

INSTITUTO TECNOLÓGICO DE AERONÁUTICA



Maximiliano Cavalcante Dias Souza

**MODELAGEM COMPUTACIONAL DA
DINÂMICA DE OCUPAÇÃO TERRITORIAL
DEVIDO A OPERAÇÃO DE UM AEROPORTO
REGIONAL**

Trabalho de Graduação
2020

Curso de Engenharia Civil-Aeronáutica

Maximiliano Cavalcante Dias Souza

**MODELAGEM COMPUTACIONAL DA
DINÂMICA DE OCUPAÇÃO TERRITORIAL
DEVIDO A OPERAÇÃO DE UM AEROPORTO
REGIONAL**

Orientador

Prof. Dr Marcelo Xavier Guterres (ITA)

ENGENHARIA CIVIL-AERONÁUTICA

SÃO JOSÉ DOS CAMPOS
INSTITUTO TECNOLÓGICO DE AERONÁUTICA

2020

Dados Internacionais de Catalogação-na-Publicação (CIP)

Divisão de Informação e Documentação

Souza, Maximiliano Cavalcante Dias
Modelagem matemática e computacional da dinâmica de ocupação territorial devido a operação de aeroporto regional / Maximiliano Cavalcante Dias Souza.
São José dos Campos, 2020.61f
Trabalho de Graduação – Engenharia Civil-Aeronáutica– Instituto Tecnológico de Aeronáutica, 2020. Orientador: Professor Doutor Marcelo Xavier Guterres

1. Aeroportos Regionais. 2. Geoprocessamento. 3. Aprendizado de máquina. I. Instituto Tecnológico de Aeronáutica. II. Modelagem matemática e computacional da dinâmica de ocupação territorial devido a operação de aeroportos regionais

REFERÊNCIA BIBLIOGRÁFICA

SOUZA, Maximiliano Cavalcante Dias. **Modelagem computacional da dinâmica de ocupação territorial devido a operação de um aeroporto regional**. Ano. 63f. Total de folhas. Trabalho de Conclusão de Curso. (Graduação em Engenharia Civil-Aeronáutica) – Instituto Tecnológico de Aeronáutica, São José dos Campos.

CESSÃO DE DIREITOS

NOME DO AUTOR: Maximiliano Cavalcante Dias Souza

TÍTULO DO TRABALHO: Modelagem computacional da dinâmica de ocupação territorial devido a operação de um aeroporto regional

TIPO DO TRABALHO/ANO: Graduação/2020

É concedida ao Instituto Tecnológico de Aeronáutica permissão para reproduzir cópias deste trabalho de graduação e para emprestar ou vender cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte deste trabalho de graduação pode ser reproduzida sem a autorização do autor.

Maximiliano C. Dias Souza

Maximiliano Cavalcante Dias Souza
DCTA Rua H8 , Alojamento H8 B 215
12228-461, São José dos Campos - SP

MODELAGEM COMPUTACIONAL DA DINÂMICA DE OCUPAÇÃO TERRITORIAL DEVIDO A OPERAÇÃO DE UM AEROPORTO REGIONAL

Essa publicação foi aceita como Relatório Final de Trabalho de Graduação

Maximiliano C. Dias Souza

Maximiliano Cavalcante Dias Souza

Autor

Marcelo Xavier Guterres

Prof. Dr Marcelo Xavier Guterres

Orientador

João Cláudio Bassan De Moraes

Prof. Dr João Cláudio Bassan De Moraes
Coordenador do Curso de Engenharia Civil-Aeronáutica

São José dos Campos, 25 de novembro de 2020

*Dedico este trabalho aos meus pais, à
minha irmã, aos meus amigos e aos meus
mestres, sem os quais não seria possível a
realização deste trabalho acadêmico.*

Agradecimentos

Agradeço aos meus pais e à minha irmã que foram minha base durante toda minha vida e sempre acreditaram nos meus planos.

Agradeço a todos os meus amigos que estiveram ao meu lado, em especial Mateus Arraes Feitosa Borges que compartilhou os desafios de cursar Engenharia Civil no ITA e além disso é um grande amigo fora da instituição, me motivando para fazer o meu melhor nas minhas atividades da vida.

Por fim, mas não menos importante meu também amigo e orientador Prof. Dr. Marcelo Xavier Guterres, que esteve sempre muito disponível para todo o apoio que precisei para a realização deste trabalho. Ele me mostrou grandes ensinamentos, entre eles a sua sensibilidade humana de entender o lado de cada pessoa e a perseverança de acreditar nelas quando até mesmo quando elas mesmas duvidam.

*"A vantagem de ter péssima
memória é divertir-se muitas
vezes com as mesmas coisas
boas como se fosse a primeira vez."*

(Friedrich Nietzsche)

Resumo

Os aeroportos regionais são um importante fator no desenvolvimento econômico. Vários tipos de análises são realizadas para entender os aspectos econômicos dos aeroportos regionais. Entre tais aspectos podemos citar o uso e ocupação do solo. Neste sentido, este trabalho oferece uma metodologia de classificação da região do entorno de aeroportos regionais, por meio da utilização de sensoriamento remoto, geoprocessamento e aprendizado de máquina. O estudo consistiu em um método de classificação de imagens, tendo como insumo fotografias de satélites LANDSAT, processadas pelo Sistema de Informação Geográfica (SIG). Essa classificação foi feita por processos computacionais de aprendizado de máquina e análises estatísticas, como teste de hipótese, box plots e coeficiente Kappa. As análises estatísticas ajudaram a entender os resultados e verificar se esse tipo de método aplicado a aeroportos regionais é eficiente. As conclusões estatísticas mostraram que o método é eficiente quanto a classificação proposta, porém ainda apresenta dificuldades e limitações para obter classificações consistentes, como a necessidade de efetuar um treinamento mais rigoroso. Esse trabalho contribuiu para entender o funcionamento das metodologias de geoprocessamento de imagens aplicadas a aeroportos regionais.

Abstract

Regional airports are important factors in economic development. Many types of analysis are made for understanding economic aspects around regional airports. Among these aspects we find ground use and occupation. In this context, this study offers a methodology for classifying regional airport's surroundings through remote sensing, geoprocessing and machine learning. This study consisted in an image classification method using LANDSAT satellite pictures as input, processed by Geographic Information System (GIS). This classification was made by computational processes of machine learning and statistical analysis, such as hypothesis testing, box plots and Kappa coefficient. The statistical analysis helped in the understanding of the results and further verification of the effectiveness of this method. The statistical conclusions showed that the method is efficient regarding the study's proposition, but still have some difficulties and limitations to obtain consistent classifications, such as the need to perform very rigorous machine learning training. This study also contributed to the understanding of the functioning of methodologies of geoprocessing of images applied to regional airports.

Lista de Figuras

FIGURA 1.1 – Comparativo de imagens do Aeródromo Chapecó, Serafim Enoss Bertaso entre o ano de 2002 e 2020.	17
FIGURA 1.2 – Fluxograma do processo para a realização da pergunta de pesquisa deste trabalho.	19
FIGURA 1.3 – Fluxograma do processo para chegar ao objetivo geral desta pesquisa.	20
FIGURA 2.1 – Tipos de aprendizado de máquina.	29
FIGURA 2.2 – Exemplo de aplicação de AM em processamento de imagens médicas.	31
FIGURA 2.3 - Quantificação da heterogeneidade intratumoral de um adenocarcinoma pulmonar em imagem de TC do tórax, para avaliação radiômica/radiogenômica.	31
FIGURA 3.1 - Fluxograma dos procedimentos metodológicos.	32
FIGURA 3.2 - Localização do município de Chapecó-SC.	33
FIGURA 3.3 - Dados técnicos do Aeroporto de SBCH.	34
FIGURA 3.4 - Bandas do Satélite LANDSAT-5.	40
FIGURA 3.5 - Função para mesclar camadas de Raster no <i>Software</i> QGIS.	41
FIGURA 3.6 - Funcionalidade para criação de Vetor Buffer , dentro do <i>software</i> QGIS.	41
FIGURA 3.7 - Exemplo de saída após a composição e a seleção da área de interesse.	42
FIGURA 3.8 - Exemplo de mapeamento das classes de interesse.	44
FIGURA 3.9 - Interface do plugin Dzetsaka.	45
FIGURA 4.1 - Composição e classificação de imagem LANDSAT-5.	49
FIGURA 4.2 - Composição e classificação de imagem LANDSAT-8.	50
FIGURA 4.3 - Evolução temporal dos valores de K.....	51
FIGURA 4.4 - Boxplot da variável Kappa.	52

Lista de Tabelas

TABELA 3.1 – Período de atividade e o tipo sensor de cada satélite do catálogo do INPE.	35-36
TABELA 3.2 – Sistema de projeção das imagens de Chapecó/SC.	38
TABELA 3.3 – Agrupamento qualitativo do coeficiente kappa.	46
TABELA A.1 – Características de resolução do sensor TM LANDSAT-5.	61
TABELA A.2 – Características de resolução do Sensor OLI LANDSAT-8.	62
TABELA 4.1 – Classificação do uso e ocupação do solo.	48-49
TABELA A.3 – Valores de Kappa (K).	63
TABELA 4.2 – Teste de hipótese para os valores de Kappa.	52

Lista de Abreviaturas e Siglas

AM: Aprendizado de Máquina;

API: *Application Programming Interface*;

ACRP: Airport Cooperative Research Program;

ECCA: *Economic Contribution of Civil Aviation*

ICAO: *International Civil Aviation Organization*;

IATA: *International Air Transport Association*;

INPE: Instituto Nacional de Pesquisas Espaciais;

PDAR: Programa de Desenvolvimento da Aviação Regional;

PIB: Produto Interno Bruto;

SIG: Sistemas de Informação Geográfica;

NDVI: *Normalized Difference Vegetation Index*;

NDBI: *Normalized Difference Built-up Index*;

NDWI: *Normalized Difference Water Index*;

TM: *Thematic mapper*;

TIFF: *Tagged Image File Format*;

Lista de Símbolos

K - coeficiente Kappa;

P_i - é o *i-ésimo* passo metodológico P ;

α - nível de confiança;

H_0 - hipótese nula;

H_1 - hipótese alternativa;

Sumário

1.0 Introdução	15
1.1 Pergunta de pesquisa	17
1.2 Objetivo Geral	19
1.2.1 <i>Objetivos Específicos</i>	20
1.3 Justificativa	20
1.4 Limitação e condição de contorno	21
1.5 Método de pesquisa	22
1.6 Estrutura do texto	22
2.0 Conceitos e Trabalhos relacionados	24
2.1 Abordagens clássicas de mensuração de efeitos econômicos	24
2.2 Geoprocessamento	25
2.3 Aprendizado de Máquina	27
3.0 Materiais e Métodos	32
3.1 Escolha do aeroporto (P1)	33
3.2 Definição da região de interesse (P2)	34
3.3 Catálogo de imagens do INPE (P4 e P5)	35
3.4 Criação do banco de dados (P3)	36
3.5 Escolha do Software de Sistema de Informação Geográfico (P6)	38
3.6 Composição de processamento de imagens (P7)	39
3.7 Definição das classes de interesse (P8)	42
3.8 Treinamento do algoritmo de aprendizagem de máquina (P9)	43
3.9 Classificação das imagens do banco de dados (P10)	44
3.9 Validação da classificação e parâmetro Kappa (P11)	46
3.10 Teste de hipótese (P13)	47
4.0 Resultados e Discussões	48
5.0 Conclusões	55
Referências	56
Anexo	61

1.0 Introdução

O Brasil possui uma malha ferroviária e fluvial deficitária no que diz respeito ao transporte de passageiros. Em particular, o modal rodoviário responsável pela maior parte do transporte de bens no país, tão pouco é suficiente para suprir a demanda nacional (Neves *et al.*, 2018). Ao encontro dos problemas supracitados, foi proposto em 2015 o Programa de Desenvolvimento da Aviação Regional (PDAR) (BRASIL, 2015). Visando não apenas promover uma melhor interligação entre as cidades de pequeno e médio porte entre si, como também com os principais centros urbanos nacionais, por meio da construção ou modernização dos aeroportos no interior do território nacional.

Esses novos aeroportos, em sua grande maioria, são construídos mais afastados das cidades em razão dos impactos ambientais, como por exemplo a poluição sonora. Nesta linha, a *International Civil Aviation Organization* (ICAO) (ICAO, 2006) determina os seguintes critérios para a escolha de um sítio aeroportuário: espaço aéreo desobstruído e possibilidades de expansões; meteorologia - ventos e condições atmosféricas; solo com suporte e condições de drenagem adequadas; disponibilidade de serviços de utilidade pública como água, energia, telefone etc; acessibilidade - vias, estradas, ferrovias, portos e transporte público; e distância do centro gerador de demanda.

Em virtude dos critérios da ICAO, a região geográfica do aeroporto, mesmo que seja mais afastada do centro da cidade, apresenta áreas e infraestruturas capazes de receber novas residências e novos empreendimentos próximos à região de implantação. A Figura 1.1 demonstra por meio de um comparativo de imagens, um exemplo de processo de ocupação do solo em torno de um aeródromo, no qual é possível observar mudanças na paisagem em um período de tempo.



