



*Estudo de Casos para Medidas de
Proximidade com Tolerância tNM em
Comparação de Imagens*

Deivid de Almeida Padilha da Silva

Dezembro / 2018

Dissertação de Mestrado em Ciência da Computação

FICHA CATALOGRÁFICA

Ficha catalográfica elaborada pela
Biblioteca Central da UNIFACCAMP

S579e

Silva, Deivid de Almeida Padilha da

Estudo de casos para medidas de proximidade com tolerância tNM em comparação de imagens / Deivid de Almeida Padilha da Silva. Campo Limpo Paulista, SP: UNIFACCAMP, 2018.

Orientador: Prof^o. Dr^o. José Hiroki Saito

Dissertação (Programa de Mestrado em Ciência da Computação) – Centro Universitário Campo Limpo Paulista – UNIFACCAMP.

1. *Near Sets*. 2. Conjuntos próximos. 3. Conjuntos próximos com tolerância. 4. Atributos. 5. Tolerância. I. Saito, José Hiroki. II. Campo Limpo Paulista. III. Título.

CDD- 006.6

Estudo de Casos para Medidas de Proximidade com Tolerância tNM em Comparação de Imagens

Este documento corresponde à Dissertação de Mestrado Apresentado à Banca Examinadora para obtenção de título de Mestre em Ciência da Computação do Centro Universitário Campo Limpo Paulista.

Campo Limpo Paulista, 20 de dezembro de 2018.

Deivid de Almeida Padilha da Silva

José Hiroki Saito (orientador)

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

RESUMO

A teoria dos conjuntos próximos -Near Sets- e conjuntos próximos com tolerância -Tolerance Near Sets- fornecem uma base formal para a observação, comparação e classificação de objetos por meio de semelhanças determinadas através de vetores n-dimensionais de atributos. Essas bases teóricas fornecem um método para implementação de uma técnica que permite uma estimativa de quanto duas imagens são similares a partir de um valor de medida de proximidade com tolerância, (*tolerance Nearness Measurement* – tNM). Esta pesquisa tem como objetivo desenvolver um algoritmo para a comparação de pares de imagens com base no valor de tNM, de modo que as semelhanças entre as imagens sejam verificadas com relação a suas características, como Níveis de Cinza e valores estatísticos de segunda ordem extraídos de Matrizes de Co-ocorrência de Níveis de Cinza (*Gray Level Co-Occurrence Matrix* – GLCM). Essas informações são utilizadas para criação de classes no cálculo do tNM. Como aplicação de tNM foi feito um estudo de classificação de imagens de regiões centrais de cidades de dimensões compatíveis ao redor do mundo, cujos resultados são apresentados, dentre outros resultados.

Palavras-chave: Near Sets, conjuntos próximos, conjuntos próximos com tolerância, atributos, tolerância.

ABSTRACT

The theory of Near Sets and Tolerance Near Sets provides a formal basis for the observation, comparison, and classification of objects by means of similarities determined through n-dimensional attribute vectors. These theoretical bases provide a method for estimating how much two images are similar from a value of proximity measure with tolerance, (tolerance Nearness Measurement – tNM). This research aims to develop the implementation of an algorithm for the comparison of pair of images based on tNM value. Thus, the similarities between the images are verified with respect to their characteristics, such as Gray Levels and second order statistical values extracted from Gray Level Co-Occurrence Matrices (GLCM). This information is used to create classes in the tNM calculation. As an application, it was calculated the tNM between pair of central regions images of cities with compatible dimensions, selected along the world, and the results are presented, among other results.

Keywords: Near Sets, Tolerance Near Sets, Features, tolerance

Agradecimentos

À Deus e aos meus familiares pelo apoio e auxílio nessa fase da minha vida, garantindo forças para que mais uma etapa seja alcançada.

Ao Prof. Dr. Saito, que foi sempre gentil, amigável e extremamente paciente, auxiliando-me nos ensinamentos e orientações.

À CAPES e aos professores e funcionários do programa de mestrado em Ciência da Computação do Centro Universitário Campo Limpo Paulista pela oportunidade e suporte.

LISTA DE FIGURAS

Figura 1: Ilustração do posicionamento dos elementos numa reta, a vizinhança do elemento x_1 . Fonte: Autor dessa dissertação.	20
Figura 2: Ilustração da vizinhança do elemento x_4 . Fonte: Autor dessa dissertação.	21
Figura 3: Exemplo de cálculo de Medida de Proximidade para a equação 6. Fonte: Adaptada de Henry (2010).	22
Figura 4: Classes de tolerância quando $\epsilon=0,2$. Fonte: Adaptada de Henry (2010).	23
Figura 5: Obtenção de GLCM: (a) imagem de entrada de dimensão 4×4 e 4 níveis de cinza; matriz indicado os tipos de pares de pixels a serem considerados na obtenção do GLCM; (c) matriz GLCM resultante. (b) Fonte: Adaptada de Hall-Beyer (2005).	27
Figura 6: Fluxograma do método proposto para a obtenção das classes das imagens X e Y e tNM. Fonte: Autor dessa dissertação.	33
Figura 7: Pseudocódigo NC do algoritmo tNM. Fonte: Autor dessa dissertação.	34
Figura 8: Pseudocódigo AE do algoritmo tNM. Fonte: Autor dessa dissertação.	35
Figura 9: Cuiabá antes. Fonte: Google Maps.	38
Figura 10: Cuiabá Depois. Fonte: Autor dessa dissertação.	39
Figura 11: Cuiabá-MT, Brasil. Fonte: Google Maps.	40
Figura 12: Imagem Mona Lisa. Fonte: https://code.google.com/archive/p/evocubist/downloads	41
Figura 13: Comparação de Dados Cuiabá - NC. Fonte: Autor dessa dissertação.	42
Figura 14: Comparação de Dados Cuiabá - AE. Fonte: Autor dessa dissertação.	43

Figura 15: Comparação de Dados Mona Lisa - NC. Fonte: Autor dessa dissertação.....	44
Figura 16: Comparação de Dados Mona Lisa - AE. Fonte: Autor dessa dissertação.....	44
Figura 17: Paisagem_1. Fonte: Autor dessa dissertação.....	45
Figura 18: Paisagem_2. Fonte: Autor dessa dissertação.....	46
Figura 19: Paisagens - NC. Fonte: Autor dessa dissertação.....	47
Figura 20: Paisagens - AE. Fonte: Autor dessa dissertação.....	47
Figura 21: Paisagens Pixel por Classes (a) Paisagem_1 e (b) Paisagem_2 Respectivamente – NC, tolerância de 10%. Fonte: Autor dessa dissertação. ..	48
Figura 22: Paisagens Pixel por Classes (a) Paisagem_1 e (b) Paisagem_2 Respectivamente, para tolerância zero. Fonte: Autor dessa dissertação.....	49
Figura 23: Histograma de classes (a) Paisagem_1 e (b) Paisagem_2, na abordagem AE, com $\alpha = 0,1$ e tamanho de subimagem de 10x10. Fonte: Autor dessa dissertação.	50
Figura 24: Histograma de classes (a) Paisagem_1 e (b) Paisagem_2, na abordagem AE, com $\alpha = 0,1$ e tamanho de subimagem de 4x4. Fonte: Autor dessa dissertação.	51
Figura 25: (a) imagem 1 - Cidade do México e (b) imagem 2 - Frankfurt. Fonte: Autor dessa dissertação.....	53
Figura 26: Experimento imagem 600x600. (a) abordagem NC e (b) abordagem AE. Fonte: Autor dessa dissertação.....	54
Figura 27: Histograma de classes para NC. (a) imagem 1 e (b) imagem 2, experimento 101. Fonte: Autor dessa dissertação.....	55
Figura 28: Histograma de classes para abordagem AE, experimento 102: (a) imagem 1 e (b) imagem2. Fonte: Próprio autor dessa dissertação.....	55
Figure 29: tNM em função do tamanho das subimagens. Fonte: Autor dessa dissertação.....	57

Figure 30: tNM em função da tolerância: (a) NC e (b) AE. (a) Fonte: Autor dessa dissertação.	58
Figura 31: (a) Mulher antes e (b) Mulher depois da feminização. Fonte: https://www.t-change.com/pt/feminizacao-facial-antes-e-depois.php	59
Figura 32: Resultado do experimento 73. Fonte: Autor dessa dissertação.	60
Figura 33: (a) Mulher antes e (b) Mulher depois do tratamento de manchas. Fonte: http://www.julianagoes.com.br/luz-pulsada-antes-e-depois-tratamento-de-manchas/	60
Figura 34: Resultado para o experimento 74. Fonte: Autor dessa dissertação.	61
Figura 35: (a) Imagem de face feminina antes e (b) após a aplicação de software edição, de rejuvenescimento. Fonte: https://www.tuasaude.com/lifting-facial/	61
Figura 36: Resultado do Experimento 75. Fonte: Autor dessa dissertação.....	62
Figura 37: (a) Imagem de Face Feminina antes e (b) Depois de procedimento estético; (c) parte central (secção) da imagem (a); e (d) parte central (secção) da imagem (b) . Fonte: http://daiannepossoly.com.br/video-botox-25-anos-antes-e-depois/	63
Figura 38: Resultados de NC (esquerda) e AE (direita). Fonte: Autor dessa dissertação.....	63
Figura 39: (a) Imagens de áreas antes do desmatamento, e (b) depois do desmatamento. Fonte: https://blogs.oglobo.globo.com/ancelmo/post/satelite-flagra-desmatamento-em-ilha-que-costumava-ser-alugada-por-revista.html	65
Figura 40: (a) imagens de áreas antes do desmatamento, e (b) depois do desmatamento. fonte: http://g1.globo.com/Amazonia/0,,MUL1363591-16052,00-PROJETO+DE+LEI+PROPOE+ANISTIA+A+QUEM+DESMATOU+ANTES+DE.html	65
Figura 41: (a) imagem de área antes do desmatamento, e (b) depois do desmatamento.	Fonte:

https://elpais.com/elpais/2017/09/12/album/1505218806_296425.html#foto_gal_3	66
Figura 42: Resultado do experimentos 80, 81 e 82. Fonte: Autor dessa dissertação.....	66
Figure 43: Gráfico de classificação usado os resultados de tNM em NC. Autor dessa dissertação.	70
Figure 44: Gráfico de classificação usando os resultados de tNM em AE. Fonte Autor dessa dissertação.....	72
Figura 45: Imagens de cidades: (a) Regina, (b) Edmonton, (c) Pointe Noire, com maiores valores de tNM em NC (Regina x Edmonton); e em AE (Regina x Pointe Noire). Fonte: Autor dessa dissertação.....	74
Figura 46: Valores de tNM para NC e AE, entre a imagem de Regina comparada com imagens de todas as outras cidades consideradas, mostrando o maior valor em ambas as abordagens. Fonte: Autor dessa dissertação.....	75
Figura 47: Imagens de Cidades: (a) Monrovia, (b) Newcastle, com menor valor de tNM na abordagem NC. Fonte: Autor dessa dissertação	76
Figura 48: Valores de tNM para NC e AE, obtidos quando a imagem de Monrovia é computada com imagens de todas as outras cidades consideradas, destacando o menor valor em NC. Fonte: Autor dessa dissertação	76
Figura 49: Imagens de cidades: (a) Matola, (b) Camberra, com menores valores de tNM na abordagem AE. Fonte: Autor dessa dissertação	77
Figura 50: Valores de tNM para NC e AE, obtidas comparando a imagem de Matola com demais imagens de cidades consideradas, destacando o menor valor de tNM na abordagem AE. Fonte: Autor dessa dissertação.....	78
Figura 51: Gráfico comparativo das abordagens NC e AE, para os valores de tNM obtidas para a cidade de Cuiabá versus demais cidades. Fonte: Autor dessa dissertação.	79

LISTA DE TABELAS

Tabela 1 : Valores de dados reais.....	19
Tabela 2: Fórmulas para o cálculo de atributos de uma matriz de GLCM.....	28
Tabela 3 Cidades usadas nos teste preliminares.....	56
Tabela 4: Resumo os experimentos sobre imagens faciais	64
Tabela 5: Resumo os experimentos sobre imagens de áreas desmatadas	67
Tabela 6: Cidades cujas imagens foram consideradas	68
Tabela 7: Tabela de classes em abordagem NC	69
Tabela 8: Tabela de classes AE.....	71
Tabela 9: Maiores valos de tNM obtidos na abordagem NC.	73
Tabela 10: Maiores valores de tNM obtidos na abordagem AE.	74
Tabela 11: Cinco menores valores de tNM, obtidos para a abordagem NC.	75
Tabela 12: Cinco menores valores de tNM obtidos para a abordagem AE.....	77
Tabela 13 (a): Valores de tNM em ordem decrescente na abordagem NC de Cuiabá versus demais cidades, e o valor médio.	80
Tabela 13 (b): Valores de tNM em ordem decrescente na abordagem AE de Cuiabá versus demais cidades, e o valor médio.	80
Tabela 14: Média de tNM entre continentes, em abordagem NC.....	81
Tabela 15: tNM médio entre continentes em abordagem AE.....	82

LISTA DE ABREVIATURAS E SIGLAS

AE - Atributo Estatístico (*Statistical Attribute*)

FP - Função de Prova (*Probe Function*)

CBIR - Recuperação de imagem baseada em conteúdo (*Content-Based Image Retrieval*)

GLCM - Matriz de Co-ocorrência em Níveis de Cinza (*Gray Level Co-occurrence Matrix*)

NC - Níveis de Cinza (*Gray Levels*)

NS - Conjuntos Próximos (*Near Sets*)

RGB - Vermelho, Verde e Azul (*Red, Green and Blue*)

RP - Reconhecimento de Padrão (*Pattern Recognition*)

TC - Classe de Tolerância (*Tolerance Class*)

tNM - Medida de Proximidade com Tolerância (*Tolerance Nearness Measure*)

TNS - Conjuntos Próximos com Tolerância (*Tolerance Near Sets*)

SUMÁRIO

Capítulo 1	9
Introdução.....	9
1.1 Contexto e Motivação.....	9
1.2 Objetivo	11
1.2.1 Objetivos específicos.....	12
1.3 Principais Contribuições.....	12
1.4 Organização do trabalho	12
Capítulo 2	14
Revisão Bibliográfica	14
2.1 Detalhando Near Sets	14
2.1.1 Sistemas Perceptuais.....	15
2.1.2 Objeto perceptual	15
2.1.3 Função de prova	16
2.1.4 Sistema Perceptivo ou Perceptual	16
2.1.5 Descrição do objeto.....	16
2.1.6 Relação de indiscernibilidade perceptiva	17
2.1.7 Relação Binária e de Equivalência.....	17
2.1.8 Relação de Indiscernibilidade Perceptual Fraca	18
2.2 Tolerance Near Sets	18
2.2.1 Relação de tolerância perceptual	18
2.2.2 Definição de medida de proximidade	22
2.3 Imagens em tons de cinza	23
2.4 Textura	24
2.5 Matriz de Co-ocorrência em níveis de cinza	24
2.5.1 Propriedades da matriz GLCM	25
2.5.2 Exemplo de obtenção do GLCM	26
2.6 Reconhecimento de Padrões	29

2.7 Trabalhos Relacionados.....	30
2.8 Considerações finais	31
Capítulo 3	32
Materiais e Métodos utilizados.....	32
3.1 Visão Geral.....	32
3.2 Princípios de Funcionamento do algoritmo de tNM.....	32
3.3 Imagens Utilizadas e Análise dos Resultados.....	36
3.4 Considerações Finais.....	36
Capítulo 4	37
Experimento, Resultados e Discussões.....	37
4.1 Visão Geral dos Experimentos	37
4.2 Padronização de Imagens de Entrada	38
4.3 Testes Preliminares com Mesmas Imagens.....	39
4.4 Testes Preliminares com Imagens Diferentes de Paisagens	45
4.5 Considerações em Relação ao Tempo de Processamento	52
4.6 Testes Preliminares com Imagens de Diferentes Cidades	52
4.6.1 tNM Variando as Subimagens e Tolerâncias	56
4.7 Experimentos com a Utilização dos Parâmetros Padrões.....	59
4.7.1 Imagens faciais	59
4.7.1.1 Experimento 73.	59
4.7.1.2 Experimento 74	60
4.7.1.3 Experimento 75	61
4.7.1.4 Experimento 76	62
4.7.2 Imagens de áreas desmatadas	64
4.7.3 Imagens de Regiões Centrais de Cidades	67
4.8 Análise e Validação dos Resultados	72
4.8.1 Maiores e Menores Valores de tNM Obtidos.....	72

4.8.2	Comparação Entre as Duas Abordagens	78
4.8.3	Média de Valores de tNM entre Continentes	81
4.9	Discussões	82
4.10	Considerações Finais	83
Capítulo 5	84
Conclusões e Propostas de Trabalhos Futuros	84
5.1	Conclusões.....	84
5.2	Principais Contribuições	85
5.3	Trabalhos Futuros	85
5.4	Considerações Finais.....	86
Referências.....	87
Apêndice A	Imagens de Cidades Utilizadas	89
Apêndice B	Resultados de cálculo de tNM entre as cidades.....	95
Apêndice C	Gráficos do Cálculo de tNM.....	114

Capítulo 1

Introdução

O presente capítulo contextualiza o projeto proposto, apresenta os objetivos assim como os problemas e motivações para a realização desta pesquisa e a estrutura do trabalho.

