmentação foi possível discriminar a parte urbana, estimar crescimento da área urbana, demonstrar que a cidade cresceu todos os anos e principalmente nos arredores do Campus Araras. Ou seja, a resolução espectral, espacial, temporal e radiométrica do *RapidEye*, atendem a estudos urbanos. Estes mesmos dados podem fornecer uma caracterização espectral dos elementos urbanos, através do resultado gerado da segmentação e RNA.

Através deste trabalho, foi comprovado que as imagens multiespectrais do *RapidEye* podem ser utilizadas para estudos urbanos, podendo detectar o crescimento da mancha urbana de maneira confiável, principalmente pelo fato do MMA já ter adquirido as mesmas e o Brasil inteiro carecer de estudos urbanos em seus municípios e de verba para fazer o mesmo, de maneira que o potencial de aplicações dessas imagens em território nacional não pode ser desprezado.

Por meio das análises das classificações geradas, se tornou evidente o impacto quantitativo da UFU naquele setor da cidade, sendo que houve um processo de urbanização acentuado naquela região, após o campus Araras se alocar naquele local.

REFERÊNCIAS

- BRITES, R. S; BIAS, E. S; ROSA, A. N. C. S. **Classificação por Regiões**. Introdução ao Processamento de Imagens de Sensoriamento Remoto, 2012.
- CARVALHO, N. B. **Redes Neurais Artificiais Aplicadas à Análise Sensorial de Requeijão Light**. 2011. Dissertação (Mestrado) – Curso de Ciência e Tecnologia de Alimentos, UFV, Viçosa, 2011.
- D'ALGE, J. C. L. **Geoprocessamento - Teoria e Aplicações - Parte I - Cap. 6 - Cartografia para Geoprocessamento**. INPE - Instituto Nacional de Pesquisas Espaciais, 2001. Disponível em www.dpi.inpe.br/gilberto/livro/introd/. Acesso em 10 ago. 2017.
- ENVI. Atmospheric Correction Module: QUAC and FLAASH User's Guide. ESRI, 2009. Disponível em: <http://www.harrisgeospatial.com/portals/0/pdfs/envi/flaash_module.pdf>. Acesso em: 25 jul. 2018.
- ESCOBAR, N.R.C. **Normalização radiométrica para detecção de mudanças da cobertura da terra em IBAs situadas no Departamento Boquerón, Paraguai**. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, XVII, 2015, João Pessoa. **Anais**. João Pessoa, INPE, 2015. p. 3780 – 3787.
- FELIX, I.M; KAZMIERCZAK, M. L.; ESPINDOLA G. M. **RapidEye: a nova geração de satélites de observação da Terra**. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, XIV, 2009, Natal. **Anais**. Natal, INPE, 2009. p. 7619 – 7622.
- FIDALGO, E. C. C. **Exatidão no processo de mapeamento temático da vegetação de uma área de mata atlântica no estado de São Paulo, a partir de imagens tm-landsat**. 1995. 167 f. Dissertação (Mestrado) - Curso de Sensoriamento Remoto, Inpe, São José dos Campos, 1995.
- FLORENZANO, T. G. **Iniciação em Sensoriamento Remoto**. Oficina de Textos, 2011.
- GALO, M. L. B. T. **Análise de Imagens Multiespectrais – Módulo 4: Extração de informações a partir de dados de sensoriamento remoto**. UNESP – Departamento de Cartografia, 2010.
- GONZALEZ, R. C.; WOODS, R. E. **Digital Image Processing**. Addison-Wesley.1993.
- HARRIS (Org.). Fast Line-of-sight Atmospheric Analysis of Hypercubes. Disponível em: <<http://www.harrisgeospatial.com/docs/FLAASH.html>>. Acesso em: 23 nov. 2017.
- INPE. Tutorial de Geoprocessamento. Disponível em: <<http://www.dpi.inpe.br/spring/teoria/>>. Acesso em: 07 out. 2017.
- JENSEN, J. R. **Introductory digital image processing: a remote sensing perspective**. New Jersey: Prentice-Hall. 1986.

JENSEN, J. R. **Remote Sensing of the environment: an earth resource perspective**. Upper Saddle River: Geographic Information Science, 2000.

Jensen, J.R. **Remote Sensing of the Environment: An Earth Resource Perspective**, 2nd Edition, Pearson Education, Prentice Hall, Upper Saddle River, 2006.