FIGURA 1.1 – Comparativo de imagens do Aeródromo Chapecó, Serafim Enoss Bertaso entre os anos de 2002 e 2020 (Google, 2020).

Portanto, os aeroportos são vetores de desenvolvimento da economia local, gerando o impulsionamento da criação de novos empreendimentos nos mais variados ramos como:

hotelaria, bancos, restaurantes, entre outros. Porém, medir os impactos econômicos devido a operação de uma infraestrutura aeroportuária não é uma atividade trivial.

Tradicionalmente a mensuração dos impactos econômicos é realizada por abordagens econômicas como: Matriz Insumo-produto, Método de Coletas e Benefícios ou Métodos Catalíticos (NGULUBE, 2011; DIMITRIOU *et al.*, 2011; COOPER & SMITH, 2005). Porém, essas metodologias prescindem de dados oficiais os quais muitas vezes não estão disponíveis. Desta forma, a análise pode ser inviabilizada.

Logo, em razão de uma possível dificuldade de aplicação de uma metodologia essencialmente econômica de avaliação de impactos, este trabalho busca desenvolver uma abordagem complementar aos modelos econômicos, aproveitando-se dos avanços nas tecnologias de sensoriamento remoto e geoprocessamento de imagens de satélite. Neste sentido, Amaral e Rios (2012) acrescentam que o geoprocessamento em conjunto com as técnicas de aprendizado de máquina (AM) permite classificar o uso e ocupação do solo de forma eficiente.

Por fim, visto a importância da aviação regional no cenário nacional surge a necessidade do acompanhamento do PDAR e de seus impactos sobre as regiões de interesse. Portanto, a modelagem proposta na presente monografia pode servir como ferramenta complementar, no que diz respeito ao entendimento dos fenômenos econômicos, sociais e ambientais, devido a operação de um aeroporto regional.

1.1 Pergunta de pesquisa

Pela perspectiva apresentada na seção anterior, a discussão sobre os impactos econômicos, sociais e ambientais da operação de um aeroporto regional, a forma de

quantificação desses e a dinâmica ocupacional, surge o questionamento que esta pesquisa acadêmica busca responder.

“É possível classificar de forma eficiente a dinâmica de ocupação temporal do solo no entorno de um aeroporto regional utilizando geoprocessamento de imagens de satélite e aprendizado de máquina?”

A Figura 1.2 ilustra por meio de um fluxograma as ideias discutidas, que permitiram a formulação da pergunta principal da pesquisa.

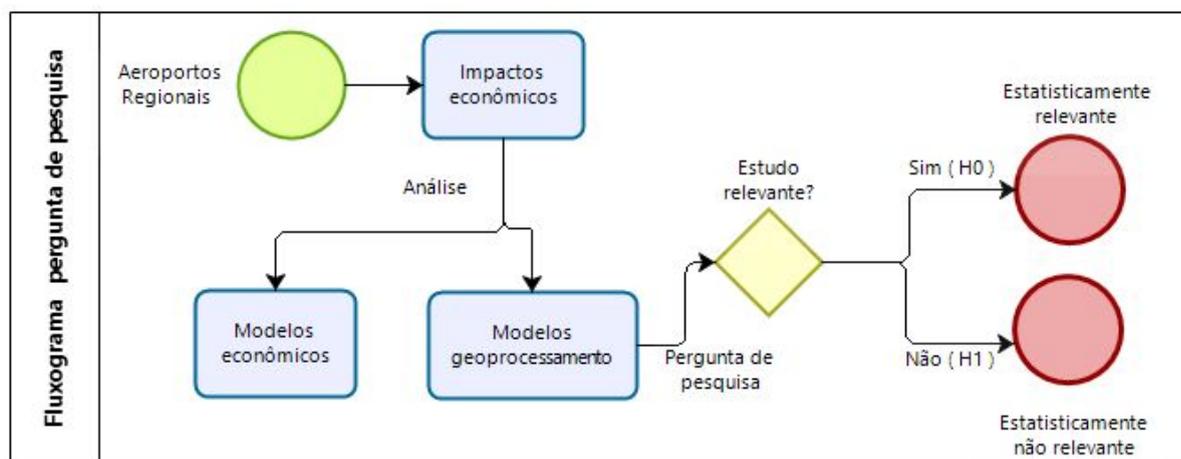


FIGURA 1.2 - Fluxograma do processo para a realização da pergunta de pesquisa deste trabalho.

A partir da pergunta foram elaboradas duas hipóteses principais. A primeira, H_0 , que corresponde à hipótese nula, ou seja, o estudo não é estatisticamente significativo no que diz respeito à eficiência do processo de classificação da dinâmica de uso e ocupação do solo. Caso a hipótese H_0 seja rejeitada, é razoável dizer que a proposta de modelagem mostrou significância estatística, portanto foi capaz de modelar o fenômeno em estudo.

1.2 Objetivo Geral

Em vista da discussão levantada pela pergunta de pesquisa, seção 1.1, definiu-se o objetivo geral da pesquisa:

“Desenvolvimento de um conjunto de procedimentos metodológicos, com auxílio de um sistema de informação geográfica (SIG) de código aberto e multiplataforma, para automatizar o processo de avaliação da dinâmica de ocupação do solo da região do entorno de um aeroporto regional, de forma cronológica (linha do tempo)”.

A Figura 1.3 apresenta um fluxograma, de forma resumida, das etapas e processos necessários para alcançar o objetivo geral delineado. É importante destacar que o conjunto total de procedimentos será explicado no capítulo que versa sobre os Materiais e Métodos da pesquisa.

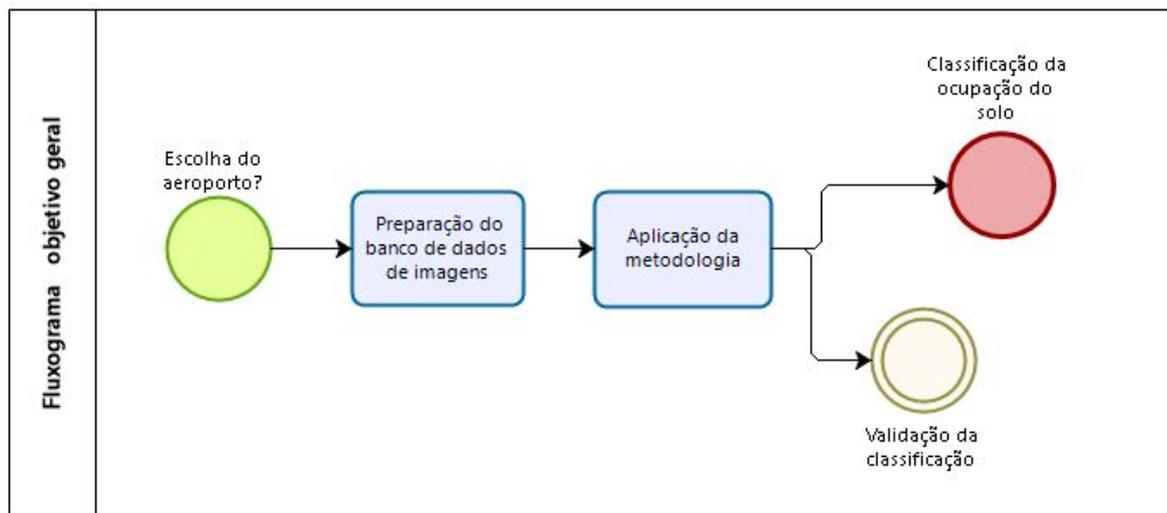


FIGURA 1.3 - Fluxograma do processo para chegar ao objetivo geral desta pesquisa.

As etapas representadas na Figura 1.3 são: seleção do aeroporto objeto de investigação; preparação e processamento do banco de dados de imagens da região do entorno do aeródromo; aplicação dos métodos de análise de aprendizado de máquina; validação da classificação realizada; e por fim a obtenção de uma classificação para o tipo de ocupação do solo.

1.2.1 Objetivos Específicos

Para chegar-se no objetivo geral os seguintes objetivos específicos foram fixados:

1. *Delimitar área de estudo com as classes de interesse;*
2. *Avaliação e seleção do software de sistema de informação geográfica (SIG) ;*
3. *Identificação do algoritmo de aprendizagem de máquina para a tarefa de classificação das imagens de satélite;*
4. *Escolha da técnica de validação do modelo computacional;*

Os objetivos (1) e (2) estão relacionados ao processo de obtenção dos dados, nestas etapas é importante obter os melhores dados disponíveis e delimitar de forma precisa a região de estudo, pois isto impactará diretamente nos resultados do estudo. Por último, os objetivos (3) e (4) estão relacionados aos processos computacionais que devem ser utilizados.

1.3 Justificativa

Com relação às justificativas da pertinência da presente pesquisa, identificam-se três razões principais: (i) de natureza teórica; (ii) de natureza prática; e (iii) de natureza econômica.

(i) Teórica: a escassa literatura que aborda a classificação da ocupação do solo no entorno dos aeroportos regionais utilizando sensoriamento remoto com aprendizado de máquina.

Na literatura é possível encontrar estudos de sensoriamento remoto focados em entender o processo de urbanização das cidades (FARINA, 2006). Entretanto, quando a análise se trata mais especificamente de aeroportos regionais existem poucos registros na literatura científica. Portanto, este estudo busca preencher essa lacuna teórica.

(ii) Prática: Uma alternativa metodológica mais simples para análise da ocupação do solo e identificação de proxies de desenvolvimento econômico.

O sensoriamento remoto traz simplicidade de acesso às informações a serem estudadas. Utilizando-se do atual contexto, de disponibilização de imagens de satélite de forma gratuita pelo Instituto Nacional de Pesquisas Espaciais (INPE). Ademais, dado o número elevado de municípios brasileiros sem registros de dados econômicos para aplicação de modelos econômicos.

(iii) Econômica: A abordagem em desenvolvimento têm custos financeiros de desenvolvimento e aplicação menor, quando comparada a outras metodologias como, por exemplo, os estudos de impactos econômicos por meio da Matriz Insumo-Produto.

No âmbito da pesquisa, o principal tipo de dados são imagens de satélites que são disponibilizadas de forma gratuitas e com alta taxa de cobertura do território nacional.

1.4 Limitação e condição de contorno

O entendimento do processo de ocupação e do desenvolvimento econômico é restrito à observação dos efeitos diretos na área selecionada. Portanto, os efeitos indiretos e induzidos não podem ser apreciados pelo processamento de imagens de satélite. Além do mais, as imagens obtidas pelos satélites são suscetíveis a erros de captura devido às condições meteorológicas e interferências eletromagnéticas.

1.5 Método de pesquisa

Para classificar a presente pesquisa acadêmica foram utilizados os critérios de Gil (2002), que são função dos objetivos gerais delineados e o dos procedimentos técnicos empregados:

(i) Classificação segundo os objetivos gerais: Existem três grandes grupos em que a pesquisa pode se enquadrar, sendo estes a pesquisa exploratória, pesquisa descritiva e pesquisa explicativa. A presente pesquisa adequa-se mais como pesquisa exploratória, pois, possui como objetivo principal o aprimoramento de ideias já conhecidas. Além disso, possui um planejamento flexível, analisando exemplos práticos reais que auxiliam na compreensão do problema. Contudo, a pesquisa enquadra-se, em partes, como descritiva, já que descreve o fenômeno que ocorre na ocupação do solo em torno do aeroporto regional com o passar do tempo.

(ii) Classificação segundo os procedimentos técnicos: Pode ser classificada como pesquisa documental, uma vez que são adotados dados secundários extraídos de fontes que não necessariamente haviam passado por tratamento analítico.

1.6 Estrutura do texto

A redação desta monografia será estruturada em cinco partes: *(i) destinada a uma breve introdução acerca do assunto e das definições da linha de investigação; (ii) revisão das particularidades do estudo quanto a revisão teórica; (iii) os métodos e materiais necessários para atingir cada um dos objetivos listados no presente capítulo; (iv) os resultados e a discussão devido à aplicação da metodologia; (v) as considerações finais e sugestões de trabalhos futuros; (vi) as referências consultadas para apoio acadêmico;*

2.0 Conceitos e Trabalhos relacionados

Este capítulo tem por objetivo, de forma resumida, apresentar os conceitos teóricos empregados na pesquisa: geoprocessamento e aprendizado de máquina (AM). Igualmente, alguns destaques da literatura científica, no que diz respeito, à aplicação de métodos ou modelos para entender os efeitos econômicos em uma região, devido à implantação ou operação de um aeroporto.

2.1 Abordagens clássicas de mensuração de efeitos econômicos

A estimação dos impactos econômicos fomentados pelas infraestruturas aeroportuárias do país são fundamentais para avaliação dos investimentos públicos e privados. Ademais, ao estudar-se a dinâmica econômica dos impactos diretos, indiretos e induzidos, possibilita aos gestores públicos e investidores inferirem quais são as principais variáveis exógenas envolvidas no processo de desenvolvimento econômico, dada uma nova infraestrutura aeroportuária e os serviços de transporte aéreo.