1.1 Contexto e Motivação

A sociedade desde o início de sua existência vem se comunicando e usando códigos diferenciados. De acordo com Artero (2009), estima-se que cerca de 70% do processamento cerebral seja destinado ao tratamento das imagens capturadas pelos olhos. Pode-se dizer que o avanço na sociedade é inerente à visão, que facilita e contribui para a realização de tarefas que seriam complexas sem a presença desse recurso natural nos seres vivos. A visão permite capturar imagens para serem processadas pelo cérebro. Esse processamento culmina com o retorno de informações a serem analisadas por uma pessoa (Artero, 2009). Em um computador, realizar processamento de imagens é igualmente complexo e trabalhoso.

Os olhos dos seres humanos capturam uma dada imagem, em seguida o cérebro assimila determinada informação referente à imagem capturada, percebendo o que se passa ao seu redor. Contudo, os olhos humanos, em vários casos, não conseguem observar os detalhes, e com isso padronizar os efeitos em imagens quando há uma pequena diferença. Assim, visamos abordar como proposta de dissertação de mestrado a aplicação de uma teoria para extrair informações das imagens e em seguida usá-las para comparar imagens, indicando a proximidade entre elas, favorecendo assim, um meio pelo qual utiliza-se de análise quantitativa para comparação entre imagens. Essa teoria é conhecida como *Near Sets* (Pawlak & Peters, 2007). *Near Sets* será

denotado *NS* para simplificação. É uma teoria que trata, dentre outras coisas, de conjuntos e análise de objetos a partir de seus atributos.

Existem inúmeras aplicações voltadas para análise de imagens que se aplicam em diferentes domínios como código de barras, comparação entre fotos de satélites, procura de regiões geográficas, verificação de áreas desmatadas, entre outros, algumas questões neste sentido são tratadas no final do capítulo dois. Essas aplicações precisam ser constantemente melhoradas, contribuindo assim para realização de sua tarefa com maior eficácia, e tal fato demonstra a importância para a realização de pesquisas nessa área.

No campo de processamento de imagens, existem diversas motivações para o aperfeiçoamento das técnicas nas mais variadas aplicações, como em reconhecimento facial e identificação de fungos em folhas, considerando que a técnica proposta a ser implementada utiliza-se de características das imagens como, cor e textura. Pode-se citar como um exemplo da aplicação de *NS* o seguinte caso no ramo da informática, em que um problema é apresentado e a solução para esse problema utiliza a teoria de *NS*. Considera-se uma empresa que usa um *software* destinado a receber arquivos digitalizados e encaminhá-los para o setor responsável com base no assunto do documento. Para que tudo ocorra de maneira correta, o programa deve "ler" o que se encontra no documento para saber qual procedimento deverá ser realizado. Como exemplo, se há a palavra "recurso", no escopo de recurso jurídico, e esta aparecer várias vezes, o *software* deve encaminhar o material para o setor jurídico. Nesse sentido, quando usamos *NS* para identificação de imagens que tratam de um mesmo objetivo, estaríamos utilizando os sensores (funções de prova / vetor para armazenagem de atributos) para encontrar o que se quer (algum objeto similar) e então tomar uma providência. Outro exemplo é o da utilização da técnica para verificar a similaridade entre assinaturas digitalizadas de uma mesma pessoa, com o intuito de se encontrar os documentos que estão digitalizados e armazenados em um banco de dados de uma empresa. Para essa finalidade os itens a serem comparados devem estar sobre o mesmo padrão de obtenção.

É pertinente deixar claro que a recuperação de imagem com base em conteúdo é de extrema importância. Eakins, J. & Graham, M. da universidade de Northumbria em Newcastle, mantem um site que trata de uma revisão do estado da arte acerca de recuperação de imagem baseada em conteúdo (CBIR - Content-Based Image Retrieval). Na conjuntura atual é fácil encontrar um programa que faça a busca de uma cadeia de caracteres. Contudo, de acordo com Russel & Norvig (2004), um *software* que encontre um subconjunto de pixels correspondente a um objeto requerido é muito importante, à medida que as coleções de vídeos e imagens aumentam em grande escala. Assim programas que fazem uso de técnicas para extração de informação de pixels em imagens devem ser desenvolvidos e melhorados para atenderem a essa demanda atual.

Utilizando conceitos de *NS*, é possível implementar a classificação das subimagens da imagem com base em suas características que permite comparar duas imagens. Vários algoritmos são usados para classificar detalhes em imagens, como por exemplo, usando pacotes *wavelet* (Peters et al. 2016) ou a medida de proximidade com tolerância, *tNM* (*Tolerance Nearness Measure*, em inglês) que faz parte da teoria *NS* (Henry, 2010), entre outros. Esta Dissertação de Mestrado envolve a análise de imagens, tomando como base a medida de proximidade *tNM*, que apresenta vantagens pela possibilidade de paralelização, para encontrar todas as classes de tolerância em um conjunto de objetos (Henry, 2010). Para calcular a textura de imagens é comum utilizar o conceito de co-ocorrência de níveis de cinza, como o algoritmo *GLCM* (*Gray-Level Co-occurrence Matrix*, em inglês) (Haralick et al., 1973).

Em seguida apresentamos os objetivos para a pesquisa.

1.2 Objetivo

- Implementar um estudo de caso para comparação de imagens utilizando conceitos de *NS* e com base em *tNM*, realizar aplicações, medir o desempenho e realizar a validação.

1.2.1 Objetivos específicos

Desenvolver um software em *Python* que realize as etapas abaixo.

- Converter uma imagem em níveis de cinza;
- Extrair a matriz *GLCM* da imagem de níveis de cinza;
- Aplicar fórmulas para extração de características estatísticas da matriz *GLCM*;
- Utilizar os níveis de cinza e as características estatísticas para criação de classes;
- Aplicar o cálculo do *tNM* para diversos pares de imagens;
- Verificar e discutir os resultados retornados a partir da comparação de pares de imagens bem como avaliar a eficácia destes.

1.3 Principais Contribuições

As principais contribuições deste trabalho de dissertação podem ser descritas como:

- Desenvolvimento de um método para comparar imagens a partir de níveis de cinza dos pixels, usando o conceito de *TNS* e *tNM*.
- Desenvolvimento de um método para comparar imagens a partir de atributos estatísticos sobre a distribuição dos níveis de cinza de pixels, no conceito de *TNS* e *tNM*.
- Desenvolvimento de um método de comparação de centros urbanos, usando as duas abordagens de obtenção de *tNM*.

1.4 Organização do trabalho

Este trabalho está dividido em cinco (5) capítulos:

- Capítulo 1: o capítulo de introdução presente;
- Capítulo 2: que compreende a revisão bibliográfica relacionado às técnicas de *NS*, *TNS*, *tNM* e *GLCM*; e trabalhos correlatos.

- Capítulo 3: que apresenta os materiais e métodos utilizados.
- Capítulo 4: que contém os experimentos, resultados e discussões levantadas de acordo com os resultados.
- Capítulo 5: que apresenta as conclusões e trabalhos futuros.

Capítulo 2

Revisão Bibliográfica

O objetivo deste capítulo é descrever as teorias, conceitos e terminologias para este trabalho, abordando os fundamentos base para os procedimentos propostos na pesquisa. Apresenta informações complementares que são consideradas fundamentais para o seu entendimento tais como princípios de Near Sets, Tolerance Near Sets, GLCM, tNM entre outros, além da descrição dos principais trabalhos correlatos.

2.1 Detalhando Near Sets

Esta seção tem por objetivo elencar pontos introdutórios e importantes da teoria de *NS* bem como realizar uma breve explanação de seu funcionamento e suas aplicações com foco no campo de processamento de imagem.

Como aplicação de *NS*, conjuntos de dados coletados nas diversas áreas do conhecimento em ciências e engenharias podem ser classificadas de acordo com suas semelhanças. Uma das técnicas empregadas para essa classificação utiliza vetores *n*-dimensionais de características numéricas que representam atributos de objetos, como valores de pixel digital de imagem. Os dados ao serem classificados são considerados conjuntos que possuem características semelhantes (Peters & Wasilewski, 2009).

A teoria de *NS* é material de pesquisa muito requisitado atualmente, porém, teve seus princípios iniciados há muito tempo, por Frigyes Riesz que realizou uma abordagem da teoria de proximidade matematicamente em 1908. Posteriormente Z. Pawlak e Orłwska abordaram Conjunto Bruto (*Rough Sets* em inglês) e aproximação de espaços, respectivamente (Pawlak 1981). A teoria de *NS* foi proposta por James Peters (2007). Em 2010 Christopher Henry trabalha sobre a teoria de *NS* em sua tese de doutorado e em uma ação

conjunta Henry e Peters criaram o *tNM* para se determinar o grau em que dois objetos se assemelham.

Em nosso cotidiano fazer relação entre objetos ou itens que se assemelham é muito comum, por exemplo, ao comparar cores de uma camisa ou a estrutura de algum objeto. Assim como, comparar o tamanho de duas árvores e verificar se elas se assemelham entre si na característica altura, é possível verificar o quão se assemelham dois objetos. No escopo computacional pode-se utilizar uma função de prova (*probe function* em inglês) para a realização dessa atividade. O sentido visual humano é capaz de capturar as características de um objeto. A função de prova (*FP*) pode ser utilizada para a atividade de capturar características de objetos para comparação com outro objeto. As características físicas de um objeto são seus atributos e podem ser capturados por uma *FP*.

2.1.1 Sistemas Perceptuais

Uma das formas para explicar a teoria *NS* é a partir das definições de conceitos chaves, como objetos perceptivos ou perceptuais, descrição do objeto e relação de indiscernibilidade perceptiva. Para descrever melhor como é a base matemática que envolve *NS* temos as seguintes definições.

2.1.2 Objeto perceptual

A definição de objeto perceptual referencia a capacidade humana de compreensão e interpretação acerca de algo que exista no mundo físico em relação às suas características intrínsecas, ou seja, objetos que existam no mundo físico e tenham características que podem ser medidas e compreendidas pela mente humana. Nesse contexto a percepção retrata a capacidade de se observar uma característica/atributo, de um objeto que pode ser medido de um objeto, como por exemplo a variação de cores ou brilho nos pixels em diferentes objetos. Exemplos de objeto perceptível incluem pacientes, componentes pertencentes a um processo de fabricação e imagens de câmera (Henry, 2010). Pavel (1993) reitera em sua abordagem de reconhecimento de

padrões, que as características de um objeto são quantificadas por funções de prova.

2.1.3 Função de prova

Considerando-se as características de objetos, como por exemplo, uma planta que contém folhas com coloração verde ou, formato alongado, uma função de prova é uma função de valores reais que representa uma característica de um objeto perceptual, ou seja, a cor verde ou formato alongado da folha. Como o foco deste trabalho é análise de imagens sobre *NS*, podemos utilizar as *FP* em termos de imagens digitais, tais como: cor, textura, contorno, orientação espacial e comprimento de segmentos de linha ao longo de uma região delimitada. Logo, para verificarmos se dois objetos perceptíveis são semelhantes, ou são associados a um mesmo padrão, utilizam-se *FPs*.

2.1.4 Sistema Perceptivo ou Perceptual

Um sistema perceptivo (O, F) consiste em um conjunto não vazio de objetos perceptivos e um conjunto não vazio F de *FPs* de valores reais (Henry, 2010).

$$\Phi \in F \mid \Phi: O \rightarrow \mathbb{R} \quad (1)$$

Considerando uma imagem e suas características mensuráveis como níveis de cinza, um sistema perceptível engloba a imagem, visto que a imagem contém o conjunto de objetos e suas características em níveis de cinza, *FPs*.

2.1.5 Descrição do objeto

Seja (O, F) , um sistema perceptivo, e $B \subseteq F$, um subconjunto de funções de prova. Então, a descrição de um objeto perceptual $X \in O$ possui uma característica dada pelo vetor:

$$\Phi_B(x) = (\Phi_1(x), \Phi_2(x), \dots, \Phi_l(x), \dots, \Phi_l(x)), \quad (2)$$

onde: " l " é o comprimento do vetor $\Phi_B(x)$ e cada $\Phi_i(x)$ é um função de prova. Isso faz parte da descrição do objeto $X \in O$ (Henry, 2010).

Ao se definir a descrição de objeto dessa forma, tem-se a descrição de um espaço de atributos. A descrição de um objeto pode ser considerada num

espaço euclidiano l dimensional, R^l , chamado um espaço de atributo. A teoria de *NS* preocupa-se com a proximidade dos objetos com base em suas descrições. Assim, a relação entre objetos é descoberta em um espaço de atributos que é determinado pelas *FPs* em B (Henry, 2010).

2.1.6 Relação de indiscernibilidade perceptiva

Seja (O, F) um sistema perceptual. Para cada $B \subseteq F$, a relação de indiscernibilidade perceptiva \sim_B é definida:

$$\sim_B = \{(x, y) \in O \times O : \forall \phi_i \in B. \phi_i(x) = \phi_i(y)\}, \quad (3)$$

ou seja, dois elementos x e y estão relacionados pela indiscernibilidade perceptiva se eles possuem um mesmo valor para todas as funções de prova no conjunto B , implementadas por ϕ_i (\cdot).

Utilizando a relação de indiscernibilidade sobre um conjunto de objetos de um sistema perceptivo, é possível obter classes de objetos equivalentes.

2.1.7 Relação Binária e de Equivalência

Uma relação binária do conjunto A no conjunto B é um subconjunto do produto cartesiano $A \times B$. Para indicar que um par $\langle x, y \rangle$ pertence à relação R , escreve-se $\langle x, y \rangle \in R$ ou $x R y$.