LURCHIARI, A. **Identificação da cobertura vegetal em áreas urbanas por meio de produtos de sensoriamento remoto e de um sistema de informação geográfica**. In: Revista do Departamento de Geografia, 2001, São Paulo -SP. **Anais**. São Paulo – SP, USP, 2001. p. 47-58.

MALUF, V.B.V. et al. **Eficácia de um método de normalização radiométrica utilizando imagens Landsat 5 TM**. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, XVII, 2015, João Pessoa. **Anais**. João Pessoa, INPE, 2015. p. 5491 – 5497.

MARTINS, G. D. **Inferência dos níveis de infecção por nematoides na cultura cafeeira a partir de dados de sensoriamento remoto adquiridos em multiescala**. 2016. 125 f. Tese (Doutorado) - Curso de Ciências Cartográficas, Unesp, Presidente Prudente, 2016.

MEC. REUNI. Disponível em: <<http://reuni.mec.gov.br/>>. Acesso em: 24 nov. 2017.

MESEV, V. T.; LONGLEY, P. A. The role of classified imagery in urban spatial analysis. In: Atkinson, P. M; Tate, N. J. (ed.) **Advances in Remote Sensing and GIS Analysis**. Chichester: John Wiley e Sons, 1999. cap. 12, p. 185 -206.

NOVO, E. M. L. de M. **Sensoriamento Remoto: Princípios e Aplicações**. Editora Edgar Blücher Ltda. São José dos Campos, 2010.

PEREIRA, M.N; KURKDJIAN, M.L.N.O; FORESTI, C; LIMA, U.M.B. **Aplicações de composições multitemporais obtidas a partir de dados Landsat no estudo de crescimento urbano**. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, III, 1984, Rio de Janeiro. **Anais**. Rio de Janeiro, INPE, 1984.

PINHO, C.M.D; FEITOSA, F.F; KUX, H. **Classificação automática de cobertura do solo urbano em imagem IKONOS: Comparação entre abordagem pixel-a-pixel e orientada a objetos**. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, XII, 2005, Goiânia. **Anais**. Goiânia, INPE, 2005. p. 4217 – 4224.

PINHO, C.M.D; FEITOSA, F.F; KUX, H. **Classificação automática de cobertura do solo urbano em imagem IKONOS: Comparação entre a abordagem pixel-a-pixel e orientada a objetos**. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, XII, 2005, Goiânia. **Anais**. Goiânia, INPE, 2005. p. 4217-4224.

QUEIROZ, Corina Jará de. **Análise de Transformações Geométricas para o Georreferenciamento de Imagens do Satélite CBERS-I**. Dissertação de Mestrado. UFRGS - CEP SRM, 2003. Disponível em www.ufrgs.br/srm/DissertaçõesPos/A18.html. Acesso em 20 dez. 2017.

RAMIREZ, F.L.B; ANDERSON, L.O; FORMAGGIO, A.R. **Normalização radiométrica automatizada para geração de mosaicos de imagens RapidEye sobre paisagens**

amazônicas, através da transformação IR-MAD. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, XVII, 2015, João Pessoa. **Anais.** João Pessoa, INPE, 2015. p. 1292-1299.

SOUZA, Í. M.; **Sensoriamento remoto orbital aplicado a estudos urbanos.** São José dos Campos, INPE, 2012.

SOUZA, U.D.V; KUX, H.J.H. **Classificação da cobertura do solo urbano na área costeira de São Luís – MA, utilizando imagens do satélite *Worldview-II* e técnicas de mineração de dados.** In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, XVI, 2013, Foz do Iguaçu. **Anais.** Foz do Iguaçu, INPE, 2013. p. 1151-1158.

STEPHAN, I.; LATINI, T. **O impacto de um campus universitário em Rio Paranaíba, MG,** In: Simpósio Cidades Médias e Pequenas da Bahia, 2014, Vitória da Conquista. **Anais.** Vitória da Conquista, UFV, 2014. p.15.

WANG, L. et al. FEITOSA, F.F; KUX, H. **China's urban expansion from 1990 to 2010 determined with satellite remote sensing.** In: Chinese Science Bullietin, Vol. 57, 2012. p. 2802-2812.

YANG, X. **Urban Remote Sensing: Monitoring, Synthesis and Modeling in the Urban Environment.** West Sussex: John Wiley & Sons, 2011.