Pela perspectiva anterior, diferentes abordagens de modelagem econômica podem ser empregadas para mensurar os efeitos devido aos investimentos em aeroportos e sua operação. A literatura destaca: o método de insumo-produto, o método de coleta de benefícios e o método catalítico.

A principal abordagem é a Matriz Insumo-Produto de Wassily Leontief, recomendada pela ICAO, em suas diretrizes metodológicas denominadas *Economic Contribution of Civil Aviation* (ECCA) (ICAO, 2005). Tal documento foi desenvolvido para auxiliar os Estados na forma de medir e avaliar a contribuição econômica da aviação civil.

Os pesquisadores de Hujer e Kokot (2000), destacam que a Matriz Insumo-Produto pode ser empregada para avaliação dos impactos locais devido à operação de aeroportos regionais. Os efeitos de impacto direto, indireto e induzido, devido a operação de aeroportos internacionais. Os resultados apontam contribuições significativas para as economias locais, estaduais (regionais) e/ou nacionais.

Outra abordagem de destaque é o método do custo-benefício, geralmente usado por governos, organismos internacionais e empresas do setor privado para avaliar os efeitos de uma determinada política. O método do custo-benefício é essencialmente uma análise de paridade dos benefícios e custos esperados, considerando também as alternativas que se perdem e a manutenção do *status quo*. Alguns exemplos do uso desta abordagem em transporte aéreo registrados na literatura são os estudos de Nwaneri (1970) e Jorge & Rus (2004).

Por fim, outro interesse da comunidade científica é a modelagem dos efeitos econômicos de um setor em outros setores correlatos, ou seja, os efeitos catalíticos. Por exemplo, qual o efeito no setor de turismo em razão de um crescimento do setor de transporte aéreo. A *Airport Cooperative Research Program* (ACRP) destaca nos seus documentos a importância da medição dos efeitos catalíticos devido à construção e operação de uma infraestrutura aeroportuária (ACRP, 2008).

2.2 Geoprocessamento

Rosa (1996), expressa que a observação, representação e o entendimento adequado da superfície terrestre é um fator relevante na organização e desenvolvimento das sociedades. Uma vez que, a compreensão da distribuição espacial da infraestrutura instalada, dos recursos

naturais, da distribuição da população, entre outros, é um conhecimento imprescindível para definição de novas políticas de desenvolvimento regional.

Em consonância com o destaque anterior, o geoprocessamento permite a automatização do processo de avaliação da distribuição espacial dos fenômenos ocorridos no espaço de tempo, em uma região geográfica, por meio do processamento de imagens satélite. Neste sentido, as possibilidades de emprego das técnicas que compõem a área de conhecimento geoprocessamento são vastas. Destacam-se aplicações nas áreas de planejamento territorial urbano, redes de transportes e impactos ambientais.

Farina (2006), apresenta em seu estudo contribuições no que diz respeito, à gestão da ocupação urbana, evidenciando as técnicas de geoprocessamento que podem ser usadas na organização da expansão territorial das cidades, observados critérios ambientais. O mesmo autor, esclarece que o geoprocessamento permite eficiência na obtenção, atualização, armazenamento, cruzamento e recuperação dos dados necessários à gestão urbana.

Zuppo (1996), relaciona a importância do uso das técnicas de geoprocessamento no planejamento do sistema de transporte e trânsito de uma cidade, por meio da simulação de trajetos e monitoramento de acidentes de trânsito, com o auxílio de Sistemas de Informação Geográfica (SIG). Na mesma linha, Lázaro (2020), realizou um estudo de caracterização pós-implantação, de corredores exclusivos de ônibus, por meio de geotecnologias de coleta e interpretação de informações georreferenciadas visando explicar os impactos positivos e negativos da infraestrutura.

Na área de engenharia de infraestrutura aeroportuária, Bevilaqua (2009), em sua dissertação propõe uma metodologia para compreender o entendimento dos planos de zona de proteção de aeródromo e a sua relação com as áreas urbanas do entorno dos aeródromos, por meio da utilização de imagens de alta resolução espacial. Para tanto, foram utilizadas

duas imagens IKONOS II, datadas de 2001 e 2008, do entorno do Aeroporto Salgado Filho em Porto Alegre, Rio Grande do Sul. Segundo o autor, o estudo revelou que o uso de imagens de alta resolução apresenta-se como uma técnica eficiente para as análises de obstáculos. Ainda, o método permitiu o monitoramento contínuo do aumento de implantações irregulares no entorno do aeroporto.

Aplicações recentes na área de Transporte Aéreo e na linha de investigação dessa monografia é o trabalho de Oliveira *et al.* (2019). Esses pesquisadores, mediante o uso das tecnologias mais recentes de geoprocessamento, realizaram o mapeamento do uso da área do entorno do Aeroporto Internacional do Recife. Para tanto, estimaram os índices físicos NDVI (*Normalized Difference Vegetation Index*), NDBI (*Normalized Difference Built-up Index*) e NDWI (*Normalized Difference Water Index*). Ademais, os pesquisadores destacam que os referidos índices vêm sendo muito utilizados como suporte para o mapeamento e monitoramento de uso e ocupação da terra. As imagens utilizadas para o cálculo dos índices são originárias do satélite LANDSAT-8, sensor OLI de 18-06-2016, órbita-ponto 214-066. Eles aplicaram a técnica de fusão RGB-IHS para obter uma melhor resolução espacial.

Por outra perspectiva sobre o uso do geoprocessamento, Figueiredo e Vieira (2007) definem que a exatidão de um mapa é a proximidade da medida de um atributo específico com o seu valor real. Portanto, a confiabilidade de um mapa está vinculada a sua exatidão. Nesta lógica, os autores afirmam que é imprescindível realizar algum tipo de procedimento estatístico, no produto resultante de uma classificação de imagens digitais, para determinar a acurácia ou exatidão desta classificação. A avaliação da acurácia pode ser obtida por meio de coeficientes de concordância derivados da matriz de confusão e pelo uso do coeficiente Kappa (K)

2.3 Aprendizado de Máquina

Monard e Baranauskas (2003), definem que aprendizado de máquina (AM) é uma área do conhecimento científico que tem por finalidade o desenvolvimento de sistemas computacionais que sejam capazes de adquirir conhecimento de forma automática.

Em linhas gerais, Barreto (2008), esclarece que os métodos de aprendizado de máquina “*são modelos computacionais que observam um certo grupo de padrões (instâncias) e tentam realizar a definição de uma resolução geral para um problema*”.

O AM é composto por diferentes técnicas de aprendizado: (i) *aprendizado supervisionado*; (ii) *aprendizado não supervisionado*; (iii) e *aprendizado por reforço*. Em complemento, a Figura 2.1 ilustra um diagrama com as formas de aprendizado com exemplos de aplicação.



FIGURA 2.1 - Tipos de aprendizado de máquina (Instituto Senai de Inovação¹, 2018).

O aprendizado supervisionado é uma tarefa que tem por objetivo aprender uma função que permita o mapeamento de uma entrada para uma saída com base em pares de

¹ <https://isitics.com/2018/05/10/principais-sub-divisoes-e-aplicabilidade-da-aprendizagem-de-maquina/>

entrada-saída de um exemplo. Ou seja, é uma tentativa de prever uma variável dependente a partir de uma lista de variáveis independentes.

Por outro lado, o aprendizado não supervisionado busca realizar a tarefa de aprendizado com dados não rotulados, classificados ou categorizados previamente. Portanto, neste caso apresenta-se somente os dados de entrada e o algoritmo descobre as saídas. A terceira abordagem, aprendizagem por reforço, o algoritmo tenta aprender qual é a melhor ação a ser executada, em função das dependendo das particularidades na qual essa ação será executada. No que diz respeito às aplicações de aprendizado de máquina, em particular, destaca-se a interpretação de imagens médicas e de geoprocessamento.

Santos *et al.* (2019), colocam em seu artigo a importância das técnicas de aprendizado de máquina no diagnóstico médico por imagem. Os algoritmos permitem avaliar a obtenção de parâmetros quantitativos, gravidade da patologia por meio da estimação de biomarcadores prognósticos e de resposta ao tratamento.

Um exemplo importante do uso de imagens médicas com aprendizado de máquina é a detecção de câncer de pele (melanoma). O resultado da aplicação é um diagnóstico (classificação) que indica a ocorrência de melanomas ou não ocorrência de melanomas. A Figura 2.2 detalha, como exemplo, o resultado final de um diagnóstico.

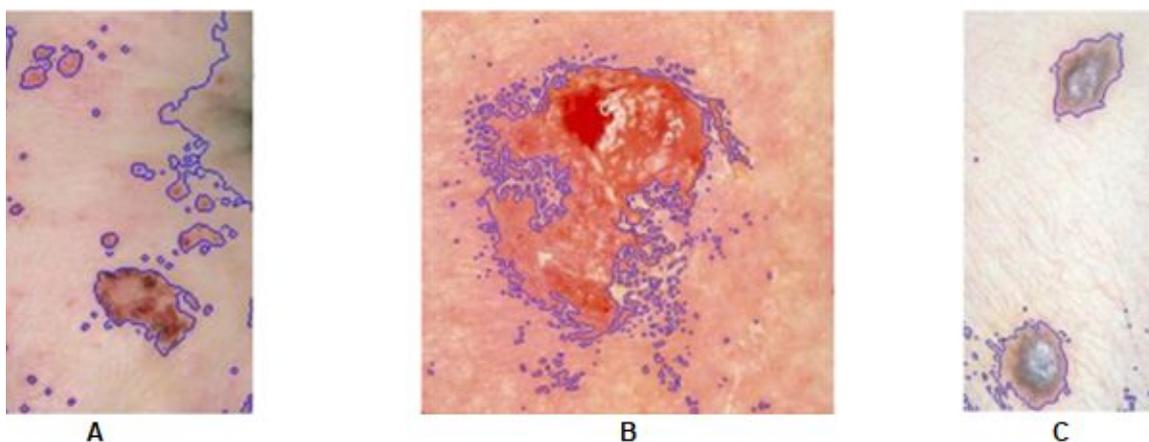


FIGURA 2.2 - Exemplo de aplicação de AM em processamento de imagens médicas (BIOTEC², 2020).

Santos *et al.* (2019), em suas próprias palavras diz: “o aprendizado de máquina é capaz de *quantificar a complexidade espacial do tumor e identificar essas sub-regiões fenotípicas/genotípicas*”, vide a Figura 2.3. A a escala de cores na Figura 2.3 se refere a um atributo extraído da imagem refletindo as sub-regiões teciduais e genéticas do tumor.

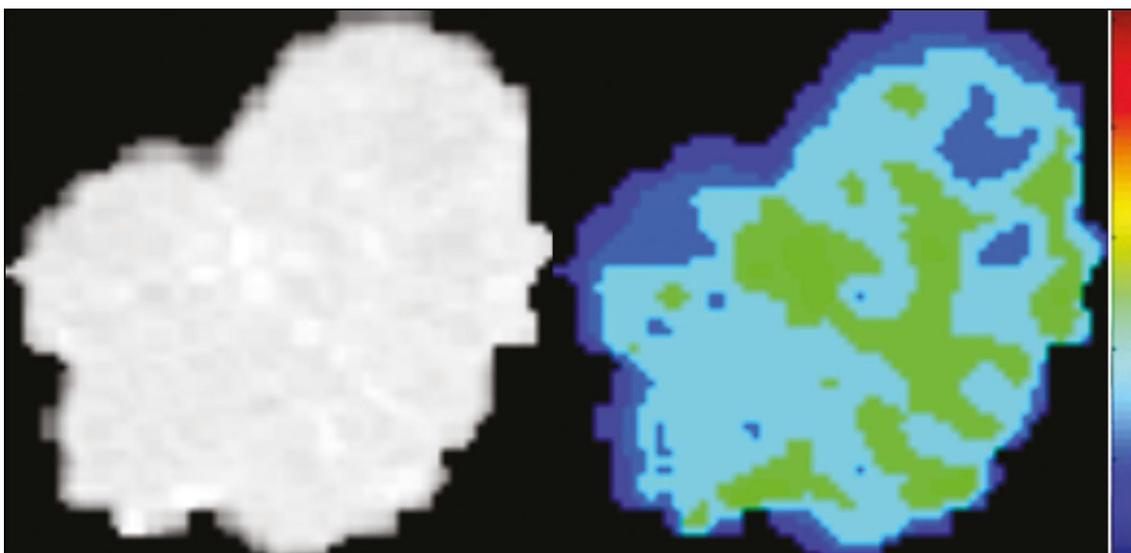


FIGURA 2.3 - Quantificação da heterogeneidade intratumoral de um adenocarcinoma pulmonar em imagem de TC do tórax, para avaliação radiômica/radiogenômica (Santos *et al.*, 2019).