Exemplo (a) Seja $A = \{1, 2, 3\}$ e $B = \{a, b\}$, o conjunto $R = \{\langle 1, a \rangle, \langle 1, b \rangle, \langle 3, a \rangle\}$, é uma relação de A em B . Além disso $\langle 1, a \rangle \in R$, $\langle 2, b \rangle \notin R$, $\langle 3, a \rangle \in R$ (Nicoletti & Hruschka, 2006).

A relação R no conjunto A é de equivalência se satisfizer as propriedades abaixo:

1. Reflexiva: se xRx para todo $x \in A$
2. Simétrica: se $\langle x, y \rangle \in R$ para $x, y \in A \rightarrow \langle y, x \rangle \in R$
3. Transitiva: se $\langle x, y \rangle \in R$ e $\langle y, z \rangle \in R$ para $x, y, z \in A \rightarrow \langle x, z \rangle \in R$.

Assim a relação de equivalência é atendida nos quesitos de simetria, transitividade e reflexividade entre os elementos do conjunto, de modo que uma relação binária é mantida ao se dividir o conjunto em um conjunto menor aplicando as três propriedades acima citadas. Existirá relação de equivalência se dado um conjunto $A, \forall a \in A, aRa$, (Reflexiva); $\forall a, b \in A$, se aRb então bRa (Simétrica); $\forall a, b, c \in A$, aRb e bRc então aRc (transitiva), para todos os elementos de cada classe.

2.1.8 Relação de Indiscernibilidade Perceptual Fraca

Seja (O, F) um sistema perceptual e seja $\Phi_i \in F$. Então, a relação de indiscernibilidade perceptual fraca \simeq_{Φ_i} é definida da seguinte forma:

$$\simeq_{\Phi_i} = \{ (x, y) \in O \times O : \exists \Phi_i \in F . \Phi_i(x) = \Phi_i(y) \}, \quad (4)$$

Observa-se que essa relação de indiscernibilidade é tida como fraca porque não há uma exigência para satisfazer todas as FPs ; apenas uma das FPs com valores iguais para x e y , é suficiente.

2.2 Tolerance Near Sets

Os Conjuntos Próximos com Tolerância, TNS , é uma alteração da teoria de NS , utilizada para verificar a similaridade entre dois objetos com tolerância em relação aos valores de função de prova.

2.2.1 Relação de tolerância perceptual

Seja (O, F) um sistema perceptual. Para cada $B \subseteq F$, a relação de tolerância perceptual é dada pela equação 5, em que a norma do vetor é L^2 indicada por " $\| \cdot \|$ ". Notadamente a distância utilizada é a Euclidiana que é um caso particular da distância de Minkowski.

$$\sim_{B \in} = \{ (x, y) \in O \times O : \| \Phi(x) - \Phi(y) \|_2 \leq \varepsilon \} \quad (5)$$

Em função da relação de tolerância perceptual é possível classificar objetos, conforme o seguinte exemplo sobre dados reais (Tabela 1), onde um objeto x_i tem um único atributo que é o seu valor numérico $\phi_i(x)$.

Tabela 1 : Valores de dados reais.

x_i	$\phi_i(x)$	x_i	$\phi_i(x)$
x_1	0,12	x_6	0,75
x_2	0,13	x_7	0,77
x_3	0,21	x_8	0,84
x_4	0,31	x_9	0,53
x_5	0,40	x_{10}	0,64

Fonte: Autor dessa dissertação.

Considerando-se a adoção de $\varepsilon = 0,1$, os objetos x_i , $i = 1, \dots, 10$, podem ser agrupados nas seguintes classes: $\{x_1, x_2, x_3\}$, $\{x_3, x_4\}$, $\{x_4, x_5\}$, $\{x_9\}$, $\{x_6, x_7, x_8\}$ e $\{x_{10}\}$.

Nota-se que para cada classe a norma de vetor de distância entre dois elementos é $\leq \varepsilon = 0,1$. Por exemplo, a classe constituída dos elementos x_1, x_2, x_3 a distância entre x_1 e x_2 é 0,01, entre x_2 e x_3 , 0,08, e entre x_1 e x_3 , 0,09.

Para se obter as classes pode ser utilizado o algoritmo C, para classificação, descrito para o caso de elementos, com atributos unidimensionais. O algoritmo está considerando uma classificação de n elementos.

Algoritmo C: Classificação

- 1) Para todos os elementos x_i , $i = 1..n$, obter a relação de vizinhos v_i , $i = 1..v$, com a distância menor ou igual a ε .
- 2) Para cada elemento x_i :
 - criar uma classe, incluindo o próprio elemento x_i como pertencente à classe;

- 2.1) escolher um vizinho x_j , dentro da relação de vizinhos v_i obtida no passo 1, agora denotado v_i' ; que seja mais próximo ao elemento x_i ;
 - verificar a distância entre x_j e outros vizinhos contidos em v_i' , sendo que os vizinhos com distância maior que ε devem ser excluídos de v_i' ;
 - incluir x_j na classe, e excluí-lo v_i' ;
- 2.2) repetir o passo 2.1, com a nova relação de vizinhos v_i' , até que esta se esvazie;
- 2.3) verificar se tem vizinhos remanescentes, ainda não pertencentes a nenhuma das classes criadas para x_i . Se isso ocorrer, repetir os passos a partir do início da etapa 2 com os remanescentes.

Para ilustrar o funcionamento do Algoritmo C, consideramos o gráfico da Fig.1, correspondentes aos elementos da Tabela 1.

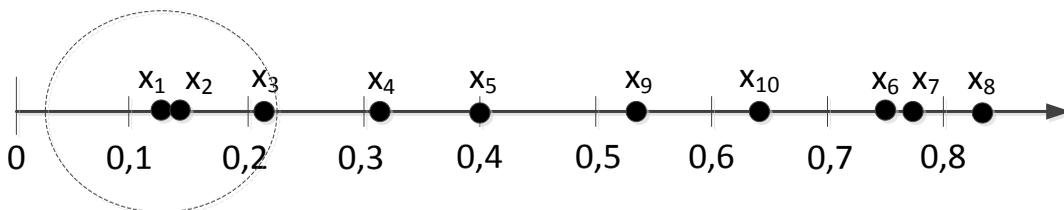


Figura 1: Ilustração do posicionamento dos elementos numa reta, a vizinhança do elemento x_1 . Fonte: Autor dessa dissertação.

Ao aplicarmos o Algoritmo C, o primeiro elemento a ser considerado seria x_1 , em que a vizinhança v_1 é constituída dos elementos $v_1 = v_1' = \{x_2 \text{ e } x_3\}$, que estão internos à circunferência de raio $\varepsilon = 0,1$ com centro em x_1 . No início da etapa (2), é criada uma classe C_1 , contendo o elemento x_1 , $C_1 = \{x_1\}$. O vizinho mais próximo de x_1 é x_2 . Portanto, verifica-se se a distância de x_2 e x_3 está dentro da tolerância, que no caso está. Portanto, inclui-se x_2 na classe, $C_1 = \{x_1, x_2\}$. E a vizinhança fica $v_1' = \{x_3\}$. Como só tem um elemento em v_1' , o mesmo é incluído na classe, $C_1 = \{x_1, x_2, x_3\}$. Como não tem vizinhos remanescentes, a etapa (2) termina para o elemento x_1 .

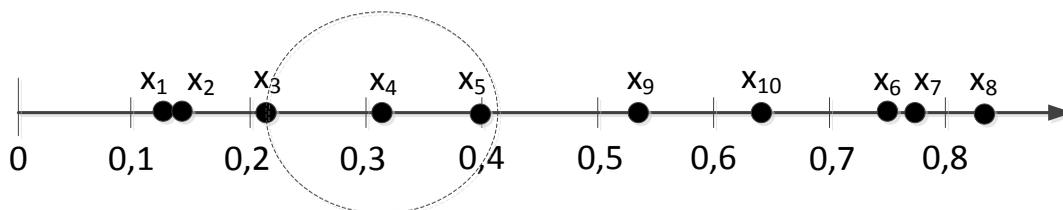


Figura 2: Ilustração da vizinhança do elemento x_4 . Fonte: Autor dessa dissertação.

Seja agora, a aplicação do Algoritmo C, para o elemento x_4 , em que a vizinhança v_4 é constituída dos elementos $v_4 = v_4' = \{x_3, x_5\}$, que estão internos à circunferência de raio $\varepsilon = 0,1$ com centro em x_4 , Fig.2.

No início da etapa (2), é criada uma classe C_4 , contendo o elemento x_4 , $C_4 = \{x_4\}$. O vizinho mais próximo de x_4 é x_5 . Portanto, verifica-se se a distância de x_3 e x_5 está dentro da tolerância, que no caso não está, e a vizinhança fica $v_4' = \{x_5\}$. Em seguida, inclui-se x_5 na classe, $C_4 = \{x_4, x_5\}$ e acaba a vizinhança $v_4' = \phi$, onde ϕ indica conjunto vazio.

Como existe um vizinho remanescente, de x_4 , a etapa (2) é repetida com $v_4' = \{x_3\}$. Portanto, é criada uma nova classe $C_4' = \{x_3, x_4\}$ e o algoritmo termina para o elemento x_4 , uma vez que não tem mais remanescentes.

Nota-se que para o elemento x_4 foram criadas duas classes de tolerância, porque os vizinhos x_3 e x_5 tinham distâncias maiores que ε .

Nota-se também que o elemento x_4 pertence a ambas as classes criadas, e a propriedade transitiva, não se aplica para os elementos x_3, x_4 e x_5 , pois $x_3 R x_4$ e $x_4 R x_5$ não implicam em $x_3 R x_5$.

O algoritmo C pode ser aplicado genericamente para a obtenção de classes de tolerância em *TNS*, mesmo em casos em que a distância entre os elementos é medida em função de um vetor de atributos.

Henry (2010) afirma que a teoria de *TNS* fornece uma base para uma abordagem quantitativa, através do valor de ε , para avaliar a similaridade de objetos sem exigir que as descrições de objetos sejam exatas. Uma abordagem quantitativa baseada em *TNS* é a medida de similaridade *tNM*. Abaixo segue algumas bases para a definição de *tNM*.

2.2.2 Definição de medida de proximidade

Seja (O, F) sistema perceptual, com $\varepsilon \in \mathbb{R}$, e ainda X e Y , conjuntos disjuntos de modo que $Z = X \cup Y$; Considera-se que C representa uma classe e H o conjunto total de classes; O símbolo $\cong_{B, \varepsilon}$ representa a relação de tolerância perceptual. Então a medida de proximidade com tolerância entre os dois conjuntos/objetos é dada pela equação (6):

$$tNM_{\cong_{B, \varepsilon}}(X, Y) = \left(\sum_{C \in H_{\cong_{B, \varepsilon}}(Z)} |C| \right)^{-1} \times \sum_{C \in H_{\cong_{B, \varepsilon}}(Z)} |C| \frac{\min(|C \cap X|, |C \cap Y|)}{\max(|C \cap X|, |C \cap Y|)}. \quad (6)$$

A equação (6) representa o cálculo de tNM em que o primeiro termo do produto é o inverso do somatório do módulo, ou tamanho, de todas as classes C criadas dentro do conjunto Z . A classe C pertence ao conjunto total de classes H em uma relação de tolerância perceptiva para o conjunto Z .

O segundo termo do produto é o somatório do módulo de cada classe criada, multiplicado pela razão de intersecção mínima e máxima dos conjuntos X e Y com a classe C .

Assim é calculada a razão entre o mínimo e o máximo entre a intersecção da classe obtida com X e Y , e esse valor é multiplicado pelo tamanho da respectiva classe. Esse cálculo é realizado para todas as classes de tolerância obtidas e o resultado é somado e dividido pelo tamanho total $Z = X \cup Y$.

Exemplo. Sejam duas imagens X e Y conforme Fig.3.

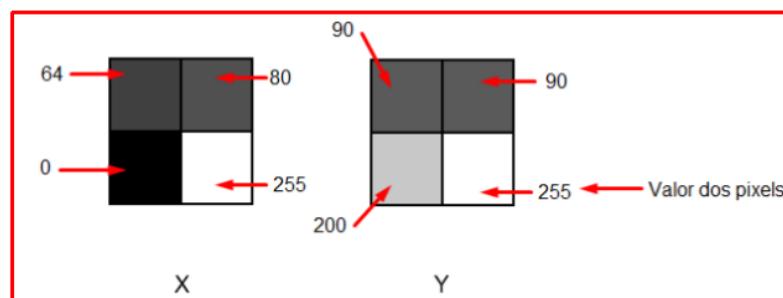


Figura 3: Exemplo de cálculo de Medida de Proximidade para a equação 6. Fonte: Adaptada de Henry (2010).

A Fig.3 representa duas imagens em níveis de cinza, em que cada quadrante possui níveis variando de 0 a 255. Elas são constituídas de quatro quadrantes de 10 x 10 pixels, com os respectivos valores de tons de cinza. As classes de tolerância (*TC*) são formadas em função do valor de ε com base nos níveis de cinza. Assim, considerando-se uma tolerância $\varepsilon = 0,2$, que corresponde a 51 em termos de níveis de cinza, todos os pixels com níveis de cinza que estiverem dentro do intervalo de 0 a 50 pertenceram a uma determinada classe, e assim por diante, de modo que é possível obter as *TCs* conforme Fig.4.

		T C				
		Classes	tamanho em pixels	Pixel X	Pixel Y	Razão
		1	400	200	200	1
		2	100	100	0	0
		3	200	100	100	1
		4	100	0	100	0

Figura 4: Classes de tolerância quando $\varepsilon=0,2$. Fonte: Adaptada de Henry (2010).

O resultado é dado por $tNM = \frac{1}{800} (400 \times 1 + 100 \times 0 + 200 \times 1 + 100 \times 0) = 0,75$.

2.3 Imagens em tons de cinza

As imagens em tons de cinza são amplamente abordadas na literatura, e para uma representação de 8 bits por pixel é possível termos 256 níveis de cinza. Utilizando o sistema RGB (que usa as componentes de cores vermelho, verde e azul), em que cada componente é formado por uma variação de intensidade de zero (0) a duzentos e cinquenta e cinco (255), existe uma possibilidade de variação de tonalidade para os pixels de 2^{24} .

Evidentemente imagens digitais coloridas apresentam uma complexidade maior para a sua representação. Se considerarmos a intensidade do pixel, temos que o valor zero (0) em vermelho, verde e azul, indica a cor preta e duzentos e cinquenta e cinco (255) nas três indica a cor branca. As outras cores são decorrentes dessa variação.

2.4 Textura

Em imagens, as texturas podem ser explicadas pelos valores de brilhos que referencia superfícies de partes altas e baixas. Hall-Beyer (2005) afirma que os valores do brilho de cada pixel, conhecido por níveis de cinza ou números digitais (*Gray Level e Digit Number*) são caracterizadas como textura e essas texturas quantificam diferenças de nível de cinza (contraste); tamanho definido da área onde ocorre a mudança (vizinhança, definida por um tamanho de janela) e direcionalidade, ou falta dela (omnidirecional). Através de uma abordagem com bases estatística, a textura pode ser definida por estatísticas extraídas de um conjunto de propriedades ou características extraídas de uma subimagem, nesse caso.

A imagem pode ser dividida em partes menores e esse processo é denominado segmentação. A segmentação pode ser realizada utilizando textura que são, essencialmente, características básicas dos padrões de pixels na imagem. Quando se fala em textura, se enquadram nesse caso, os padrões repetidos, observáveis pelo sensor da visão.

Existem alguns métodos para determinar as texturas dentre os quais: espectral, multiescala, baseado em modelos, métodos estruturais e métodos estatísticos. Matrizes de dependência espacial de tons de cinza (*spatial Gray-Level Dependence Matrices - SGLDM*), também conhecido como *GLCM*, é uma abordagem estatística utilizada neste trabalho.