Em síntese, a literatura médica sobre aprendizado de máquina registra um conteúdo vasto das aplicações neste campo do conhecimento, por exemplo: Araújo *et al.* (2019), Braga *et al.* (2018) e Freitas e Polleto (2019).

Conforme destacado na redação desta monografia, os algoritmos de aprendizado de máquina têm sido empregados em aplicações de interpretação de imagens de satélite. Por exemplo, Gaiad *et al.* (2017), usaram Redes Neurais Artificiais (RNA) e *Support Vector Machine* (SVM) e o *Random Forest* (RF), para determinar a acuracidade e precisão na

² <https://profissaobiotec.com.br/aplicacao-de-tecnicas-de-machine-learning-a-diagnostics-na-saude/>

detecção das classes de uso e cobertura da terra. O objetivo do estudo, de maneira geral, foi avaliar a área do município de Mariana, Minas Gerais, local onde ocorreu o rompimento da barragem da mineradora. Os resultados obtidos indicaram que o algoritmo com melhor desempenho foi o SVM, com exatidão global (98,323%) e maior índice Kappa (0,979). Ainda, de acordo com a matriz de confusão, constata-se que a classe de Sombra e de Lama obtiveram maior erro na classificação, tendo como classes de maior acerto Água e Vegetação.

Dias (2020), em sua tese de doutorado, realiza uma classificação de imagens de geoprocessamento por pixel com base no perfil temporal. Ou seja, o perfil temporal pode ser representado como uma série de observações dos índices de vegetação dos pixels de interesse. Segundo a pesquisadora, este tipo de abordagem permite o reconhecimento de culturas, estudos fenológicos e o monitoramento de mudanças na cobertura do solo. Ademais, os métodos baseados em aprendizado de máquina lograram bons resultados na tarefa de classificação de imagens.

Por último, Pereira (2008), em seu estudo atesta que a incorporação de algoritmos de aprendizado de máquina na análise de dados espaciais fornece resultados com qualidade superior, quando comparados ao uso das técnicas tradicionais de geoprocessamento.

3.0 Materiais e Métodos

O escopo deste capítulo fundamenta-se em apresentar o delineamento metodológico da pesquisa e as estratégias que serão empregadas para testar a hipótese experimental definida no Capítulo 1, da presente monografia. Para tanto, a Figura 3.1 apresenta o fluxograma dos procedimentos metodológicos que serão executados. No fluxograma, cada procedimento foi designado pela legenda P_i , onde i é o i -ésimo passo metodológico P.

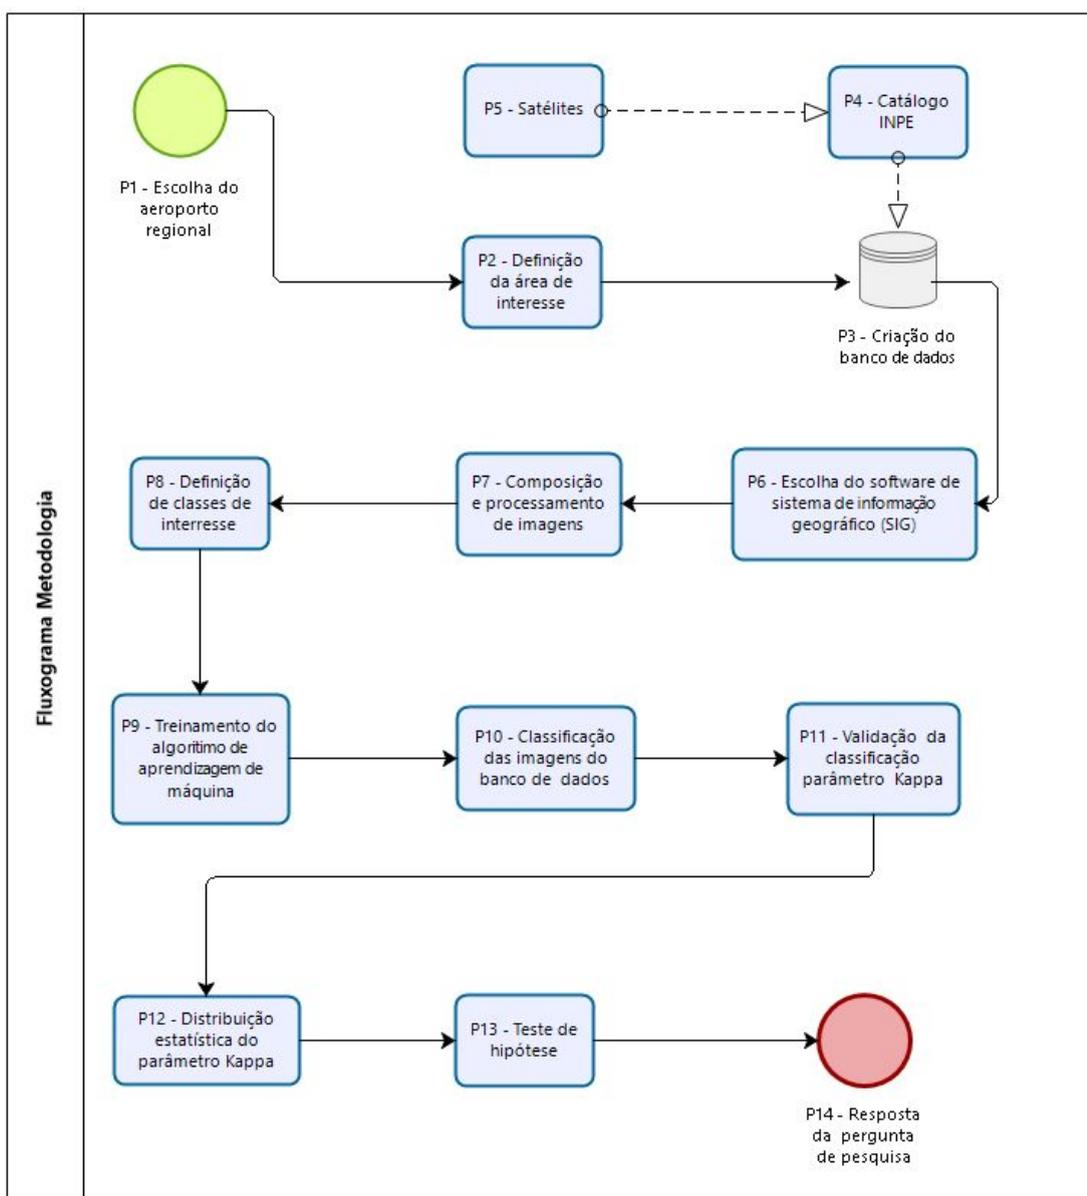


FIGURA 3.1 - Fluxograma dos procedimentos metodológicos.

3.1 Escolha do aeroporto (P1)

O procedimento metodológico **P1**, indicado na Figura 3.1, corresponde à escolha do aeroporto objeto de análise. A seleção deve atender os seguintes requisitos: (i) *categoria regional*; e (ii) *localização afastada do centro de gerador de demanda*.

Portanto, como objeto de estudo de caso foi selecionado o Aeroporto Regional de Chapecó - Serafim Enoss Bertaso (IATA: XAP, ICAO: SBCH), que fica localizado no município de Chapecó, na unidade federativa de Santa Catarina, inaugurado em 18 de março de 1978, *vide* Figura 3.2.

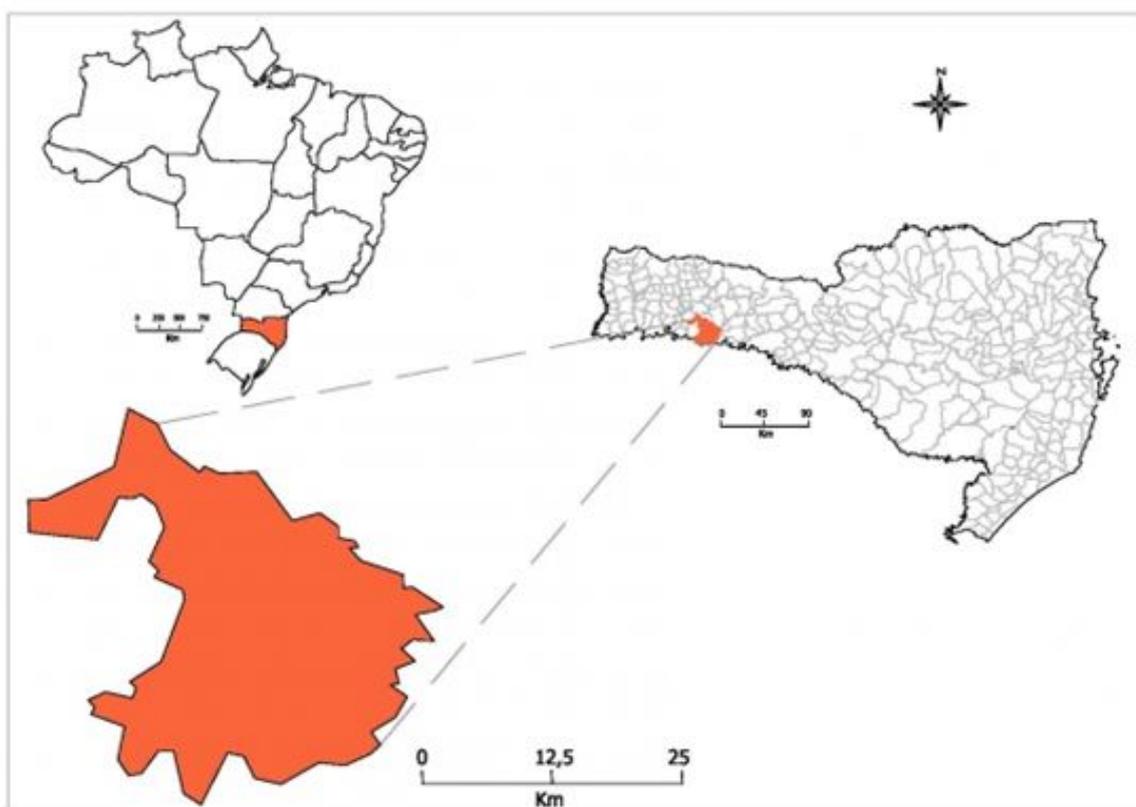


FIGURA 3.2 - Localização do município de Chapecó-SC

Algumas das razões da escolha do aeroporto SBCH, foi que além de atender o requisito de ser um aeroporto regional, o mesmo foi construído em uma região afastada do

centro, cerca de 9 km. Gerando assim um cenário apropriado para o presente estudo. Em complemento, a Figura 3.3 exibe as características operacionais do aeroporto.



FIGURA 3.3 - Dados técnicos do Aeroporto de SBCH (HORUS³, 2020).

Por fim, resumidamente, as principais estatísticas socioeconômicas da cidade de Chapecó são: população estimada de 224.013 pessoas; e PIB per capita de R\$ 41.683,33.

3.2 Definição da região de interesse (P2)

O procedimento **P2**, indicado na Figura 3.1, diz respeito à definição da área de interesse. Portanto, a região no entorno do aeródromo selecionado no **P1** deve apresentar as seguintes características mínimas: (i) *processo de urbanização em desenvolvimento*; e (ii) *topografia e geologia que permitam a atração de investimentos*.

Desse modo, a seleção de uma região que já passou pelo processo completo de urbanização, não será possível mensurar os impactos de uso e ocupação do solo, gerados

³ <https://horus.labtrans.ufsc.br/gerencial/>

pelo aeródromo, na linha do tempo. Ademais, se a região selecionada estiver localizada em condições acidentadas ou íngremes poderá ser um impedimento para atração econômica.

3.3 Catálogo de imagens do INPE (P4 e P5)

As etapas **P4** e **P5**, indicadas na Figura 3.1, são determinantes na construção da metodologia em desenvolvimento. Visto que, a não disponibilidade de imagens históricas com razoável qualidade, pode inviabilizar as análises da dinâmica ocupacional e dos possíveis efeitos econômicos no entorno do aeródromo selecionado.

Muito embora, o INPE disponibiliza um vasto catálogo de imagens procedentes de diferentes satélites. Cada satélite possui suas particularidades, entre elas: *(i) o período de atividade; e (ii) o tipo sensor*. A Tabela 3.1 resume as particularidades destacadas.

TABELA 3.1 – Período de atividade e o tipo sensor de cada satélite do catálogo do INPE.

Satélite	Sensor	Data inicial	Data final
CBERS-1	IRM/WFI/CCD	14/10/1999	ago/2003
CBERS-2	IRM/WFI/CCD	28/10/2003	10/01/2009
CBERS-2B	HRC/WFI/CCD	19/09/2007	12/05/2010
CBERS-4	MUX/IRS/WFI/PAN5/PAN10	01/01/2015	EM ATIVIDADE
LANDSAT1	MSS	23/07/1972	01/07/1978
LANDSAT2	MSS	22/01/1975	25/02/1982
LANDSAT3	MSS	05/03/1978	31/03/1983
LANDSAT5	TM	01/03/1984	22/11/2011
LANDSAT7	ETM+	15/04/1999	EM ATIVIDADE 31/05/2003 Interrompeu recepção no Brasil
LANDSAT8	OLI	20/02/2015	EM ATIVIDADE

RESOURCESAT1	LISS3/AWIFS	17/10/2003 Dados no Brasil após 22/10/2010	Em 12/09/2013, foi interrompida a recepção no Brasil.
RESOURCESAT2	LISS3/AWIFS	20/4/2011 Dados no Brasil após 01/10/2014	EM ATIVIDADE
AQUA	MODIS	04/05/2002	EM ATIVIDADE
TERRA	MODIS	18/12/1999	EM ATIVIDADE

Logo, em vista da disponibilidade, a escolha dos satélites e dos sensores de monitoramento devem considerar os seguintes parâmetros:

1. *Monitoramento de forma cronológica da operação do aeroporto de regional;*
2. *Boa qualidade de resolução espacial das imagens;*
3. *Sensoriamento multispectral .*

Em particular, destaca-se que os satélites LANDSAT-5 de sensor TM (*Thematic mapper*) e LANDSAT-8 de sensor OLI, com resolução espacial de aproximadamente 30 metros, Além do mais, seus sensores abrangem um vasto espectro eletromagnético.

3.4 Criação do banco de dados (P3)

Efetivadas as etapas iniciais do processo metodológico (**P1, P2, P4 e P5**), conforme a Figura 3.1, o próximo procedimento delineado consiste na estruturação do banco de dados de imagens espaciais. De forma geral, Câmara et al (2001) esclarece que a construção de um banco de dados espacial ocorre em quatro fases:

- I. *Refere-se à importação e processamento das imagens em nível digital para o sistema de informações geográficas;*
- II. *Diz respeito a forma de realizar o georreferenciamento das imagens utilizando-se um mapa cadastral;*
- III. *Espacialização dos atributos de interesse;*
- IV. Cálculo de geoestatísticas zonais a partir das imagens;

Em consonância com as fases supracitadas, indicadas por Câmara et al (2001), a fonte primária de importação de imagens do território nacional é o repositório do INPE⁴. Então, eleito o repositório, na sequência selecionam-se os satélites que armazenam imagens com o histórico da região.

Para o estudo de caso, a região no entorno do aeroporto de SBCH, os satélites selecionados foram o LANDSAT-5 e LANDSAT-8. O LANDSAT-5 catalogou imagens desde o ano de 1984 até o ano de 2011, com resolução apropriada para análise em desenvolvimento. Por outro lado, o LANDSAT-8 disponibiliza imagens para o período de anos entre 2015 a 2020, igualmente, de boa qualidade. Deste modo, o banco de dados de imagens espaciais estruturado registra uma história de 36 anos da região do entorno do aeródromo em análise.

Em particular, as imagens obtidas pelos satélites do INPE são georreferenciadas com dados do tipo TIFF (*Tagged Image File Format*). Diferentemente das imagens tradicionais, essas chegam com apenas a banda espectral registrada pelo sensor do satélite. Outra característica importante é o posicionamento da imagem na projeção utilizada. Neste sentido,

⁴ <http://www.dgi.inpe.br/CDSR/>

todas as imagens selecionadas para o estudo foram reprojctadas para o Sistemas de Referência de Coordenadas WGS 84/ UTM zone 22S EPSG:32722.

A Tabela 3.2 apresenta o sistema projeção, o modelo matemático teórico da representação da superfície da Terra ao nível do mar, assim como a órbita e ponto das imagens de Chapecó-SC.

TABELA 3.2 – Sistema de projeção das imagens de Chapecó/SC.

Características	Valor
Órbita	222
Ponto	79
Datum padrão	WGS 84
Projeção padrão	UTM 22 S

3.5 Escolha do *Software* de Sistema de Informação Geográfico (P6)

O procedimento **P6**, da Figura 3.1, consiste na seleção do *software* do tipo SIG. De acordo com Aronoff (1989), os SIG's são sistemas ou *softwares* utilizados para armazenar e manipular dados georreferenciados. Neste sentido, existem várias ferramentas que foram desenvolvidas com este intuito, por exemplo: Spring, ArcGIS, VisionGIS, QGIS, Terrset, entre outros.

Para a escolha da melhor ferramenta (**P6**), apresentar-se-á as características de algumas dessas ferramentas, segundo a ótica dos próprios desenvolvedores:

Spring: Este sistema de informações geográficas foi feito para aplicações em Agricultura, Floresta, Gestão Ambiental, Geografia, Geologia, Planejamento Urbano e Regional. Fornece um ambiente unificado de Geoprocessamento e Sensoriamento

Remoto para aplicações urbanas e ambientais. É um mecanismo de difusão do conhecimento desenvolvido pelo INPE e seus parceiros. É um *software* gratuito.

ArcGIS: Criação e utilização de mapas; compilar dados geográficos; análise de informações mapeadas; compartilhar e descobrir informações geográficas; usar mapas e informações geográficas em uma gama de aplicações; e gestão de informação geográficas numa base de dados. Uma boa parte das funcionalidades não é gratuita.

Terrset: Análise e Modelagem de Superfícies; Análise de Séries Temporais e Detecção de Mudanças; Análise de Risco e Vulnerabilidade; Apoio a Decisão tipo Multi-Critério/Multiobjetivo; Suporte API (*Application Programming Interface*), entre outras.

QGIS: O QGIS disponibiliza um número de funcionalidades em constante crescimento através das funções nativas e de complementos. Podendo visualizar, gerir, editar, analisar dados, e criar mapas para impressão. O QGIS é um Sistema de Código Aberto licenciado segundo a Licença Pública Geral GNU.

Visto as características, o QGIS se destaca dos outros *software* por possuir o código aberto, apresentando também, várias funcionalidades e oportunidades de implementações, como por exemplo o terminal em python que dá acessibilidade a novas aplicações. Portanto, o *software* escolhido no P6 é o QGIS

3.6 Composição de processamento de imagens (P7)

Selecionado o SIG no procedimento **P6** e o banco de dados de imagens nos procedimentos **P4** e **P5**, a próxima ação corresponde ao procedimento **P7**, observar Figura 3.1, que consiste no processamento das imagens, com objetivo de extrair da melhor forma possível as informações pertinentes à pesquisa, isto é, a geração das imagens coloridas.

Para tanto, é importante entender como o sensor de cada satélite registra essas imagens. O LANDSAT-5 registra por meio do sensor TM de 7 bandas espectrais, conforme apresentado na Tabela A.1 do anexo desta monografia. A fim de ilustração, a Figura 3.4, destaca as bandas disponíveis para o satélite LANDSAT-5. Por outro lado, o LANDSAT-8, por meio do sensor OLI registra 9 bandas espectrais, descritas na Tabela A.2. (veja anexo).

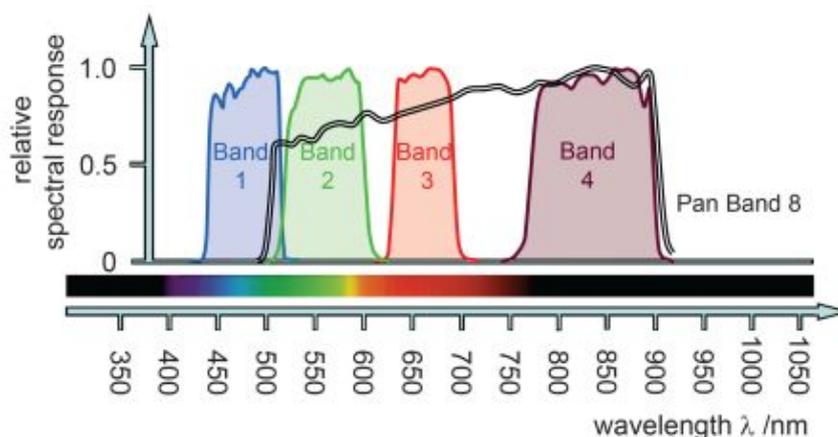


FIGURA 3.4 - Bandas do Satélite LANDSAT-5. (INPE⁵, 2020)

Utilizando o QGIS (consultar **P5** na Figura 3.1), foi criado um *Raster*⁶ (dado matricial), que agrupa todas as bandas em um só arquivo, esse processo aumenta a

⁵ <http://www.dgi.inpe.br/documentacao/satelites/landsat>

⁶ Em computação gráfica, uma imagem raster ou gráfico de bitmap é uma matriz de pontos, que representa geralmente uma grade retangular de pixel ou pontos de cor, que podem ser visualizados por meio de um monitor, papel ou mesmo no seu celular.

quantidade de informação associada a cada pixel da imagem. Em destaque, a Figura 3.5 mostra a interface da função utilizada no *software* QGIS.

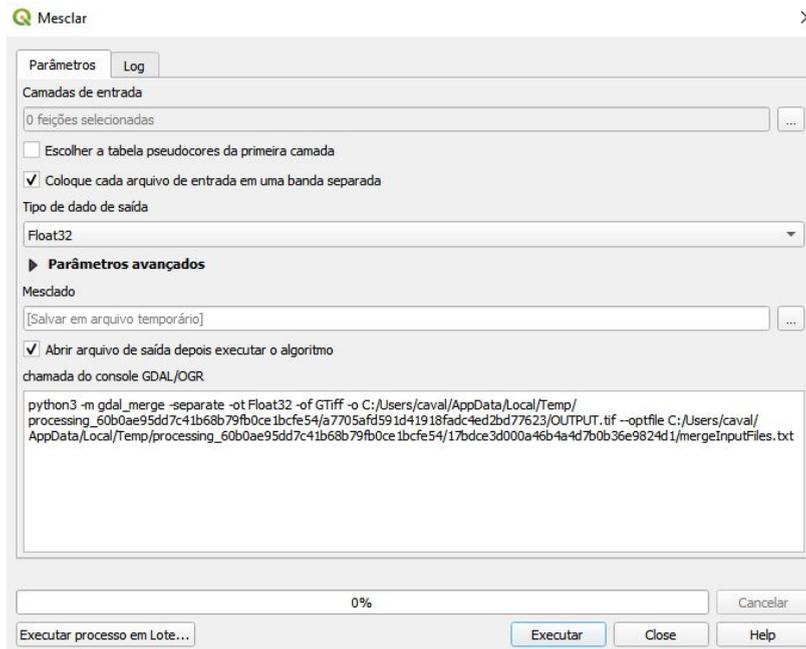


FIGURA 3.5 - Função para mesclar camadas de Raster no *Software* QGIS.

Para fazer o recorte da região de interesse, foi criado um vetor *buffer*, vide o comando do QGIS na Figura 3.6, com raio de 3 km e centralizado no centro da pista do Aeroporto de Chapecó.

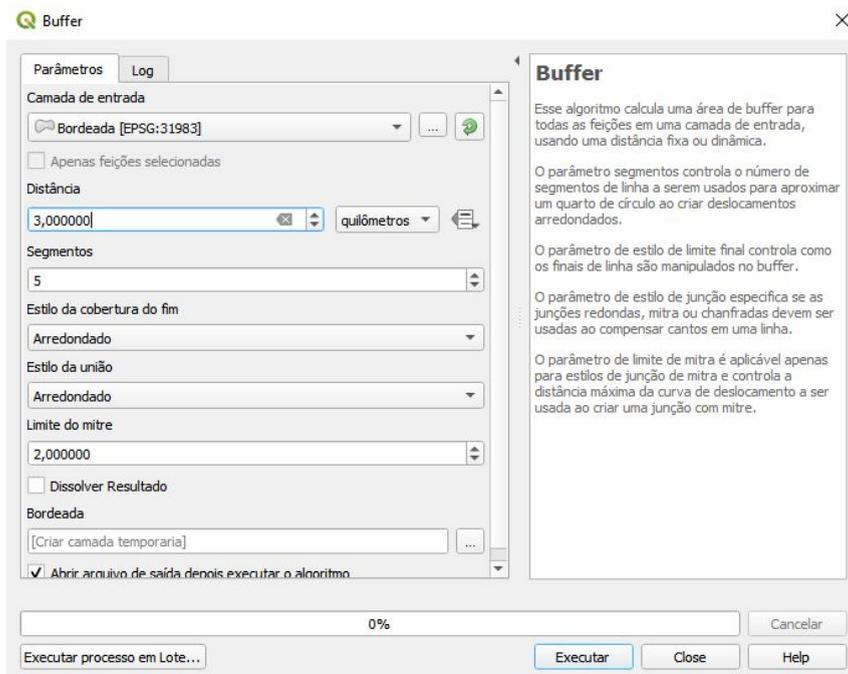


FIGURA 3.6 - Funcionalidade para criação de Vetor Buffer , dentro do *software* QGIS.

Na sequência, com auxílio do vetor *buffer* foi efetuado o recorte do *Raster*, cujo resultado é a seleção de interesse colorida. Um exemplo da imagem resultante do processamento descrito pode ser visualizado na Figura 3.7. O processo foi repetido sistematicamente com todas as imagens do banco de dados.