2.5 Matriz de Co-ocorrência em níveis de cinza

A matriz de co-ocorrência em níveis de cinza, *GLCM*, é muito utilizada para obtenção de atributos estatísticos em imagens, principalmente em aplicações de sensoriamento remoto. No início da década de 1970 Haralick

(Haralick et al.1973) realizou uma abordagem no campo de análise de texturas de imagem, propondo *GLCM*. Com o uso do *GLCM* e fórmulas estatísticas para extração de informações, as texturas podem ser caracterizadas. O *GLCM* descreve características existentes entre pares de pixels de uma imagem.

As informações estatísticas possíveis de se extrair são várias e cada uma retrata uma informação específica da imagem, por exemplo, sempre considerando toda a imagem, o Contraste vai indicar a medida da intensidade de contraste de um pixel e seu vizinho, Correlação representa o quão correlacionado um pixel é com o seu vizinho. A Energia e a Entropia preocupam-se com a quantidade de variação da intensidade dos pixels.

GLCM é definido com respeito ao ângulo e distância entre os pares de pixels na imagem. Contudo, para simplificação, pode-se definir inicialmente com respeito aos pixels horizontalmente adjacentes, que correspondem ao ângulo 0° e distância $d = 1$.

Sejam $L_x = \{1,2, \dots, N_x\}$ e $L_y = \{1,2, \dots, N_y\}$ denotando respectivamente os domínios espaciais horizontal e vertical da imagem em nível de cinza quantizados em N_g níveis, e portanto os níveis de cinza estão contidos em $G = \{0, 1, \dots, N_g-1\}$. Então $L_x \times L_y$ é o conjunto de todas as coordenadas de pixels da imagem I , onde $I: L_x \times L_y \rightarrow G$, e *GLCM* é dada pela equação (7):

$$P(i, j) = \left\{ \left\{ \begin{array}{l} ((k, l), (m, n)) \in (L_y \times L_x) \times (L_y \times L_x): \\ m - k = 0, n - l = 1, I(k, l) = i, I(m, n) = j \end{array} \right\} \right\} \quad (7)$$

Basicamente o ponto i com referência k, l no domínio horizontal e vertical, indica o pixel de referência e o ponto j com as referências m, n , indica o pixel vizinho. Nesse caso particular a matriz *GLCM* utiliza uma angulação de zero grau ($m - k = 0$) e uma distância unitária ($n - l = 1$).

2.5.1 Propriedades da matriz *GLCM*

É pertinente relatar que *GLCM* contém algumas propriedades importantes.

- *GLCM* é sempre uma matriz quadrada.
- *GLCM* tem o mesmo número de linhas e colunas que o nível de quantização da imagem, N_g . Uma imagem de 2 bits tem 2^2 níveis de cinza (0, 1, 2, e 3). Uma imagem de 8 bits possui 2^8 (de 0 a 255) 256 níveis de cinza para cada pixel.

2.5.2 Exemplo de obtenção do GLCM

Para ilustrar a obtenção da matriz *GLCM*, apresenta-se na Fig. 5, um exemplo, com uma pequena imagem de entrada de dimensão 4x4, com 4 níveis de cinza. O cálculo é mostrado para a direção 0° no sentido direita para esquerda. A Fig. 5(a), retrata a matriz de uma imagem 4x4 em níveis de cinza. A matriz da Fig.5(b) mostra o tipo de par de níveis de cinza cada posição da de *GLCM* deve contar, na imagem de entrada. Assim, na posição (0,0), *GLCM* deve contar o número de vezes em que ocorre um par de pixels com nível de cinza 0 (pixel de referência) e nível de cinza 0 (pixel vizinho à direita). A Fig. 5(c) mostra *GLCM*, com a contagem do número de ocorrências dos pares de pixels (de referência e vizinho), com os níveis de cinza indicados na Fig.5(b). Como exemplo, na posição indicada por (0,1) na matriz da Fig.5(b), a contagem deve ser do par de níveis de cinza 0 e 1 na direção horizontal e sentido da esquerda para a direita, encontrados na imagem de entrada. Essa contagem resulta em dois, e, portanto, a matriz *GLCM* está preenchida com esse valor na posição (0,1).

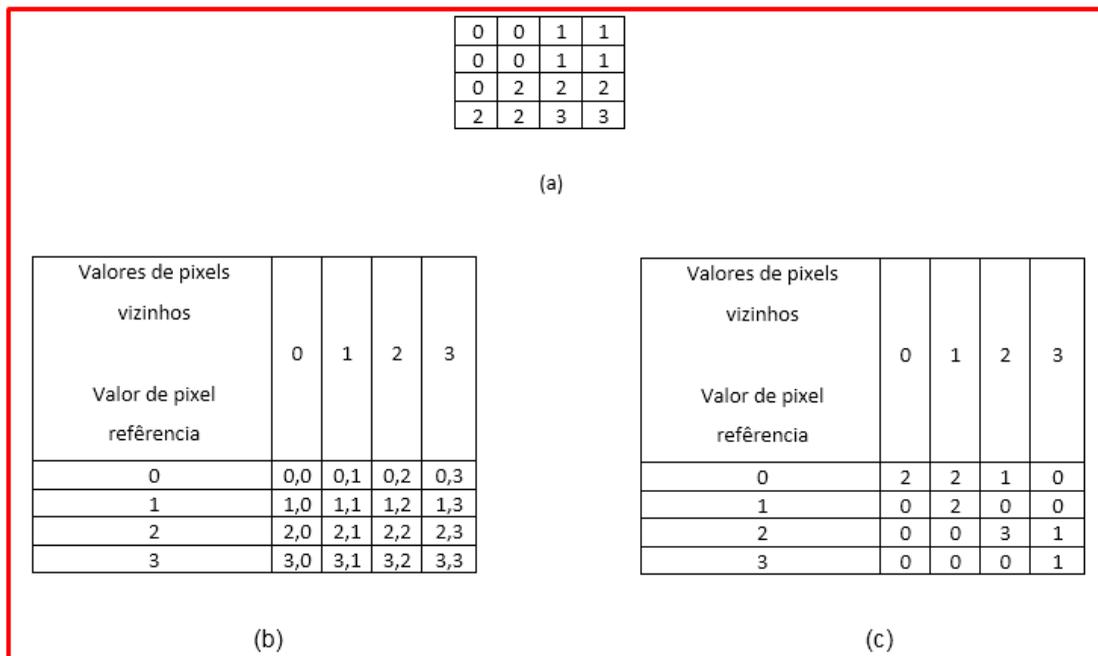


Figura 5: Obtenção de GLCM: (a) imagem de entrada de dimensão 4x4 e 4 níveis de cinza; matriz indicado os tipos de pares de pixels a serem considerados na obtenção do GLCM; (c) matriz GLCM resultante. (b) Fonte: Adaptada de Hall-Beyer (2005).

Pode-se observar que *GLCM* é uma matriz sempre quadrada que mantém informações das intensidades relativas dos pixels em uma dada imagem. *GLCM* calcula as probabilidades de co-ocorrências entre os níveis de cinza i e j , dada certa distância s (também conhecida como *pps* ou *pixel pair spacing*) e uma orientação θ . Os valores de angulação podem ser de 0, 45, 90, 135 e 180 graus (Baraldi & Parmiggiani, 1995).

Ao se considerar a imagem em níveis de cinza, aplica-se um algoritmo para obter *GLCM*. Agora o próximo passo é converter os valores de *GLCM* em valores estatísticos, relacionados em um vetor de funções de prova. A informação é obtida, percorrendo todos os elementos de *GLCM* e aplicando funções estatísticas, os dados obtidos referem-se à textura da imagem.

Haralick *et al.*, (1973) estabelece quatorze características tratadas como significativas em uma imagem, como a variância calculada sobre a soma dos pixels adjacentes; variação na diferença entre pixels adjacentes; entropia na soma e na diferença; correlação envolvendo entropias, e o coeficiente de correlação máximo. A Tabela 2 retrata algumas das principais características

abordadas por Haralick *et al.*, (1973), onde C refere-se à matriz GLCM, com os seus valores normalizados; i e j são coordenadas da matriz; G é a quantidade dos níveis de cinza; μ_x, μ_y , são referentes às médias e σ_x, σ_y , os desvios padrões.

Tabela 2: Fórmulas para o cálculo de atributos de uma matriz de GLCM.

Estatística	Equação
Dissimilaridade	$\sum_{i,j=1}^G C_{ij} i - j $
Uniformidade	$\sum_{i,j=1}^G C_{ij}^2$
Entropia	$-\sum_{i,j=1}^G C_{ij} \log C_{ij}$
Contraste	$\sum_{i,j=1}^G C_{ij} i - j ^2$
Correlação	$\sum_{i,j=1}^G \frac{(i - \mu_x)(j - \mu_y) C_{ij}}{(\sigma_x) (\sigma_y)}$
Variância	$\sum_{i,j=1}^G (i - \mu^2) C_{ij}$

Fonte: Adaptada de Martins (2011).

2.6 Reconhecimento de Padrões

Reconhecimento de padrões (*RP*) é uma área da ciência que trata da classificação e descrição de objetos. De acordo com Theodoridis & Koutroumbas (2003) o reconhecimento de padrões é a disciplina científica cujo objetivo é classificar os objetos em várias categorias ou classes. É importante notar que dependendo da aplicação, os objetos podem ser imagens ou formas de onda de sinal ou qualquer tipo de medição que precise ser classificada (Theodoridis & Koutroumbas, 2003), e o foco desta pesquisa está baseado em classificação de objetos/imagens para verificação do nível de similaridade a partir de seus atributos.

O RP é dividido nas etapas de obtenção do objeto, extração de características, seleção de características e classificação. Ao se considerar que uma classe é um conjunto de padrões, pode-se aplicar um extrator e seletor de características e posteriormente, se é desconhecida a classe do objeto, aplica-se um classificador para se obter a classe do mesmo.

Informações características da imagem como luminosidade, intensidade de cor, texturas, são encontradas em cada pixel formador da imagem podendo ser usados para a comparação entre os objetos, ou seja, realizar uma comparação de duas imagens até que se obtenha o objeto idêntico ou próximo nos quesitos das características padronizadas.

A distância é uma forma de medir a similaridade de dois objetos, ou seja, verificar o quanto dois objetos são próximos. Com zero (0) indicando nenhuma similaridade e um (1) indicando a existência de similaridade. Os tipos de distâncias utilizadas são várias, dependendo da aplicação, dentre elas temos a Manhattan, Chebyshev, Mahalanobis, Hausdorff, Hamming, Minkowski e Euclidiana, sendo esta última uma das mais utilizadas, por conseguinte será implementada neste trabalho. A equação 8 refere-se a esta distância. A variável d indica a distância entre as posições i e j . A informação que x representa são coordenadas tratadas nas respectivas posições variando de 1 até p .

$$d(i, j) = \sqrt{(x_{i1} - x_{j1})^2 + (x_{i2} - x_{j2})^2 + \dots + (x_{ip} - x_{jp})^2} \quad (8)$$

2.7 Trabalhos Relacionados

Nesta seção, descreve-se alguns trabalhos recentes relacionados a *NS* e *TNS*.

Um trabalho extenso sobre a aplicação de *tNM* foi desenvolvido por Henry (Henry, 2010), onde foi explorada a recuperação de imagens baseadas em conteúdo. Duas medidas de proximidade foram exploradas, uma baseada na distância de Hausdorff e outra baseada na distância de Hamming.

O trabalho de Khedgaonkar, Singh e Gawande (Khedgaonkar *et al.*, 2011), descreve uma aplicação de identificação de semelhanças em imagens de faces antes e após cirurgias plásticas, considerando-se *TNS*, como um método para estabelecer a semelhança entre objetos contidos em conjuntos disjuntos, pela comparação e classificação de objetos. Os resultados experimentais indicaram o desempenho e precisão do reconhecimento de faces após cirurgia plástica.

Ramanna e colaboradores (Ramanna *et al.*, 2013) desenvolveram um trabalho de aplicação de *NS* na construção de grafos induzidos por sistemas perceptuais, bem como a análise de tais grafos usando a teoria de *NS*. Como atributos distintos de tais grafos tem-se as camadas, de modo que os mesmos podem ser chamados de grafos com camadas. Uma aplicação prática em análise de imagens digitais é descrita determinando a proximidade entre grafos com camadas.

Wolski (Wolski, 2010) estabeleceu uma conexão topológica entre a percepção de objetos (em *NS*) e a classificação desses objetos, usando a definição de conjuntos brutos (*Rough Sets - RS*), destacando-se que em *NS*, a obtenção de conjuntos próximos se inicia com uma seleção de funções de prova que provê uma base para a descrição e discernimento dos objetos. Por outro lado, em *RS*, a classificação de objetos é baseada nos atributos dos objetos que são coletados em tabelas previamente estabelecidas ou encontradas na literatura.

Uma das aplicações de *NS* seria na análise de proximidade entre imagens de cidades. Domingues et al. (Domingues, 2018) não sei se você entendeu, mas a ideia é essa.) desenvolveram um estudo sobre a organização topológica de várias cidades ao redor do mundo, de acordo com a teoria de redes complexas. Nesse estudo, foram identificadas as regiões mais significantes de cada cidade, e baseada na estimativa de várias medidas topológicas as mesmas foram comparadas. Os resultados mostram que cidades de continentes específicos, tendem a ter propriedades topológicas particulares. Esse resultado é importante, uma vez que pretende-se realizar um estudo semelhante neste trabalho de dissertação.

2.8 Considerações finais

Nesse capítulo, foram apresentados os princípios que permitem a contextualização de conceitos relacionados à dissertação, bem como um resumo dos principais trabalhos correlatos. No próximo capítulo serão descritos o trabalho desenvolvido e a metodologia.

Capítulo 3

Materiais e Métodos utilizados

Esse capítulo evidencia a proposta metodológica que será usada neste trabalho de mestrado, apresenta e descreve os procedimentos que serão usados, bem como as técnicas a serem implementadas para alcançar os objetivos propostos.

3.1 Visão Geral

O foco desta pesquisa consiste em propor o desenvolvimento de um programa computacional que permite validar o método implementado em linguagem Python, que permita verificar estimativas do quanto duas imagens são similares ou próximas quantitativamente. Essa verificação se dá através do cálculo de tNM entre duas imagens.

3.2 Princípios de Funcionamento do algoritmo de tNM

O cálculo do tNM é baseado na equação (6), Capítulo 2, portanto, o algoritmo projetado baseia-se na subdivisão das imagens X e Y a serem calculadas em subimagens. Essas subimagens que devem ser rotuladas, como pertencentes a uma das imagens, devem ser comparadas duas a duas indistintamente em relação a esse rótulo para a obtenção das classes de subimagens, denotadas como C , na referida equação. Posteriormente, em função do rótulo é possível calcular a razão entre o mínimo e o máximo da intersecção de cada classe com as imagens X e Y , para o cálculo do tNM .

Na Fig.6 é apresentado um fluxograma que ilustra os passos para obter o valor de tNM entre as imagens X e Y . O procedimento se inicia com o carregamento de duas imagens. Então na etapa de pré-processamento temos duas possíveis abordagens em que o cálculo do tNM pode ser realizado: (1)

uma primeira abordagem a partir dos níveis de cinza, *NC* ou em (2) uma segunda abordagem a partir dos atributos estatísticos, *AE*, extraídos de GLCM das subimagens geradas das duas imagens. As classes são geradas na etapa de pré-processamento em função do valor de tolerância ε , aplicado na distância entre os valores de níveis de cinza dos pixels (na abordagem *NC*) ou vetores de atributos das subimagens (na abordagem *AE*), para que os pares de pixels ou subimagens, cujas distâncias sejam menores ou iguais a essa tolerância, sejam consideradas na mesma classe.