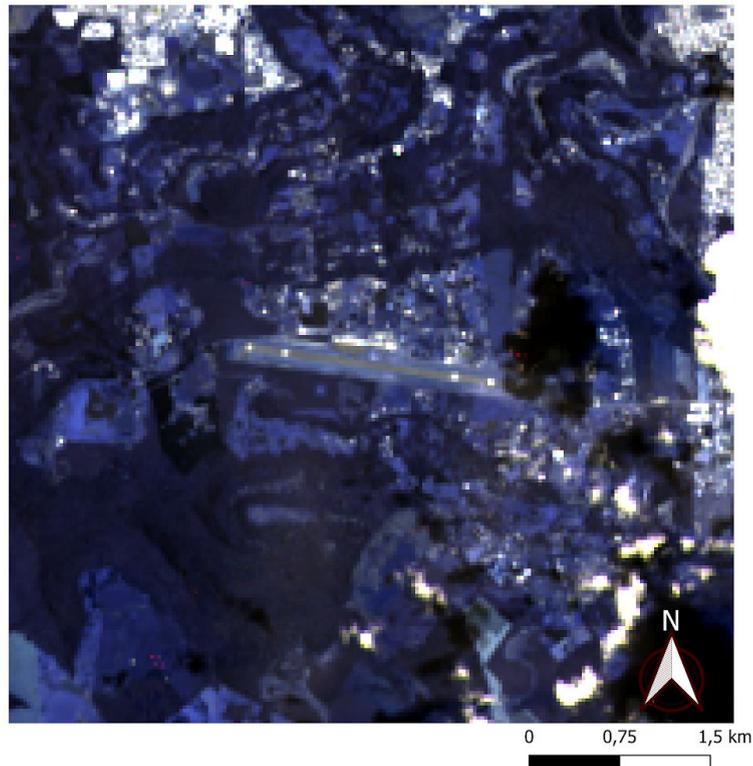


FIGURA 3.7 - Exemplo de saída após a composição e a seleção da área de interesse.
Fonte: LANDSAT-8.

3.7 Definição das classes de interesse (P8)

Para o processo de classificação, o procedimento **P8** da Figura 3.1, foi utilizado um algoritmo de aprendizado de máquina supervisionado. Para tanto, é imprescindível definir, de forma clara, as classes de interesse da classificação. Logo, para o processo de definição deve ser considerado as observações realizadas na paisagem da região de interesse. Assim foram definidas as 4 classes de interesse que se apresentaram de forma mais recorrente na paisagem:

- A. *Vegetação densa;*
- B. *Vegetação pouco densa;*
- C. *Asfalto e construções;*

D. Solo Descoberto.

É importante reforçar que, especificamente na região de estudo, a classe referente à água não foi observada em áreas suficientes. Em se tratando de análises em outros aeroportos regionais, uma classe referente a cobertura de água também pode ser levada em consideração, dada à recorrência que essa é abordada em outros trabalhos de geoprocessamento.

3.8 Treinamento do algoritmo de aprendizagem de máquina (P9)

No processo de treinamento do algoritmo, o procedimento **P9** da Figura 3.1, foi efetuada uma seleção manual de exemplos para as classes de interesse. Para essa seleção é importante que a escolha dos exemplos seja representativa para cada camada de interesse, ou seja, que os exemplos apresentem características recorrentes para cada uma das classes de interesse. Se possível, estudos de campo também podem ser solicitados para verificação da paisagem e uma consequente ratificação no treinamento da rotina. Além disso, imagens de satélite recentes (Google Earth Pro, 2020) em alta resolução também indicam o que é observado na região.



FIGURA 3.8 - Exemplo de mapeamento das classes de interesse (Google, 2020).

Uma vez com os exemplos de cada classe determinados, foi criada uma camada *Shapefile* conforme a Figura 3.8, na qual são ilustrados polígonos em verde que mapeiam as classes de interesse. O *software* QGIS permite o mapeamento desses exemplos por meio da sobreposição das imagens dos satélites LANDSAT 5 e 8 .

3.9 Classificação das imagens do banco de dados (P10)

O processo de classificação, que corresponde ao procedimento **P10** da Figura 3.1, utiliza o plugin *Dzetsaka* integrado ao *software* QGIS. Este plugin é código aberto em linguagem de programação Python, e apresenta quatro algoritmos de classificação de

imagens, são eles *Gaussian Mixture Model*, *Random Forest* (Floresta Aleatória), *Support Vector Machines* e *K-Nearest Neighbors*.

O algoritmo escolhido para o trabalho foi de Floresta Aleatórias, entre os motivos da escolha está a sua praticidade de uso, além do mais costuma apresentar bons resultados de acordo com a literatura. As entradas para o processo de classificação são dois arquivos: o primeiro é a área de interesse (*raster*) e o segundo é o mapeamento de uso e ocupação do solo (*shapefile*) referente às classes de interesse. A Figura 3.8 mostra a interface do plugin e onde o primeiro campo é para o *raster* e o segundo campo é para a entrada do *shapefile*⁷.

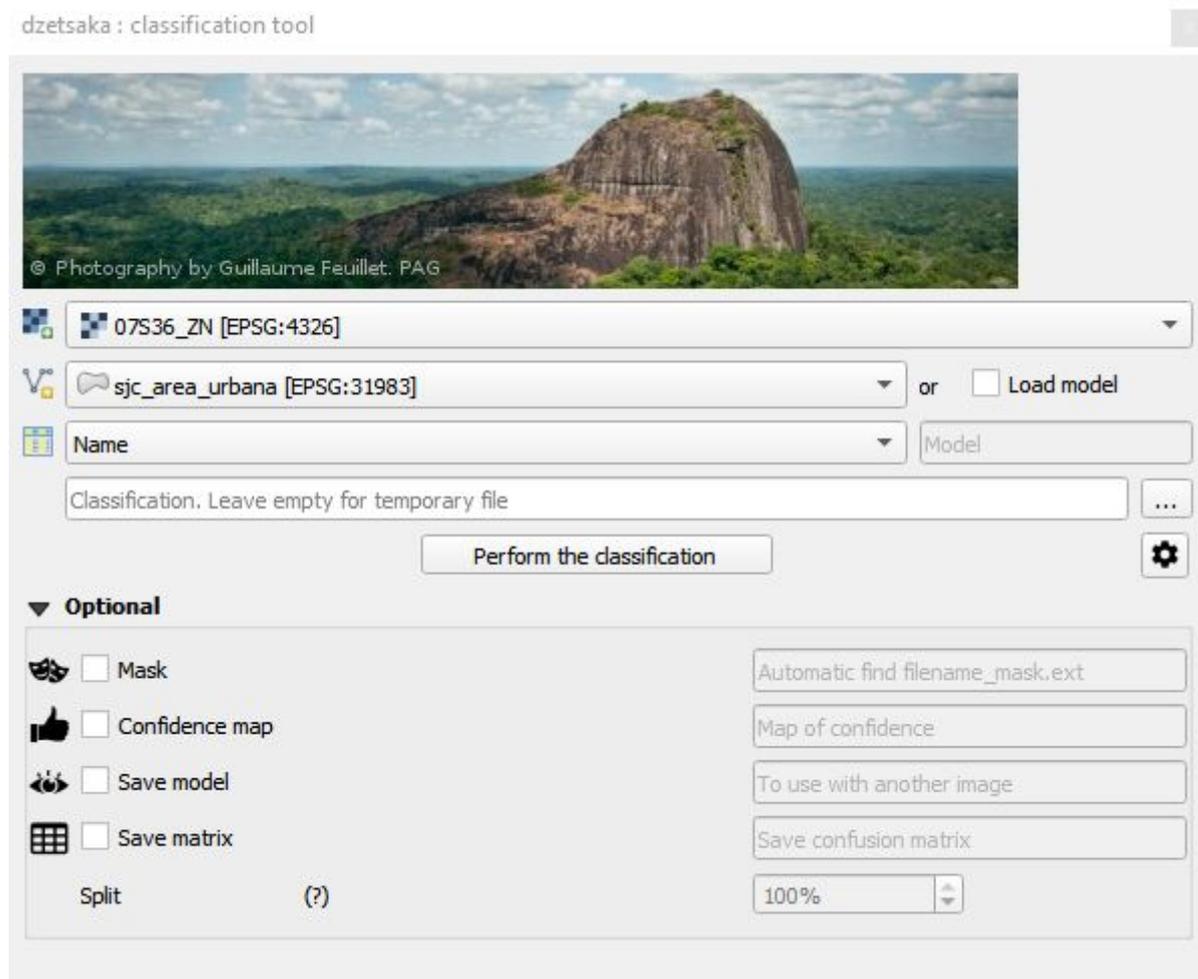


FIGURA 3.9 - Interface do plugin Dzetsaka.

⁷ O Esri Shapefile ou simplesmente *Shapefile* é um formato popular de arquivo contendo dados geoespaciais em forma de vetor usado por Sistemas de Informações Geográficas também conhecidos como SIG.

Como saída , o plugin gera um mapa da classificação (*raster*) e também é gerado um arquivo “.csv”, com a matriz de confusão referente ao teste estatístico realizado com metade da amostra do *Shapefile* .

3.9 Validação da classificação e parâmetro Kappa (P11)

Para o processo de validação da classificação, que corresponde ao procedimento **P11** da Figura 3.1, foi utilizado o coeficiente Kappa (PERROCA e GAIDZINSKI, 2003), que é construído a partir da matriz de confusão. Este coeficiente foi criado como uma forma de dizer sobre a qualidade da classificação, conforme representado na Tabela 3.3.

TABELA 3.3 – Agrupamento qualitativo do coeficiente kapa.

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

Fonte: Fonseca (2000).

A Tabela 3.3 mostra como o parâmetro Kappa avalia o desempenho da classificação. Quanto mais próximo de 1 melhor é o desempenho da classificação.

3.9 Distribuição estatística do coeficiente Kappa (P12)

Em virtude de todos os procedimentos metodológicos realizados, obteve-se variados valores de kappa, associado aos experimentos de classificação efetuados em todo banco de dados. A presente etapa, o procedimento **P12**, de forma geral, consiste na preparação de uma distribuição estatística da variável aleatória K .

3.10 Teste de hipótese (P13)

A etapa conclusiva da metodologia é o procedimento **P13**, que consiste na realização de um teste de hipótese, cujo objetivo principal é responder o problema de pesquisa definido na seção 1.1 desta monografia, para tanto foi utilizado um teste unilateral à direita. Seguindo as duas hipóteses indicadas nas Equações 3.1 e 3.2:

$$H_0 : \mu = \mu_0 \quad (3.1)$$

$$H_1 : \mu > \mu_0 \quad (3.2)$$

Para a definição de μ_0 , foi utilizado como referência a Tabela 3.3, que fixou $K = 0,8$ como uma classificação excelente. O teste escolhido foi o t de *Student*, para uma distribuição amostral da média, com o desvio padrão populacional desconhecido. O nível de confiança adotado no teste é de 95%.

4.0 Resultados e Discussões

A Tabela 4.1 apresenta as áreas de cobertura para cada uma das quatro classes de estudo predefinidas: vegetação densa, vegetação pouco densa, solo descoberto e asfalto e edificações. Também é destacada a variação percentual em relação ao resultado do ano anterior. Evidenciam-se dificuldades para a classificação de forma coerente ao avaliar a variação abrupta da ocupação de ano a ano. Por exemplo, para a cobertura de solo descoberto, que de 1988 para 1989 variou positivamente em 351,0 % e de 1987 para 1988 teve uma queda de -73,0% .

TABELA 4.1 – Classificação do uso e ocupação do solo.