Basicamente, o fluxograma considera os níveis de cinza, para *NC*, e o cálculo de características estatísticas de texturas - entropia, contraste, energia e uniformidade, dividindo as imagens *X* e *Y* a serem comparadas em subimagens, e então extraindo informações estatísticas das subimagens, para *AE*. Essa etapa está sendo demonstrada como pré-processamento (Fig. 6).

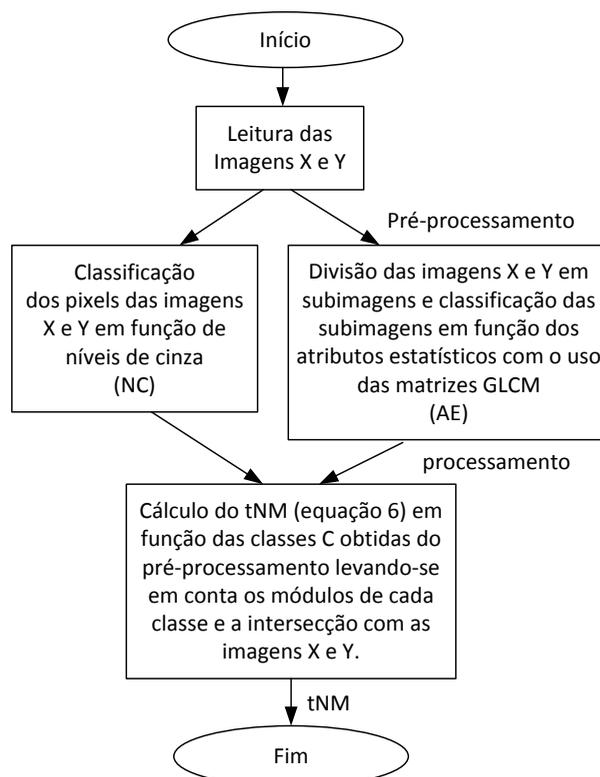


Figura 6: Fluxograma do método proposto para a obtenção das classes das imagens *X* e *Y* e *tNM*. Fonte: Autor dessa dissertação.

Algumas modificações no código fornece a possibilidade da realização de recuperação de imagem baseado em conteúdo, de tal forma que seria

fornecido uma imagem e especificado o objeto na imagem, então a partir desse objeto as classes seriam criadas e carregadas em um vetor de atributos utilizadas para se buscar correspondências. A Fig. 7 mostra o pseudocódigo do algoritmo para o cálculo de tNM na abordagem NC .

```
Procedure  $tNM(X, Y, \varepsilon, K)$  // abordagem  $NC$   
Input:  $X, Y, \varepsilon$  // imagens a serem comparadas e valor de tolerância  
Output:  $K$  // valor de  $tNM$  obtido ao se comparar as duas imagens  
1 begin // fase de inicialização do algoritmo, no passo 1 duas imagens são lidas e  
carregadas no sistema  
2 inicializar  $K$  com valor zero  
3 as imagens são convertidas para níveis de cinza  
4 cada pixel das imagens  $X$  e  $Y$  é classificada em classes  $C_i$  de níveis de cinza definidos em  
função da tolerância  $\varepsilon$   
5 repeat  
6 para cada classe  $C_i$  obter a razão entre a intersecção mínima e máxima da mesma com as  
imagens de entrada  $X$  e  $Y$   
7 multiplicar a razão obtida em (6) pelo módulo da classe  
8 acumular o resultado de (7) em  $K$   
9 until não haja mais classes  
10 calcular o valor de  $K$  final dividindo  $K$  pelo tamanho total das duas imagens  
11 end  
12 return ( $K$ )  
13 end_procedure
```

Figura 7: Pseudocódigo NC do algoritmo tNM . Fonte: Autor dessa dissertação.

O algoritmo da Fig.7 consta da etapa de pré-processamento e processamento descrito na Fig. 6 iniciando-se com a leitura das duas imagens e essa primeira abordagem, refere-se ao cálculo do tNM em função dos níveis de cinza da imagem.

No pseudocódigo NC , em (1) as imagens são carregadas no programa; em (2) é inicializado o valor de tNM , descrito pela variável K em zero; e na etapa (3) ocorre a conversão para escala de níveis de cinza. Na etapa (4), o valor de tolerância permite a criação das classes em função dos 256 níveis de cinza. Na etapa (5) inicia-se as iterações de cálculo do tNM . O procedimento

para o cálculo do tNM é constituído do cálculo da razão entre as intersecções mínima e máxima de cada classe com as imagens de entrada X e Y , etapa (6), e multiplicação dessa razão pelo módulo ou tamanho da classe (7). Ao final os resultados de cada classe são somados, etapa (8) e divididos pelo tamanho total das duas imagens, etapa (10), resultando no índice tNM , etapas (11 a 13).

```

Procedure  $tNM(X, Y, \epsilon, n, K)$  // abordagem AE
Input:  $X, Y, \epsilon, n$  // imagens de entrada, tolerância e número de subimagens
Output:  $K$  // valor de  $tNM$  entre as duas imagens de entrada
1 begin // inicialização, as duas imagens são lidas e carregadas no sistema
2 o valor de  $K$  é inicializado com o valor zero
3 as imagens são convertidas para níveis de cinza e divididas em  $n$  subimagens
4 são geradas matrizes GLCM das subimagens e extraídos os atributos estatísticos
    com base no valor de épsilon e na norma euclidiana, as classes são criadas
5 repeat
6 para cada classe  $C_i$  obter a razão entre os módulos mínimo e o máximo das intersecções da
    classe com as imagens de entrada  $X$  e  $Y$ 
7 multiplicar a razão obtida em (6) pelo módulo da classe
8 acumular o resultado de (7) em  $K$ 
9 until não haja mais classes
10 calcular o valor de  $K$  final dividindo  $K$  pelo tamanho total das duas imagens
11 end
12 return (k)
13 end_procedure

```

Figura 8: Pseudocódigo AE do algoritmo tNM . Fonte: Autor dessa dissertação

No pseudocódigo AE, Fig. 8, na etapa (1) as imagens são carregadas no programa; em (2) a variável K , que representa tNM , é inicializada com zero; e em (3) as imagens são convertidas em níveis de cinza e depois subdivididas em n subimagens. Em (4), para cada subimagem é gerada uma GLCM e são extraídos os atributos estatísticos de entropia, energia, contraste e uniformidade. Outras características podem ser usadas, contudo essas foram escolhidas por representarem as informações mais relevantes das imagens, e mais comumente utilizadas. Em função do valor de tolerância ϵ , comparado com a norma euclidiana entre duas subimagens, as classes são criadas

conforme a definição de *TNS*, equação (5). Em seguida ocorre a iteração para o cálculo de *tNM* propriamente dito, análoga à descrição do pseudocódigo *NC*.

Esses dois pseudocódigos foram trabalhados separadamente, contudo nada impede a implementação em um mesmo módulo de software.

3.3 Imagens Utilizadas e Análise dos Resultados

Como descrito anteriormente, as imagens a serem processadas podem ser dos mais diferentes campos de aplicação. Contudo as propostas são referentes a regiões geográficas, com ou sem desmatamento; faces com cirurgias estéticas e faces normais; e comparação entre centros urbanos de cidades ao redor do mundo. A aplicação de *tNM* nas imagens de centros urbanos verifica similaridades em função de valores de textura das subimagens.

Para a avaliação dos resultados, será realizada uma comparação entre as duas abordagens utilizadas para o cálculo de *tNM*: a abordagem *NC* e a abordagem *AE*. Além disso, serão desenvolvidas classificações das cidades em função dos valores de *tNM* obtidos, e os resultados serão analisados.

3.4 Considerações Finais

Neste capítulo foi apresentada a proposta de pesquisa, descrevendo a metodologia pretendida e empregada para se obter valores de *tNM* entre imagens, utilizando as bases teóricas descritas.

Capítulo 4

Experimento, Resultados e Discussões

Neste capítulo os experimentos e resultados obtidos são explicitados, e também são apresentadas as discussões acerca dos mesmos, para validação.

4.1 Visão Geral dos Experimentos

Para a implementação dos algoritmos foi utilizada a ferramenta de programação *Python*, linguagem de programação criada por Guido van Rossum em 1991. Essa linguagem foi criada com o principal objetivo de oferecer uma fácil e eficiente maneira de se produzir códigos. O *download* do programa foi realizado pelo site <https://www.python.org/>, em sua versão 3.7 para plataforma Windows. Após a implementação do código, com o intuito de se garantir resultados harmonizados, os testes foram realizados em um computador com as seguintes especificações:

- Sistema Operacional Windows 7 Ultimate 64bits
- Notebook HP
- Processador i7 2,6 Giga-hertz
- Memória RAM 16 Gigabytes
- Hard Disk 1 Terabytes

Nos experimentos foram utilizadas 50 imagens dentre as que tratam de desmatamento, cirurgias faciais e principalmente de centros urbanos. Isso devido a importância que o estudo das características das cidades vem apresentando em recentes artigos, atualmente, como exemplo Domingues *et al.* (2017) afirma que estudos anteriores sobre a caracterização da estrutura das cidades por meio de redes complexas proporcionaram importantes contribuições para o entendimento e potencial aperfeiçoamento de aspectos como sistema de trânsito, crescimento de cidades e planejamento de cidades.

A aplicação em *tNM* verifica os aspectos relacionados às características de textura com a abordagem *AE* ou níveis de cinza, abordagem *NC*, indicando a similaridade entre as imagens, por conseguinte, se há relação na estrutura das cidades de diferentes localizações e culturas.

4.2 Padronização de Imagens de Entrada

Em geral, para cada imagem utilizada existiu uma etapa de pré-processamento que contribuiu para determinar um padrão de entrada. Os resultados do pré-processamento foram analisados de maneira puramente visual e quantitativamente em relação à dimensão, e, por conseguinte em relação ao número de pixels, e formato de gravação.

As imagens foram convertidas para o mesmo formato/extensão, nesse caso o jpg por ser um dos mais utilizados e difundidos e ainda por manter uma boa qualidade de imagem. Imagens que não possuíam dimensões iguais em relação aos seus pares, para efeito de cálculo de *tNM*, foram redimensionadas.

As imagens, das Figs. 9 e 10, ilustram o pré-processamento, antes e depois, respectivamente. Basicamente a imagem da Fig. 10 foi redimensionada para adequar às questões do cálculo do *tNM* pelo padrão escolhido nesse trabalho, reduzindo a área geográfica considerada.

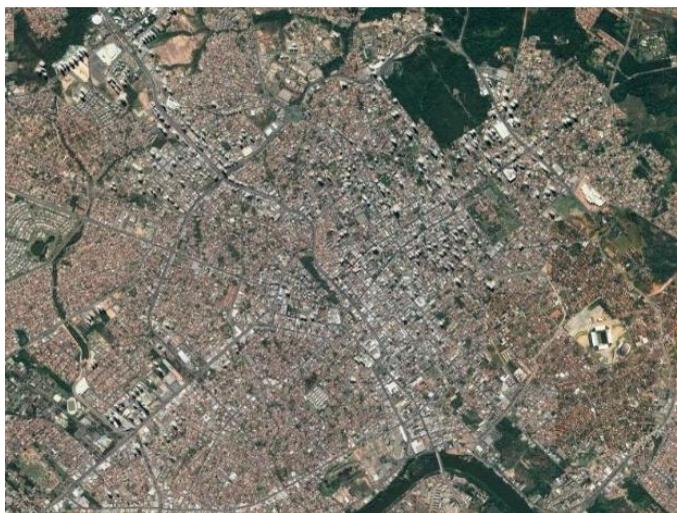


Figura 9: Cuiabá antes. Fonte: Google Maps.

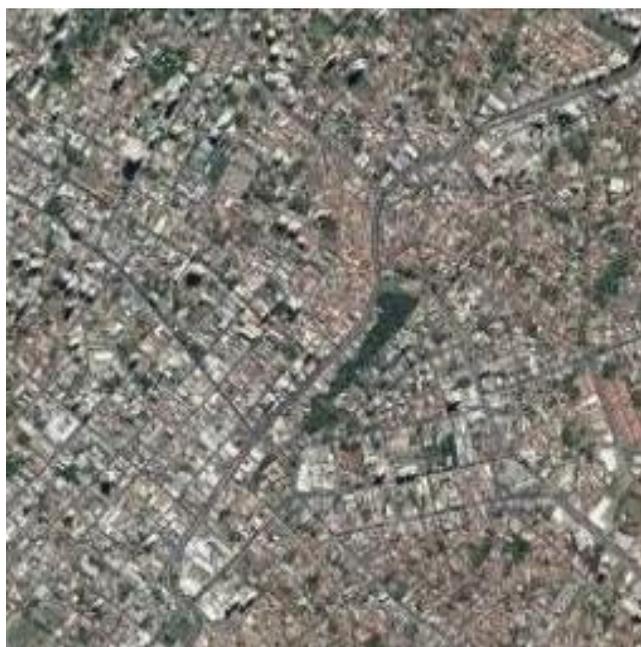


Figura 10: Cuiabá Depois. Fonte: Autor dessa dissertação.

Domingues *et al.* (2017) utilizou para seus experimentos imagens do banco de dados do OpenStreetMaps de cidades com 100.000 e 600.000 habitantes. Contudo esta pesquisa utiliza as imagens obtidas a partir do Google Maps, para análise das cidades, por oferecerem imagens mais adequadas para os experimentos.

As cidades foram escolhidas em função de sua densidade populacional, abrangendo os mais diferentes tipos, diferentes regiões geográficas e continentes, com a população variando de 400.000 a 1.200.000. As regiões das cidades que constam nas fotos foram escolhidas sem a presença de rios e lagos, o que se mostrou como um ponto difícil visto que algumas cidades em suas regiões centrais apresentavam grande quantidade desses acidentes geográficos.

4.3 Testes Preliminares com Mesmas Imagens

Os testes iniciais foram realizados com o intuito de se verificar o bom funcionamento do mesmo, assim experimentos de verificação de tNM foram executados, primeiro com um par de mesmas imagens. Como esperado, para o cálculo do tNM na abordagem NC , independentemente do valor de tolerância ϵ ,

e portanto, das classes geradas para o cálculo do tNM , o resultado foi 1, indicando o valor máximo de similaridade, ou seja, indicando que as imagens são exatamente iguais. Para o cálculo de tNM na abordagem AE , usando a distância euclidiana, o valor do tNM retornado também foi 1, independentemente da quantidade de subimagens geradas e do valor da tolerância ε , utilizada na criação das classes.

As Figs. 11 e 12 retratam as imagens utilizadas nos testes iniciais. As Figs. 13,14,15 e 16 referem-se ao quadro de dados do experimento para imagens das Figs. 11 e 12, da cidade de Cuiabá - MT, e do quadro Mona Lisa, em que o cálculo do tNM foi feito com as mesmas.

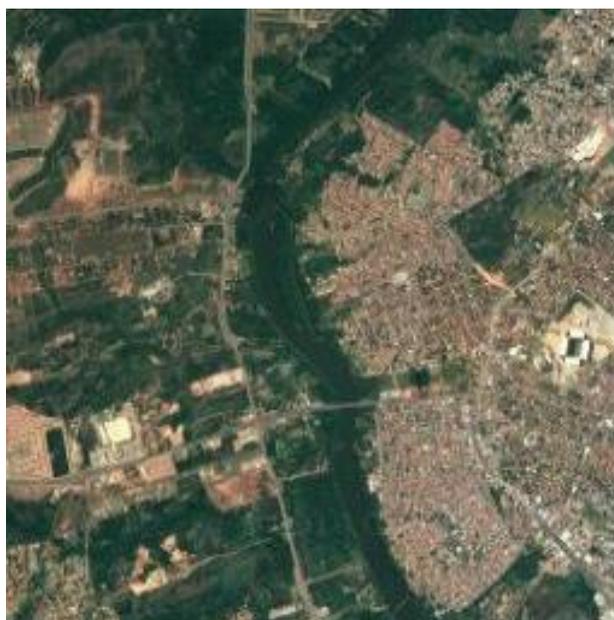


Figura 11: Cuiabá-MT, Brasil. Fonte: Google Maps.



Figura 12: Imagem Mona Lisa. Fonte: <https://code.google.com/archive/p/evocubist/downloads>.

Nos quadros das Figs. 13 e 14, 15 e 16, na primeira linha na parte central, é indicada a abordagem utilizada. Na coluna à esquerda são identificadas as duas imagens em arquivos jpg. Nas duas colunas da parte central, informações como dimensão da imagem, número de classes geradas e o tempo de execução, tolerância e finalmente o valor obtido de tNM, são inseridas. Na coluna à direita, é indicada a denotação da identificação do experimento.

No quadro da Fig.13, *NC*, houve variação no valor de tolerância nos experimentos indicados de Cuiabá_1, a Cuiabá_4, resultando na diferença em relação ao número de classes geradas e tempo de execução, para cada experimento.

Imagem 1 e 2 respectivamente	Configuração NC (Níveis de Cinza)		Número de Experimento
Cuiabá .jpg e Cuiabá .jpg	Extensão = .JPG	Tolerancia/Épsilon = 1%	Experimento Cuiabá_1
	Dimensão da Imagem = 256x256		
	Nº de Classes Geradas = 100	tNM = 1,0	
	Tempo de Execução = 25 seg		
Cuiabá .jpg e Cuiabá .jpg	Extensão = .JPG	Tolerancia/Épsilon = 50%	Experimento Cuiabá_2
	Dimensão da Imagem = 256x256		
	Nº de Classes Geradas = 2	tNM = 1,0	
	Tempo de Execução = 2 seg		
Cuiabá .jpg e Cuiabá .jpg	Extensão = .JPG	Tolerancia/Épsilon = 100%	Experimento Cuiabá_3
	Dimensão da Imagem = 256x256		
	Nº de Classes Geradas = 1	tNM = 1,0	
	Tempo de Execução = 2 seg		
Cuiabá .jpg e Cuiabá .jpg	Extensão = .JPG	Tolerancia/Épsilon = 0	Experimento Cuiabá_4
	Dimensão da Imagem = 256x256		
	Nº de Classes Geradas = 256	tNM = 1,0	
	Tempo de Execução = 2 seg		

Figura 13: Comparação de Dados Cuiabá - NC. Fonte: Autor dessa dissertação.

No quadro da Fig.14, *AE*, também houve variação no valor de tolerância nos experimentos indicados de Cuiabá_5, a Cuiabá_10, resultando na diferença em relação ao número de subimagens, classes geradas e tempo de execução, para cada experimento.

Imagem 1 e 2 respectivamente	Configuração AE (Atributos Estatísticos)		Número de Experimento
Cuiabá .jpg e Cuiabá .jpg	Extensão da Imagem = .JPG	Atributos Estatísticos = 0,01	Experimento Cuiabá_5
	Dimensão da Imagem = 256x256		
	Nº de Subimagens Geradas = 8192	Dimensão da Subimagem = 4x4	
	Quantidade de Classes Geradas = 999	tNM = 1,0	
Tempo de execução = 6 h			
Cuiabá .jpg e Cuiabá .jpg	Extensão da Imagem = .JPG	Atributos Estatísticos = 0,05	Experimento Cuiabá_6
	Dimensão da Imagem = 256x256		
	Nº de Subimagens Geradas = 8192	Dimensão da Subimagem = 4x4	
	Quantidade de Classes Geradas = 178	tNM = 1,0	
Tempo de execução = 50 min			
Cuiabá .jpg e Cuiabá .jpg	Extensão da Imagem = .JPG	Atributos Estatísticos = 0,1	Experimento Cuiabá_7
	Dimensão da Imagem = 256x256		
	Nº de Subimagens Geradas = 8192	Dimensão da Subimagem = 4x4	
	Quantidade de Classes Geradas = 59	tNM = 1,0	
Tempo de execução = 11 min			

Cuiabá .jpg e Cuiabá .jpg	Extensão da Imagem	= .JPG	Atributos Estatísticos	= 0,5	Experimento Cuiabá_8
	Dimensão da Imagem	= 256x256	Dimensão da Subimagem	= 4X4	
	Nº de Subimagens Geradas	= 8192	tNM	= 1,0	
	Quantidade de Classes Geradas	= 5			
	Tempo de execução	= 6 mim			
Cuiabá .jpg e Cuiabá .jpg	Extensão da Imagem	= .JPG	Atributos Estatísticos	= 0,9	Experimento Cuiabá_9
	Dimensão da Imagem	= 256x256	Dimensão da Subimagem	= 4X4	
	Nº de Subimagens Geradas	= 8192	tNM	= 1,0	
	Quantidade de Classes Geradas	= 3			
	Tempo de execução	= 6 min			
Cuiabá .jpg e Cuiabá .jpg	Extensão da Imagem	= .JPG	Atributos Estatísticos	= 1	Experimento Cuiabá_10
	Dimensão da Imagem	= 256x256	Dimensão da Subimagem	= 4X4	
	Nº de Subimagens Geradas	= 8192	tNM	= 1,0	
	Quantidade de Classes Geradas	= 3			
	Tempo de execução	= 6 min			

Figura 14: Comparação de Dados Cuiabá - AE. Fonte: Autor dessa dissertação.

No quadro da Fig.15, *NC*, imagem de *Mona Lisa*, houve variação nos valores de tolerância nos experimentos indicados de *Mona Lisa_1*, a *Mona Lisa_4*, resultando na diferença em relação ao número de classes geradas e tempo de execução, para cada experimento.

No quadro da Fig.16, *AE*, imagem de *Mona Lisa*, também houve variação no valor de tolerância nos experimentos indicados de *Mona Lisa_5*, a *Mona Lisa_10*, resultando na diferença em relação ao número de subimagens, classes geradas e tempo de execução, para cada experimento.

Imagem 1 e 2 respectivamente	Configuração NC (Níveis de Cinza)		Número de Experimento
	Extensão	Tolerancia/Épsilon	
Mona Lisa .jpg e Mona Lisa .jpg	= .JPG	= 1%	Experimento Mona Lisa_1
	= 256x256	tNM = 1,0	
	= 100		
	= 25 seg		
Mona Lisa .jpg e Mona Lisa .jpg	= .JPG	= 50%	Experimento Mona Lisa_2
	= 256x256	tNM = 1,0	
	= 2		
	= 2 seg		
Mona Lisa .jpg e Mona Lisa .jpg	= .JPG	= 100%	Experimento Mona Lisa_3
	= 256x256	tNM = 1,0	
	= 1		
	= 2 seg		
Mona Lisa .jpg e Mona Lisa .jpg	= .JPG	= 0	Experimento Mona Lisa_4
	= 256x256	tNM = 1,0	
	= 256		
	= 2 seg		

Figura 15: Comparação de Dados Mona Lisa - NC. Fonte: Autor dessa dissertação.

Imagem 1 e 2 respectivamente	Configuração AE (Atributos Estatísticos)		Número de Experimento
	Extensão da Imagem	Atributos Estatísticos	
Mona Lisa .jpg e Mona Lisa .jpg	= .JPG	= 0,01	Experimento Mona Lisa_5
	= 256x256	Dimensão da Subimagem = 4X4	
	= 8192		
	= 999		
	= 8 h		
Mona Lisa .jpg e Mona Lisa .jpg	= .JPG	= 0,05	Experimento Mona Lisa_6
	= 256x256	Dimensão da Subimagem = 4X4	
	= 8192		
	= 198		
	= 40 min		
Mona Lisa .jpg e Mona Lisa .jpg	= .JPG	= 0,1	Experimento Mona Lisa_7
	= 256x256	Dimensão da Subimagem = 4X4	
	= 8192		
	= 64		
	= 11 min		
Mona Lisa .jpg e Mona Lisa .jpg	= .JPG	= 0,5	Experimento Mona Lisa_8
	= 256x256	Dimensão da Subimagem = 4X4	
	= 8192		
	= 5		
	= 6 min		
Mona Lisa .jpg e Mona Lisa .jpg	= .JPG	= 0,9	Experimento Mona Lisa_9
	= 256x256	Dimensão da Subimagem = 4X4	
	= 8192		
	= 3		
	= 6 min		
Mona Lisa .jpg e Mona Lisa .jpg	= .JPG	= 1	Experimento Mona Lisa_10
	= 256x256	Dimensão da Subimagem = 4X4	
	= 8192		
	= 1		
	= 6min		

Figura 16: Comparação de Dados Mona Lisa - AE. Fonte: Autor dessa dissertação.

4.4 Testes Preliminares com Imagens Diferentes de Paisagens

As Figs. 17 e 18 exemplificam o cálculo de tNM para imagens com algumas semelhanças na paisagem, utilizadas nos experimentos. Para o cálculo do tNM em NC foram usados os valores de tolerância de 10% e 0% (nenhuma tolerância, ou seja, gerando 256 classes); e para o tNM em AE foi adotado o valor de tolerância de 0,1 e as dimensões das subimagens de 4x4 e 8x8 pixels. As imagens comparadas possuem dimensões de 400x300 pixels.



Figura 17: Paisagem_1. Fonte: Autor dessa dissertação.



Figura 18: Paisagem_2. Fonte: Autor dessa dissertação.

Observa-se que essas imagens possuem características semelhantes como a presença de água e vegetação verde.

No quadro da Fig.19, *NC*, do par de imagens de paisagens, houve variação nos valores de tolerância, em 10% e 0%, nos experimentos indicados como Paisagens_1, e Paisagens 2, resultando na diferença em relação ao número de classes geradas de 10 e 256, tempo de execução, de 5 s para ambos, e o *tNM* de 0,762 e 0,728, respectivamente.

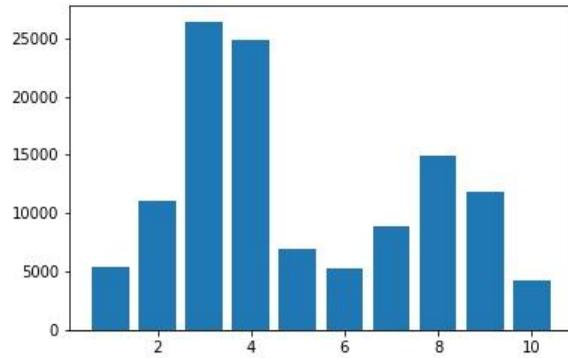
No quadro da Fig.20, *AE*, do par de imagens de paisagens, também houve variação no valor de tolerância nos experimentos indicados de Paisagens_3 e Paisagens_4, resultando na diferença em relação ao número de subimagens de 2400 e 15.000, classes geradas de 100 e 160, tempo de execução de 3 min e uma hora, dimensão de subimagem de 10x10 e 4x4, e valor de *tNM* de 0,728 e 0,75626, respectivamente.

Imagem 1 e 2 respectivamente	Configuração NC (Níveis de Cinza)		Número de Experimento
Paisagem_1 .jpg e Paisagem_2 .jpg	Extensão = .JPG	Tolerancia/Épsilon = 10%	Experimento Paisagens_1
	Dimensão da Imagem = 400x300		
	Nº de Classes Geradas = 10	tNM = 0,762	
	Tempo de Execução = 5 seg		
Paisagem_1 .jpg e Paisagem_2 .jpg	Extensão = .JPG	Tolerancia/Épsilon = 0	Experimento Paisagens_2
	Dimensão da Imagem = 400x300		
	Nº de Classes Geradas = 256	tNM = 0,728	
	Tempo de Execução = 5 seg		

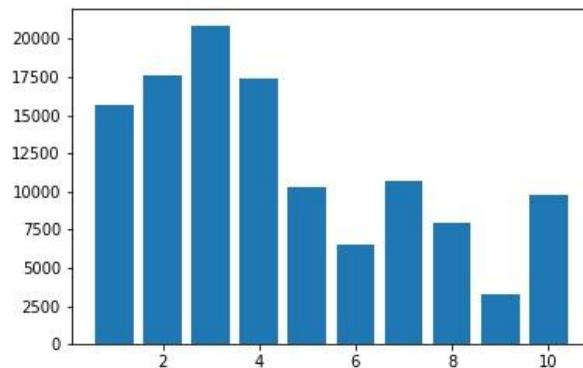
Figura 19: Paisagens - NC. Fonte: Autor dessa dissertação.

Imagem 1 e 2 respectivamente	Configuração AE (Atributos Estatísticos)		Número de Experimento
Paisagem_1 .jpg e Paisagem_2 .jpg	Extensão da Imagem = .JPG	Atributos Estatísticos = 0,1	Experimento Paisagens_3
	Dimensão da Imagem = 400x300		
	Nº de Subimagens Geradas = 2400	Dimensão da Subimagem = 10X10	
	Quantidade de Classes Geradas = 100		
	Tempo de execução = 3 min		
Paisagem_1 .jpg e Paisagem_2 .jpg	Extensão da Imagem = .JPG	Atributos Estatísticos = 0,1	Experimento Paisagens_4
	Dimensão da Imagem = 400x300		
	Nº de Subimagens Geradas = 15000	Dimensão da Subimagem = 4X4	
	Quantidade de Classes Geradas = 160		
	Tempo de execução = 1h		

Figura 20: Paisagens - AE. Fonte: Autor dessa dissertação.



(a)

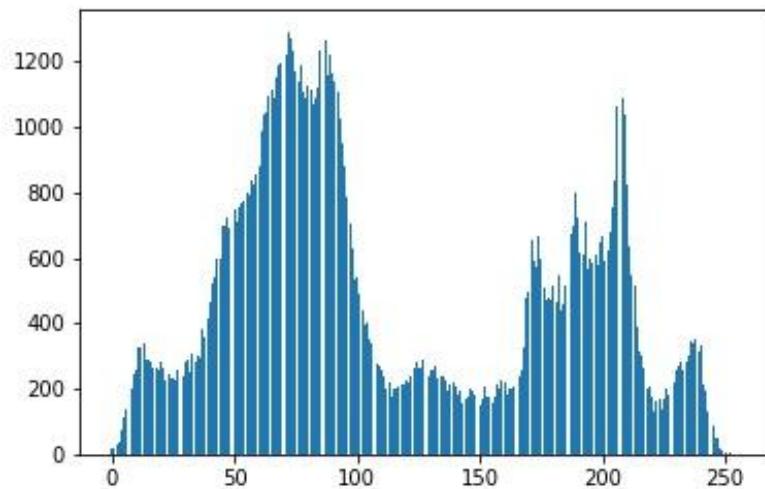


(b)

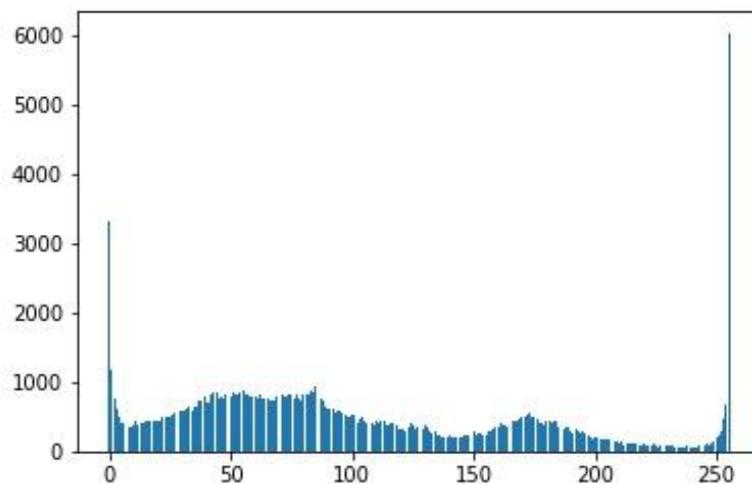
Figura 21: Paisagens Pixel por Classes (a) Paisagem_1 e (b) Paisagem_2 Respectivamente – NC, tolerância de 10%. Fonte: Autor dessa dissertação.