Ano	Vegetação Densa (km ²)	Relação ano anterior (%)	Vegetação pouco densa (km ²)	Relação ano anterior (%)	Solo descoberto (km ²)	Relação ano anterior (%)	Asfalto e Edificações (km ²)	Relação ano anterior (%)
1984	14,0	-	5,0	-	14,9	-	2,3	-
1985	13,8	-1,3%	7,8	58,5%	7,0	-53,0%	7,4	229,3%
1986	14,0	1,8%	9,5	21,1%	4,2	-40,3%	8,3	12,3%
1987	13,6	-3,1%	9,4	-1,4%	7,7	83,9%	5,4	-35,1%
1988	14,5	6,4%	9,8	4,5%	2,1	-73,0%	9,7	79,6%
1989	12,3	-15,1%	7,5	-23,1%	9,3	351,0%	6,9	-28,9%
1990	13,9	13,3%	6,3	-16,0%	11,7	25,9%	4,1	-41,1%
1991	13,1	-6,1%	13,5	113,8%	3,6	-69,3%	5,9	44,1%
1992	11,7	-10,3%	13,1	-3,3%	7,2	100,0%	4,1	-30,8%
1993	16,4	40,5%	7,7	-41,2%	8,4	16,1%	3,5	-13,0%
1994	15,2	-7,3%	6,0	-21,3%	11,5	38,2%	3,2	-10,4%
1995	14,9	-2,0%	9,4	54,9%	6,2	-46,6%	5,5	74,7%
1996	16,5	10,6%	11,9	26,7%	4,1	-33,0%	3,5	-37,3%
1997	15,1	-8,7%	11,4	-3,9%	6,9	66,7%	2,6	-24,5%
1999	14,5	-4,1%	5,0	-56,5%	14,0	102,9%	2,6	-1,6%
2000	15,2	5,3%	8,4	69,4%	9,9	-29,3%	2,5	-4,3%
2001	15,3	0,5%	8,7	3,4%	8,3	-16,1%	3,7	50,2%
2003	15,4	0,4%	6,7	-23,2%	10,6	28,5%	3,3	-10,8%
2005	14,1	-8,3%	9,0	35,0%	10,3	-3,1%	2,6	-22,0%
2006	18,2	28,8%	10,3	14,8%	3,6	-65,1%	3,9	51,3%

2007	13,3	-26,6%	13,3	28,1%	5,8	60,0%	3,6	-6,2%
2008	15,7	17,4%	10,8	-18,6%	7,1	23,8%	2,4	-33,3%
2009	16,2	3,7%	8,7	-19,0%	8,6	21,2%	2,4	-1,8%
2010	15,3	-6,0%	11,3	30,0%	6,4	-25,5%	2,9	23,5%
2011	16,9	10,6%	12,3	8,7%	4,2	-34,4%	2,6	-13,3%
2015	15,8	-6,7%	12,8	3,4%	5,0	19,4%	2,4	-4,7%
2017	10,4	-34,3%	13,7	7,4%	7,9	57,0%	4,0	65,2%
2018	13,9	33,9%	7,3	-46,6%	10,8	36,0%	4,0	0,4%
2019	13,9	0,1%	7,3	-0,1%	10,8	-0,1%	4,0	0,0%

Os resultados visuais, também são importantes para trabalhos de geoprocessamento. Cada experimento associado à Tabela 4.1, gerou um arquivo *raster* georreferenciado da região de interesse, assim apresentados na Figura 4.1 e Figura 4.2.

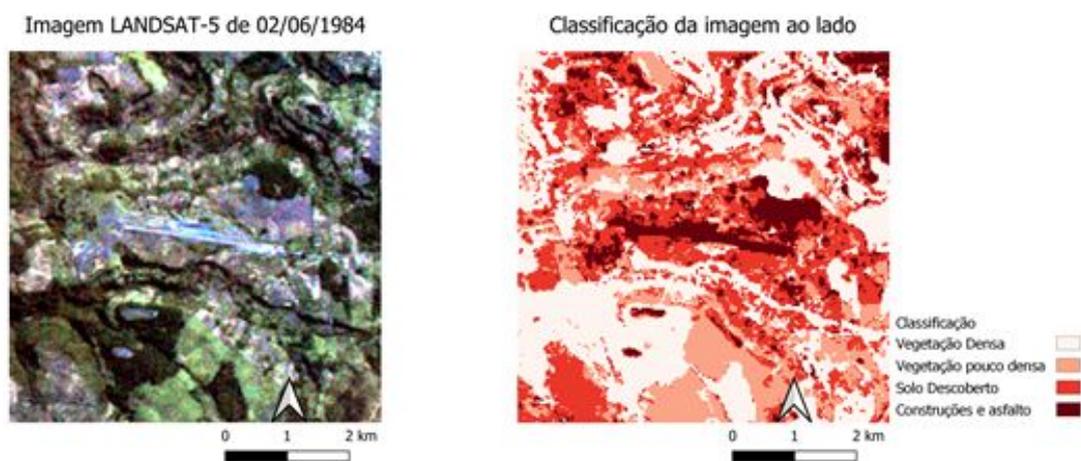


FIGURA 4.1 - Composição e classificação de imagem LANDSAT-5.

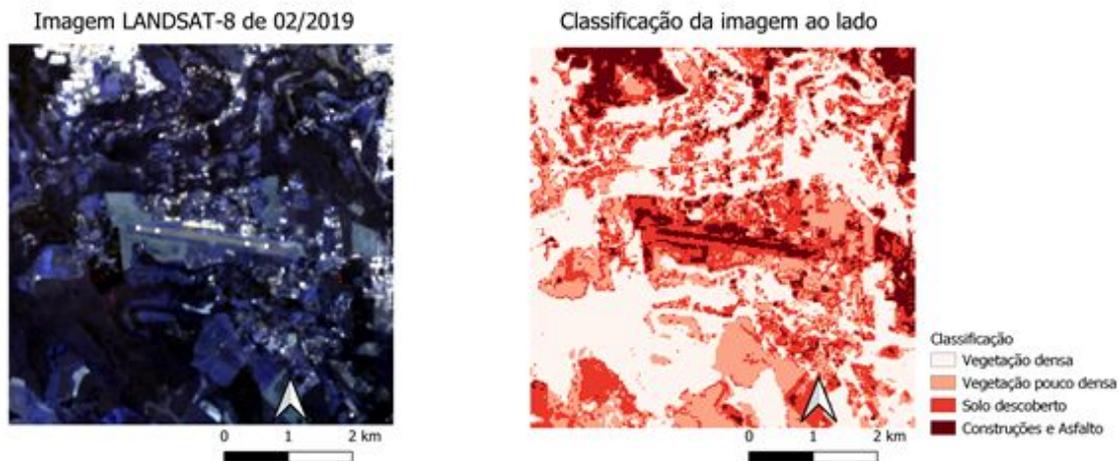


FIGURA 4.2 – Composição e classificação de imagem LANDSAT-8.

Outro resultado importante da aplicação do procedimento metodológico são os valores do coeficiente Kappa, em destaque na Tabela A.3 do anexo deste documento, estes valores foram estimados a partir da matriz de confusão. De outra forma, a Figura 4.3 destaca a evolução temporal dos valores do coeficiente K. Lembrando, o valor de K permite avaliar o nível de concordância da classificação do algoritmo de aprendizado de máquina, no caso presente o Floresta Aleatória.

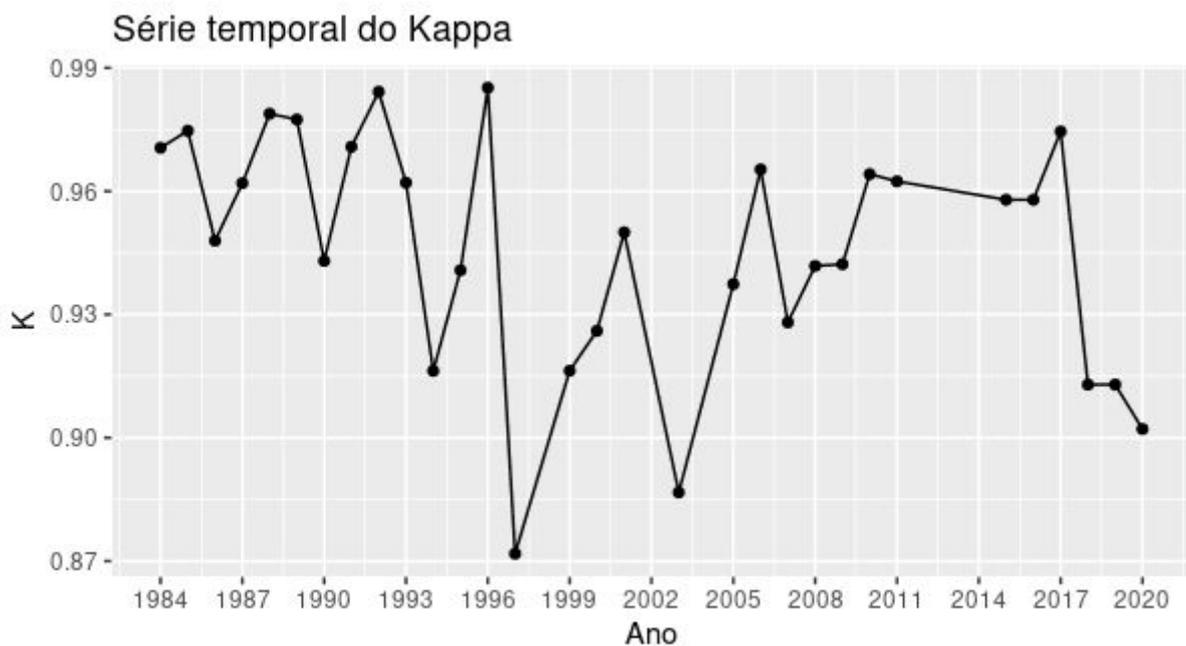


FIGURA 4.3 – Evolução temporal dos valores de K

Ao contrário do ocorrido na Tabela 4.1, os dados da Figura 4.3 mostraram que a classificação está em concordância com a classificação proposta. Da Figura 4.3 os menores valores de Kappa, foram 0,88 e 0,87 para classificação referente à 2003 e 1997 respectivamente. Lembrando, a Tabela 3.5 mostra que valores de kappa acima de 0,8 já é um indicador de classificação com forte concordância ou excelente.

Em seguida foi realizado o estudo estatístico dos valores kappa, através de dois testes, o primeiro foi o Box Plot Figura 4.4 e teste de hipótese.

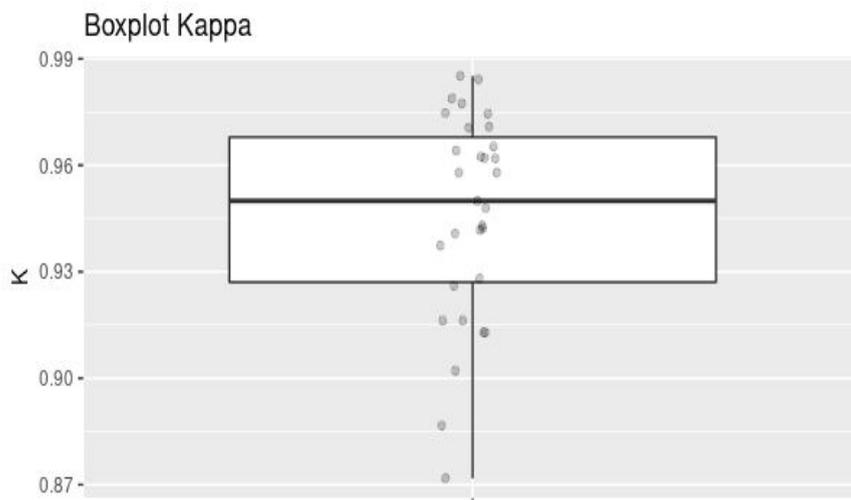


FIGURA 4.4 – Boxplot da variável Kappa.

O Boxplot⁸ da Figura 4.4, indica que a distribuição dos valores de K são relativamente centrados na média, além do mais não aponta a existência de *outliers*. Logo, o teste de hipótese do procedimento **P13**, pode ser realizado com maior rigor estatístico. Neste sentido, a Tabela 4.2 apresenta os resultados do teste.

TABELA – 4.2 Teste de hipótese para os valores de Kappa.

Teste de hipótese	
μ_0	0,8
μ	0,9459
Desv. Pad Amostra	0,02914
N	31
α	5%
t calculado	27,880
t tabela	2,042
t calculado > t tabelado	
Hipótese nula (H0) rechaçada	

⁸ O boxplot (gráfico de caixa) é um gráfico utilizado para avaliar a distribuição empírica dos dados. O boxplot é formado pelo primeiro e terceiro quartil e pela mediana. As hastes inferiores e superiores se estendem, respectivamente, do quartil inferior até o menor valor não inferior ao limite inferior e do quartil superior até o maior valor não superior ao limite superior. Fonte: <http://www.portalaction.com.br/estatistica-basica/31-boxplot>

O resultado do teste é que a hipótese nula (H_0) foi rejeitada, ou seja, foi obtido significância estatística para a classificação realizada, com isso responde-se a pergunta de pesquisa: *“é possível classificar de forma eficiente utilizando-se sensoriamento remoto e aprendizado de máquina as áreas no entorno de um aeroporto”*.

Entretanto, obtivemos dois tipos de respostas diferentes para os resultados. A primeira é proveniente da análise de variação da área Tabela 4.1. Os resultados não apontam uma identificação coerente dos dados de uso e ocupação do solo na região estudada, dada a grande variação percentual da cobertura das classes entre anos subsequentes. Apesar disso, o resultado oriundo da análise do parâmetro Kappa, indica através do teste de hipótese que a metodologia de classificação está de acordo com as classes de interesse propostas no trabalho de forma excelente.

Apesar das respostas aparentemente conflitantes, destaca-se o caráter complementar de ambas análises. A segunda análise indica que o processamento de imagens digitais pode ser um caminho viável e retifica os fundamentos teóricos por trás da análise. Apesar do tratamento válido, conforme verificado na 2ª análise, o resultado da 1ª análise trata das limitações do método diante das atuais limitações de técnica e tecnologia.

Um exemplo de tais limitações é dado pela resolução dos pixels das imagens. Tomando-se em comparação um loteamento médio com 100 m² de área, percebe-se que a resolução do Pixel de 30m x 30m como unidade básica de análise acarreta grandes imprecisões nos dados na evolução temporal da ocupação humana na região, justificando desse modo as grandes variações ano contra ano das coberturas para cada classe explicitadas na Tabela 4.1.