Na Fig. 21 (a) é mostrado o histograma de distribuição dos pixels na imagem Paisagem_1, Fig. 17, e na Fig. 21(b), o histograma de distribuição dos pixels na imagem Paisagem_2, Fig.18, ambas com a tolerância de 10%.

A Fig. 22 corresponde aos histogramas da distribuição dos pixels nos 256 níveis de cinza, que corresponde ao nível de tolerância zero, para a obtenção de classes em NC. A Fig. 22(a) corresponde ao histograma da imagem da Fig. 17, e a Fig. 22(b), à imagem da Fig. 18.



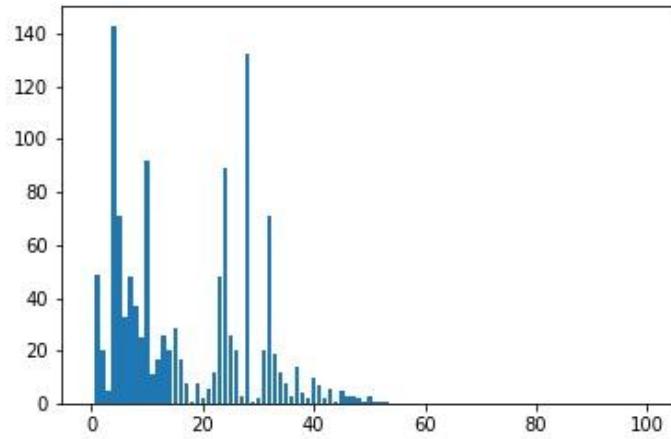
(a)



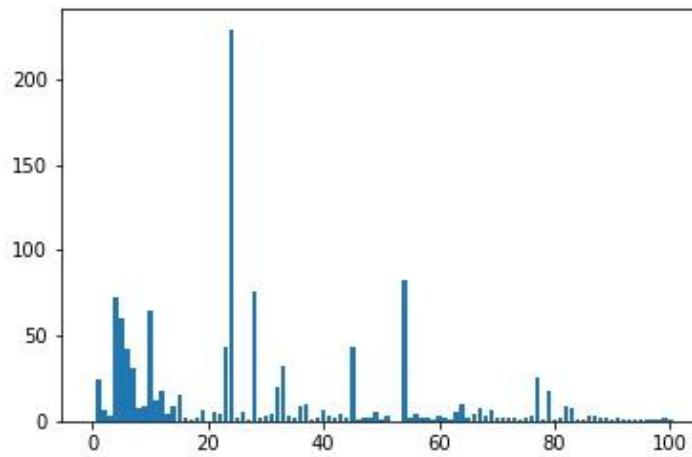
(b)

Figura 22: Paisagens Pixel por Classes (a) Paisagem_1 e (b) Paisagem_2 Respectivamente, para tolerância zero. Fonte: Autor dessa dissertação.

É possível observar na Fig. 23, os histogramas de distribuição de subimagens, em 100 classes geradas, com tolerância de 0,1, para a abordagem *AE*, quando o tamanho da subimagem foi de 10x10 pixels, sendo a Fig. 23(a), para a paisagem da Fig.17 e a Fig. 23(b) para a paisagem da Fig.18.

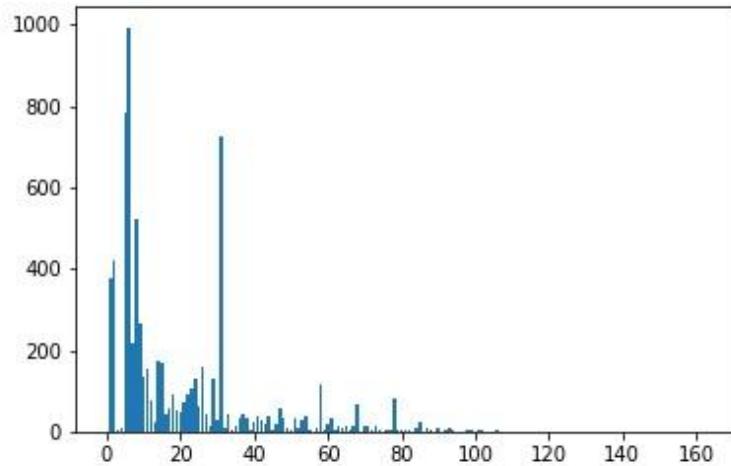


(a)

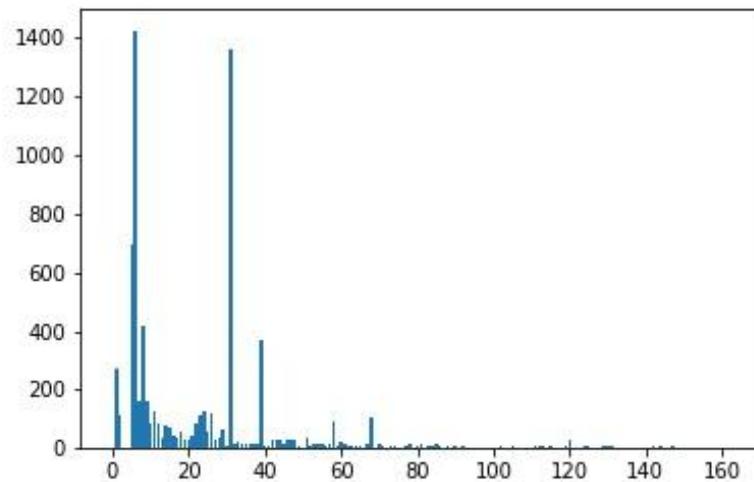


(b)

Figura 23: Histograma de classes (a) Paisagem_1 e (b) Paisagem_2, na abordagem AE, com $\varepsilon = 0,1$ e tamanho de subimagem de 10×10 . Fonte: Autor dessa dissertação.



(a)



(b)

Figura 24: Histograma de classes (a) Paisagem_1 e (b) Paisagem_2, na abordagem AE, com $\varepsilon = 0,1$ e tamanho de subimagem de 4x4. Fonte: Autor dessa dissertação.

É possível observar na Fig. 24, os histogramas de distribuição de subimagens, em 160 classes geradas, com tolerância de 0,1, para a abordagem AE, quando o tamanho da subimagem foi de 4x4 pixels, sendo a Fig. 24(a), para a paisagem da Fig.17 e a Fig. 24(b) para a paisagem da Fig.18.

4.5 Considerações em Relação ao Tempo de Processamento

Para dimensões de imagens padronizadas utilizadas no cotidiano teríamos por exemplo *Fullscreen, Standard 4:3*, 1600x1200; 1400x1050; 1280x960; 1152x864 e 1024x768; ou ainda *Standard 5:4*, 1280x1024; *Widescreen 16:10*, 1920x1200, como podem ser encontrados no site que disponibiliza papeis de paredes para computadores, “*Wallpapers Craft*”. Para uma imagem *Fullscreen, Standard 5:4*, 1280x1024, e subimagens de dimensões 4x4 teríamos 81920 subimagens, sendo duas imagens com essa dimensão teríamos 163840 subimagens para se extrair as características estatísticas e calcular as distâncias, criar as classes e calcular o *tNM*. Para o cálculo do *tNM* em abordagem *NC*, o procedimento é realizado em um tempo aceitável, não mais que 3 minutos. Para *tNM* em abordagem *AE*, com tolerância variando de 0,1 a 1, não houve impacto significativo no tempo dos cálculos de *tNM*, o mesmo não ocorre para o intervalo entre 0,01 a 0,09. Para quantidade de subimagens superior a 800, o processo se torna mais demorado para as configurações do computador utilizado. E com o intuito de se facilitar os cálculos, foi sugerido utilizar imagens que sejam representações de matrizes quadradas e suas subimagens múltiplas de 2.

4.6 Testes Preliminares com Imagens de Diferentes Cidades

A Fig. 25, contém em (a), imagem 1 - Cidade do México, e em (b), imagem 2 – Frankfurt, respectivamente. Esse par de imagens é processado para cálculo de *tNM*, cujo quadro é mostrado na Fig. 26(a) em abordagem *NC*, e na Fig. 26(b) na abordagem *AE*. Ambas retratam os cálculos de *tNM* e indicaram lentidão em função da variação da quantidade de subimagens geradas. Isso é facilmente perceptível em função de cálculos realizados com imagens que apresentam dimensões a partir de 210x210 pixels com o uso de tolerância = 0,1 e dimensões de subimagens 4x4 ou 2x2, no cálculo de *tNM* em abordagem *AE*.



(a)



(b)

Figura 25: (a) imagem 1 - Cidade do México e (b) imagem 2 - Frankfurt. Fonte: Autor dessa dissertação.

No quadro da Fig.26(a), tNM_{NC} , entre imagens da Cidade do México e Frankfurt, foram usados os valores de tolerância, em 1% e 50%, nos experimentos indicados como 7 e 13, resultando na diferença em relação ao número de classes geradas de 10 e 2, tempo de execução de 10s e 5s, e o tNM obtido foi de 0,747 e 0,816, respectivamente.

No quadro da Fig.26(b), tNM_{AE} , do mesmo par de imagens de cidades, os valores de tolerância usados foram de 0,9, 0,5 e 0,1. A quantidade de classes geradas foi de 2, 4 e 28 e os valores de tNM obtidos foram de 0,999, 0,991 e 0,661, respectivamente para os experimentos 101, 102 e 103. A dimensão das subimagens foi de 10x10 pixels e o tempo de execução foi de 10 min para todos os experimentos.

Imagem 1 e 2 respectivamente	Configuração NC (Níveis de Cinza)		Número de Experimento
Cidade do México - México .jpg e Frankfurt - Alemanha .jpg	Extensão	= .JPG	Tolerancia/Épsilon = 1%
	Dimensão da Imagem	= 600x600	
	Nº de Classes Geradas	= 10	tNM = 0,747
	Tempo de Execução	= 10 seg	
Cidade do México - México .jpg e Frankfurt - Alemanha .jpg	Extensão	= .JPG	Tolerancia/Épsilon = 50%
	Dimensão da Imagem	= 600x600	
	Nº de Classes Geradas	= 2	tNM = 0,816
	Tempo de Execução	= 5 seg	

(a)

Imagem 1 e 2 respectivamente	Configuração AE (Atributos Estatísticos)		Número de Experimento
Cidade do México - México .jpg e Frankfurt - Alemanha.jpg	Extensão da Imagem = .JPG	Atributos Estatísticos = 0,9	101
	Dimensão da Imagem = 600X600	Dimensão da Subimagem = 10X10	
	Nº de Subimagens Geradas = 7200		
	Quantidade de Classes Geradas = 2	tNM = 0,999	
	Tempo de execução = 10 min		
Cidade do México - México .jpg e Frankfurt - Alemanha.jpg	Extensão da Imagem = .JPG	Atributos Estatísticos = 0,5	102
	Dimensão da Imagem = 600X600	Dimensão da Subimagem = 10X10	
	Nº de Subimagens Geradas = 7200		
	Quantidade de Classes Geradas = 4	tNM = 0,991	
	Tempo de execução = 10 min		
Cidade do México - México .jpg e Frankfurt - Alemanha.jpg	Extensão da Imagem = .JPG	Atributos Estatísticos = 0,1	103
	Dimensão da Imagem = 600X600	Dimensão da Subimagem = 10X10	
	Nº de Subimagens Geradas = 7200		
	Quantidade de Classes Geradas = 28	tNM = 0,661	
	Tempo de execução = 10 min		

(b)

Figura 26: Experimento imagem 600x600. (a) abordagem NC e (b) abordagem AE. Fonte: Autor dessa dissertação.

No experimento denotado como 7, na Fig.26 (a), o número de 10 classes geradas para abordagem *NC* são em relação à primeira imagem, com os seguintes números de pixels respectivamente: 1: 111, 2: 5688, 3: 35948, 4: 89805, 5: 127247, 6: 66358, 7: 20343, 8: 8059, 9: 4738, 10: 1703. E para segunda imagem 1: 6, 2: 1982, 3: 69279, 4: 147405, 5: 106216, 6: 30239, 7: 3834, 8: 842, 9: 193, 10: 4.

A Fig.27(a) é o histograma das classes geradas para imagem da Fig. 25(a), Cidade do México, e a Fig. 27(b), para a imagem da Fig. 25(b), Frankfurt, referentes ao experimento 7, abordagem *NC*. A Fig.28(a) representa o histograma das classes geradas para a imagem da Fig. 25(a), e a Fig.28(b), para as classes geradas para a imagem da Fig. 25(b), referentes ao experimento denotado como 101, abordagem *AE*.

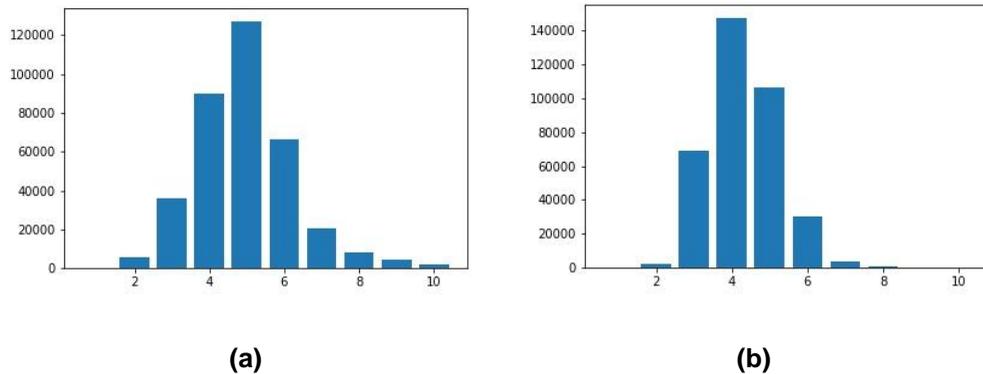


Figura 27: Histograma de classes para NC. (a) imagem 1 e (b) imagem 2, experimento 101. Fonte: Autor dessa dissertação.

O que é perceptível para esses histogramas da Fig.27 é que com relação à primeira imagem, a maior concentração de pixel por classe ocorreu na classe 5 enquanto para segunda imagem a maior concentração de pixels se deu na classe 4.

O histograma da Fig.28, refere-se à distribuição subimagens por classes referentes ao experimento 102, em que a tolerância usada é de 0,5. Nota-se que a maior concentração de pixels por classe se deu nas classes entre 0 e 5, em ambas as imagens.