Percebe-se que o método é promissor e com o avanço da tecnologia de processamento de imagens, espera-se poder obter resultados ainda melhores, justificando portanto estudos posteriores e complementares aos efetuados nesse trabalho.

5.0 Conclusões

Conforme destacado durante a redação desta monografia, as abordagens clássicas de mensuração de efeitos econômicos, como a Matriz Insumo-Produto, podem não ser aplicáveis para mapear, medir e analisar a interdependência entre produtores e consumidores de bens e serviços associados à operação de um aeroporto regional, uma vez que tais abordagens, essencialmente econômicas, necessitam de um número elevado de estatísticas oficiais de diferentes indicadores macroeconômicos, os quais eventualmente podem não estar disponíveis para aplicação.

Portanto, o uso de modelos de geoprocessamento pode surgir como alternativa complementar à análise econômica tradicional, por meio da interpretação histórica da dinâmica espacial de ocupação das áreas no entorno do aeródromo objeto de estudo.

A aplicação das técnicas de geoestatísticas em uma sequência de imagens de satélite permitiu identificar as modificações temporais nas taxas de ocupação do uso do solo nas áreas do entorno do aeródromo de Chapecó. Ademais, os indicadores possíveis de serem medidos são: *taxa de uso do solo por cobertura da vegetação; taxa de uso do solo por cobertura de edificações; taxa de uso do solo por cobertura de vias terrestres.*

Por fim, o estudo foi bastante esclarecedor sobre a capacidade da metodologia em classificar o uso e ocupação do solo. O estudo também conseguiu apontar caminhos de pesquisa futuros e possíveis aperfeiçoamentos para a metodologia. É importante frisar que o sensoriamento remoto possui a tendência sempre disponibilizar novas tecnologias. Este estudo e estudos futuros são potencializados com novas tecnologias. Conclui-se que a pesquisa se mostra promissora para a finalidade que se aplica e conseguiu contribuir para o desenvolvimento do conhecimento.

Referências

ACRP, Airport Cooperative Research Program, ACRP Report 3 – Analysis of Aircraft Overruns and Undershoots for Runway Safety Areas, 2008.

ACRP, Airport Cooperative Research Program, ACRP Report 50 – Improved Models for Risk Assessment of Runway Safety Areas, 2011.

ALMEIDA, CM de; MONTEIRO, Antonio Miguel Vieira; CÂMARA, Gilberto. **Modelos de simulação e prognósticos de mudanças de uso do solo urbano: instrumento para o subsídio de ações e políticas públicas urbanas**. XI Encontro Nacional da Associação Nacional de Pesquisa em Planejamento Urbano e Regional-ANPUR (Bahia-Salvador), 2005.

AMARAL, Amara Borges; DE SOUZA RIOS, Aila. **Geoprocessamento: mapeamento do uso e ocupação do solo no alto curso do Rio Piedade**. Revista de Geografia-PPGEO-UFJF, v. 2, n. 1, 2012.

ARAÚJO-FILHO, José de Arimatéia Batista et al. **Inteligência artificial e imagem cardíaca: precisamos falar sobre isso**. Arq Bras Cardiol: Imagem Cardiovasc, v. 32, n. 3, p. 154-6, 2019.

ARONOFF, Stan. **Geographic information systems. A management perspective**, WDL Publicacions, Ottawa, Canada, 1989.

BARRETO, Cephass Alves da Silveira. **Uso de técnicas de aprendizado de máquina para identificação de perfis de uso de automóveis baseado em dados automotivos**. 2018. Dissertação de Mestrado. Universidade Federal do Rio Grande do Norte, UFRN, Brasil.

BEVILAQUA, Adriano; MARTINS, Jefferson Luís Ferreira. **Utilização de Imagens de Alta Resolução para Gerenciamento de Zonas de Proteção de Aeródromos**. Salão de Iniciação Científica (21.: 2009 out. 19-23: Porto Alegre, RS). Livro de resumos. Porto Alegre: UFRGS, 2009., 2009.

BRAGA, Ana Vitória et al. **Inteligência Artificial na Medicina**. CIPEEX, v. 2, p. 937-941, 2018.

BRASIL. **Lei no 13.097 de 19 de Janeiro de 2015.** Disponível <<http://www2.camara.leg.br/legin/fed/lei/2015/lei-13097-19-janeiro-2015-780071-normaatuallizada-pl.html>> . Acesso em: agosto de 2020.

CÂMARA, Gilberto; DAVIS, Clodoveu; MONTEIRO, Antônio Miguel Vieira. **Introdução à ciência da geoinformação.** Instituto Nacional de Pesquisas Espaciais, 2001.

DIAS, Danielle Furtado dos Santos. **Representações de séries temporais baseadas em imagens para classificação de imagens de satélite.** Tese de Doutorado, Universidade Estadual de Campinas, Instituto de Computação. 2020.

DIMITRIOU, Dimitrios et al. **An input output model to quantify the benefits of tourist airports on regional economy.** Journal of Air Transport Studies, v. 2, n. 2, p. 92-105, 2011.

COOPER, A.; SMITH, Ph. **The economic catalytic effects of air transport in Europe.** Studie des Oxford Economic Forecasting im Auftrag von EUROCONTROL, 2005.

FARINA, Flávia C. **Abordagem sobre as técnicas de geoprocessamento aplicadas ao planejamento e gestão urbana.** Cadernos EBAPE. br, v. 4, n. 4, p. 01-13, 2006.

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.** Simpósio Brasileiro de Sensoriamento Remoto, v. 13, p. 5755-5762, 2007.

FREITAS, Matheus F. Assmann; POLETO, Alex Sandro R. De Souza. **Um Estudo Exploratório Sobre Inteligência Artificial Aplicada à Medicina.** DEZEMBRO DE 2019, v. 2596, p. 88, 2019.

GAIAD, Natália Peixoto; MARTINS, Ana Paula Marques; DEBASTIANI, Aline Bernarda; Corte; SANQUETTA, CORTE, Ana Paula Dalla; SANQUETTA, Carlos Roberto. **Uso e cobertura da terra apoiados em algoritmos baseados em aprendizado de máquina: o caso de Mariana–MG.** Enciclopédia Biosfera, v. 14, n. 25, p. 1211-1220, 2017.

GIL, Antonio Carlos et al. **Como elaborar projetos de pesquisa.** São Paulo: Atlas, 2002.

GOOGLE. Google Earth website. <http://earth.google.com/>, 2020.

HUJER, Reinhard; KOKOT, Stefan. **Frankfurt Airport's impact on regional and national employment and income**. Institute for Statistics and Econometrics Postfach, v. 11, n. 19, p. 32, 2000.

HUMPHREYS, Ian; FRANCIS, Graham. **Performance measurement: a review of airports**. International journal of transport management, v. 1, n. 2, p. 79-85, 2002.

ICAO. International Civil Aviation Organization. **Aerodrome Design Manual: Parte 1 – Runways - Doc 9157**. 3a Edição. Montreal, 2006.

ICAO. International Civil Aviation Organization. **Aerodromes. International Standards and Recommended Practices. Annex 14 to the Convention on International Civil Aviation. Aerodrome Design and Operations**, vol. 1, fifth ed., Canada, 2009.

ICHIHARA, Silvio Massaru. **O uso combinado dos modelos de insumo-produto e técnicas de geoprocessamento**. 2007. Tese de Doutorado. Universidade de São Paulo.

JORGE, José-Doramas; DE RUS, Ginés. **Cost–benefit analysis of investments in airport infrastructure: a practical approach**. Journal of Air Transport Management, v. 10, n. 5, p. 311-326, 2004.

LÁZARO, Bruno de Oliveira. **Análise espacial e geoestatística aplicadas ao estudo de sistemas de transporte público urbano**. 2020. 30 f. Trabalho de Conclusão de Curso (Graduação em Engenharia Civil) - Universidade Federal de Uberlândia, 2020.

MONARD, Maria Carolina; BARANAUSKAS, José Augusto. **Conceitos sobre aprendizado de máquina. Sistemas inteligentes-Fundamentos e aplicações**, v. 1, n. 1, p. 32, 2003.

NEVES, Eduarda Araújo; FERREIRA, Juliana; OLIVEIRA, Thaynara Martins de; RIOS, Matheus Leonardo Martins Ribeiro; OLIVEIRA, Meire Ramalho. **Modais de transporte: Análise do panorama atual brasileiro e um estudo bibliométrico**. Anais XXXVIII Encontro Nacional de Engenharia de Produção, Maceió, Alagoas, Brasil. 2018.

NGULUBE, Patrick. **Cost analysis and the effective management of records throughout their life cycle**. Journal of the South African Society of Archivists, v. 44, p. 3-18, 2011.

NWANERI, V. C. **Equity in Cost-Benefit Analysis: A case study of the third London airport**. Journal of transport economics and policy, p. 235-254, 1970.

KUX, Herman; BLASCHKE, Thomas. **Sensoriamento Remoto e SIG Avançados**. 2007.

OLIVEIRA, Claudianne Brainer de Souza; CANDEIAS, Lúcia Bezerra; JÚNIOR, João Rodrigues Tavares. **Utilização de índices físicos a partir de imagens OLI-TIRS para o mapeamento de uso e cobertura da terra no entorno do aeroporto internacional do Recife/Guararapes - Gilberto Freire**. Revista Brasileira de Geografia Física, v. 12, n. 03, p. 1039-1053, 2019.

PERROCA, Márcia Galan; GAIDZINSKI, Raquel Rapone. **Avaliando a confiabilidade interavaliadores de um instrumento para classificação de pacientes: coeficiente Kappa**. Revista da Escola de Enfermagem da USP, v. 37, n. 1, p. 72-80, 2003.

PEREIRA, Carlos José de Almeida. **Geoprocessamento e computação inteligente: possibilidades, vantagens e necessidades**. Tese de Doutorado, Universidade Estadual Paulista, Instituto de Geociências e Ciências Exatas, 2008.

ROSA, Roberto; BRITO, Jorge Luis Silva. **Introdução ao geoprocessamento**. Uberlândia: Universidades Federais de Uberlândia, 1996.

SANTOS, Marcel Koenigkam et al. **Inteligência artificial, aprendizado de máquina, diagnóstico auxiliado por computador e radiômica: avanços da imagem rumo à medicina de precisão**. Radiologia Brasileira, v. 52, n. 6, p. 387-396, 2019.

ZUPPO, Carlos André et al. **Geoprocessamento no sistema de transporte e trânsito de Belo Horizonte**. Anais II GIS Brasil, p. 376-387, 1996.

ICAO. 2005. "Economic contribution of civil aviation (ECCA).International Civil Aviation Organization, Circular 292-AT."

Anexo

TABELA A.1 – Características de resolução do sensor TM LANDSAT-5.

Sensor	Bandas Espectrais	Resolução espectral	Resolução Espacial	Resolução Temporal	Área Imageada	Resolução Radiométrica
TM (Thematic Mapper)	(B1) Azul	0,45-0,52 μm	30 m	16 dias	185 Km	8 bits
	(B2) Verde	0,50-0,60 μm				
	(B3) Vermelho	0,63-0,69 μm				
	(B4) Infravermelho próximo	0,76-0,90 μm				
	(B5) Infravermelho médio	1,55-1,75 μm				
	(B6) Infravermelho Termal	10,4-12,5 μm	120 m			
	(B7) Infravermelho médio	2,08-2,35 μm	30 m			

TABELA A.2 Características de resolução do Sensor OLI LANDSAT-8.

Sensor	Bandas Espectrais	Resolução espectral	Resolução Espacial	Resolução Temporal	Área Imageada	Resolução Radiométrica
OLI (Operational Land Imager)	(B1) Azul costeiro	0,43-0,45 μm	30 m	16 dias	170x183 km	16 bits
	(B2) Azul	0,45-0,51 μm				
	(B3) Verde	0,53-0,59 μm				
	(B4) Vermelho	0,64-0,67 μm				
	(B5) Infravermelho próximo	0,85-0,88 μm				
	(B6) Infravermelho Médio	1,57-1,65 μm				
	(B7) Infravermelho Médio	2,11-2,29 μm				
	(B8) Pancromática	0,50-0,68 μm	15 m			
	(B9) Cirrus	1,36-1,38 μm	30 m			

TABELA A.3 - Valores de Kappa (K)

Ano	Kappa	Ano	Kappa
1984	0,970551	2003	0,886675
1985	0,974699	2005	0,937379
1986	0,94795	2006	0,965297
1987	0,961954	2007	0,928065
1988	0,978846	2008	0,941806
1989	0,977447	2009	0,942225
1990	0,943035	2010	0,964152
1991	0,970822	2011	0,962404
1992	0,984202	2015	0,957906
1993	0,962069	2016	0,957906
1994	0,916276	2017	0,974517
1995	0,940768	2018	0,912912
1996	0,985186	2019	0,912912
1997	0,871762	2020	0,902111
1999	0,916299		
2000	0,92601		
2001	0,949975		