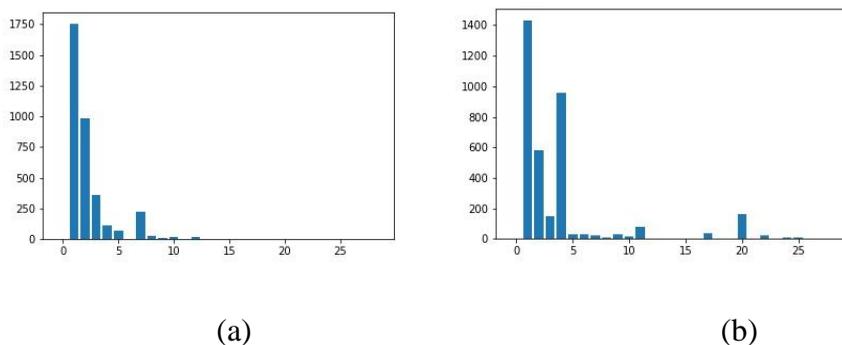


Figura 28: Histograma de classes para abordagem AE, experimento 102: (a) imagem 1 e (b) imagem2. Fonte: Próprio autor dessa dissertação.

É importante notar que a diferença dos valores resultantes de tNM para os experimentos 101 a 102, é insignificante, apesar a variação significativa na tolerância. No entanto, para os experimentos 102 a 103, a diferença nos valores de tNM resultantes é maior. Isso devido à generalização das classes que resulta nos casos de alto valor de tolerância, 0,9 e 0,5, respectivamente, nos experimentos 101 e 102. Já no experimento 103, o valor de tolerância de 0,1,

resulta numa melhor discriminação entre as subimagens. Em relação ao cálculo do tNM para imagens de cidades, preliminarmente foram realizados vários testes considerando-se 5 imagens do Continente americano e 5 imagens do continente europeu a saber.

Tabela 3 Cidades usadas nos teste preliminares

Continente Americano		Continente Europeu	
Brasil	Cuiabá - MT	Portugal	Lisboa
Brasil	Campo Grande - MS	Alemanha	Frankfurt
Canadá	Alberta - Edmonton	França	Lyon
Canadá	Regina - Saskatchewan	Itália	Nápoles
Canadá	Winnipeg - Manitoba	Itália	Palermo

Fonte: Autor dessa dissertação.

Essas imagens foram testadas primeiro em relação a suas dimensões, ou seja, a quantidade de pixels existentes nas imagens foi definida de modo a garantir um tempo médio de 10 minutos para a execução do código. As imagens foram obtidas de fotos de satélite pelo *software* do *Google Maps*. As altitudes variaram entre 1 a 5 quilômetros em relação ao solo, variando também as dimensões da imagem e os parâmetros como tolerância, quantidade de subimagens e quantidade de classes pela tolerância nos testes.

4.6.1 tNM Variando as Subimagens e Tolerâncias

Na figura 29 é apresentado um gráfico que demonstra a variação do valor de tNM em função das variações do tamanho das subimagens, na abordagem *AE*, num experimento denotado 750. Os valores de subimagens

variam de 4x4 a 256x256, que denota a dimensão da imagem inteira, sem subdivisão.

Imagem 1 e 2 respectivamente	Configuração AE (Atributos Estatísticos)	Número de Experimento
Cidade do México - México e Frankfurt - Alemanha	Extensão da Imagem = .JPG	750
	Dimensão da Imagem = 256x256	
	Nº de Subimagens Geradas = 512	
	Quantidade de Classes Geradas = 47	
	Tempo de execução = 10 min	
	Atributos Estatísticos = 0,1	
	Dimensão da Subimagem = 4x4	
tNM = 0,981		

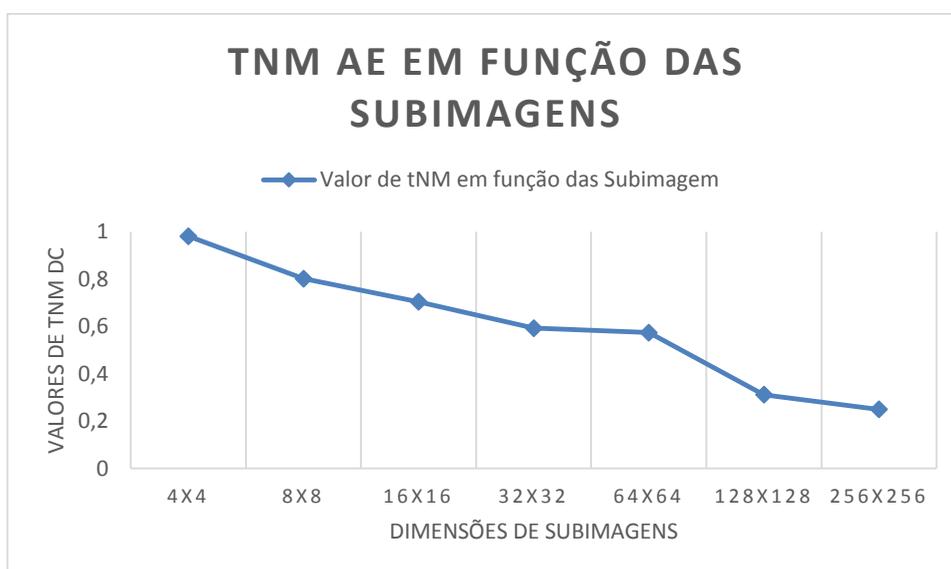
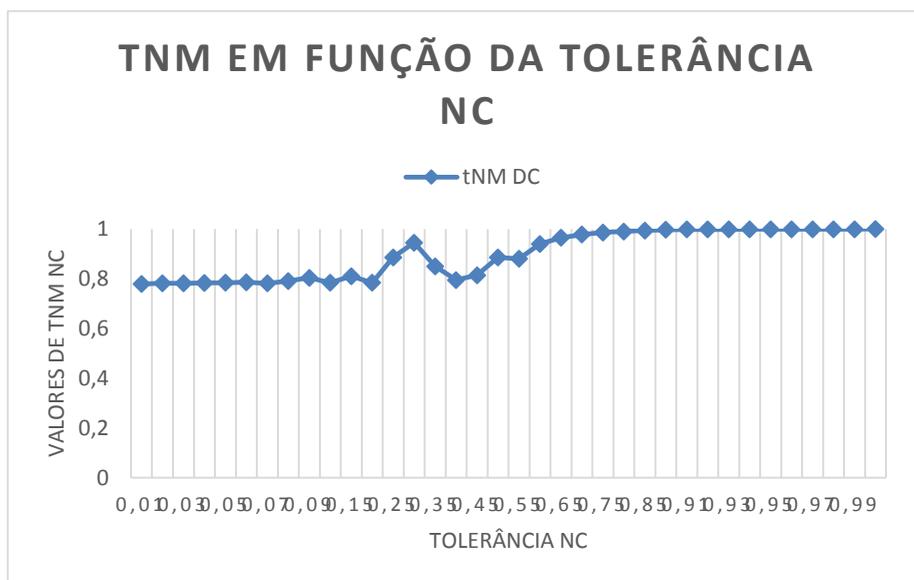
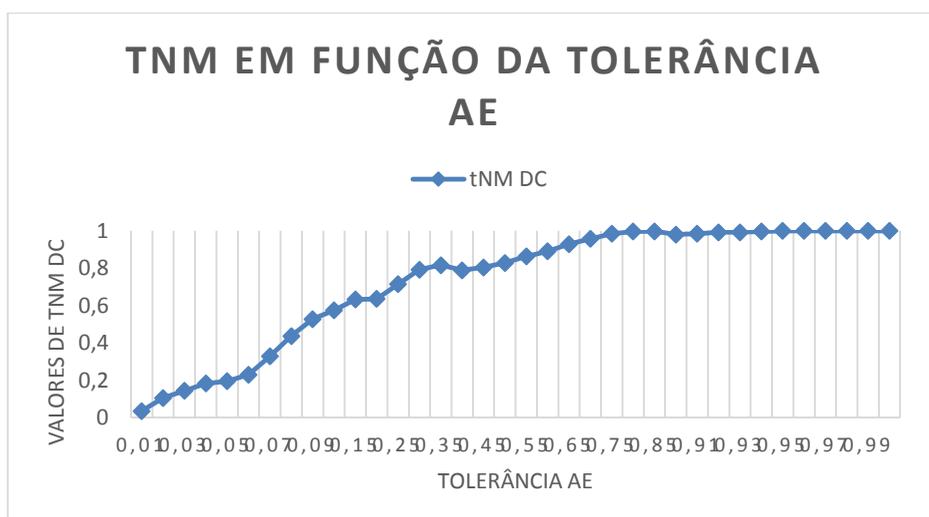


Figure 29: tNM em função do tamanho das subimagens. Fonte: Autor dessa dissertação.

Nota-se que à medida que o tamanho da subimagem aumenta, o valor de tNM diminui. Com as mesmas imagens utilizadas no experimento 750, foram obtidos os valores de tNM variando a tolerância, na abordagem NC, com é mostrado na Fig. 30(a); e um outro gráfico representando o cálculo do tNM em AE, na Fig.30(b).



(a)



(b)

Figure 30: tNM em função da tolerância: (a) NC e (b) AE. (a) Fonte: Autor dessa dissertação.

Os gráficos da Fig. 30 representam a variação de testes de tolerância de 1% a 100%. Observe que os gráficos tendem para 1, contudo, o gráfico de NC tem seu valor de tNM inicial em torno de 0,700 e tende para 1. Comparando os gráficos da Fig. 30, pode-se afirmar que a abordagem AE apresenta maior possibilidade de discriminação entre as imagens para valores menores de tolerância, para esse tipo de pares de imagens. Afim de proporcionar um tempo de execução em torno de 10 minutos para os testes, e precisão em relação ao

cálculo do tNM , as dimensões das imagens, tolerâncias e tamanho de subimagens foram ajustados para os experimentos seguintes.

4.7 Experimentos com a Utilização dos Parâmetros Padrões

Determinados os parâmetros padrões para a aplicação do algoritmo de tNM , realizou-se os experimentos que se dividiram em:

- Imagens faciais,
- Imagens de áreas desmatadas e
- Comparação de cidades por fotos de satélites.

4.7.1 Imagens faciais

Para os testes de Imagens Faciais, utiliza-se faces de pessoas antes e depois de algum processo, com o intuito de verificar o nível de similaridade pelo tNM . Nota-se que existem vários aspectos que influenciam o resultado, como a variação na cor do fundo, no ambiente e luminosidade, além dos efeitos do procedimento aplicado nas faces. A seguir constam quatro cálculos de tNM , denotados experimento 73, 74, 75 e 76.

4.7.1.1 Experimento 73.

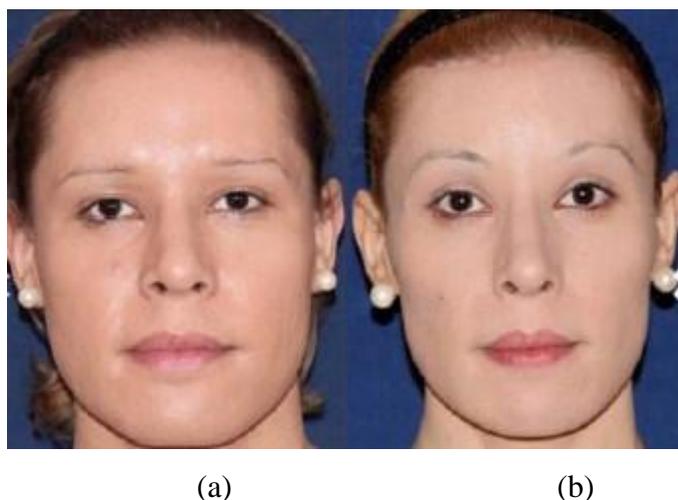


Figura 31: (a) Mulher antes e (b) Mulher depois da feminização. Fonte: <https://www.t-change.com/pt/feminizacao-facial-antes-e-depois.php>.

Imagem 1 e 2 respectivamente	Configuração NC (Níveis de Cinza)	Configuração AE (Atributos Estatísticos)	Número de Experimento
Mulher antes e Mulher depois_1	Extensão = .JPG	Extensão da Imagem = .JPG	73
	Dimensão da Imagem = 170x220	Dimensão da Imagem = 170x220	
	Nº de Classes Geradas = 100	Nº de Subimagens Geradas = 2992	
	Tempo de Execução = 10 seg	Quantidade de Classes Geradas = 77	
	Tolerancia/Épsilon = 1%	Tempo de execução = 3 min	
	tNM = 0,840	Atributos Estatísticos = 0,1	
	Dimensão da Subimagem = 5x5		
	tNM = 0,850		

Figura 32: Resultado do experimento 73. Fonte: Autor dessa dissertação.

O tNM no experimento 73, entre as duas imagens da Fig.31, de dimensão 170x220, antes do processo de feminização (a) e após o processo (b), teve os seguintes resultados mostrados no quadro da Fig.32, resumidos em: a) para a abordagem *NC*, valor de tNM de 0,48, e b) para *AE*, 0,85. Nota-se que vários fatores como luminosidade, posicionamento, brincos, diferença nos cabelos, entre outros, influenciam no resultado. O índice de tolerância usado foi de 1% para *NC* e 0,1 para *AE*, e o número de classes geradas foi de 100 para *NC* e 2992 para *AE*. A dimensão da subimagem na abordagem *AE* foi de 5x5. O tempo de execução para *NC* foi de 10s e para *AE*, 3 min.

4.7.1.2 Experimento 74



Figura 33: (a) Mulher antes e (b) Mulher depois do tratamento de manchas. Fonte: <http://www.julianagoes.com.br/luz-pulsada-antes-e-depois-tratamento-de-manchas/>.

Mulher antes e Mulher depois_2	Extensão	= .JPG	Extensão da Imagem	= .JPG	74
	Dimensão da Imagem	= 160x160	Dimensão da Imagem	= 160x160	
	Nº de Classes Geradas	= 100	Nº de Subimagens Geradas	= 3200	
	Tempo de Execução	= 10 seg	Quantidade de Classes Geradas	= 98	
	Tolerancia/Épsilon	= 1%	Tempo de execução	= 3 min	
	tNM	= 0,713	Atributos Estatísticos	= 0,1	
			Dimensão da Subimagem	= 4x4	
		tNM	= 0,899		

Figura 34: Resultado para o experimento 74. Fonte: Autor dessa dissertação.

No experimento 74, entre as duas imagens da Fig. 33, de dimensão 160x160, antes do processo de tratamento de manchas (a) e após o processo (b), teve os seguintes resultados mostrados no quadro da Fig.34, resumidos em: a) para a abordagem NC, valor de tNM de 0,713, e b) para AE, 0,899. O índice de tolerância usado foi de 1% para NC e 0,1 para AE, e o número de classes geradas foi de 100 para NC e 3200 para AE. A dimensão da subimagem na abordagem AE foi de 4x4. O tempo de execução para NC foi de 10s e para AE, 3 min.

4.7.1.3 Experimento 75



Figura 35: (a) Imagem de face feminina antes e (b) após a aplicação de software edição, de rejuvenescimento. Fonte: <https://www.tuasaude.com/lifting-facial/>.

Mulher antes e Mulher depois_3	Extensão	= .JPG	Extensão da Imagem	= .JPG	75
	Dimensão da Imagem	= 320x428	Dimensão da Imagem	= 320x428	
	Nº de Classes Geradas	= 100	Nº de Subimagens Geradas	= 17120	
	Tempo de Execução	= 10 seg	Quantidade de Classes Geradas	= 169	
	Tolerancia/Épsilon	= 1%	Tempo de execução	= 1 h	
	tNM	= 0,809	Atributos Estatísticos	= 0,1	
			Dimensão da Subimagem	= 4x4	
			tNM	= 0,752	

Figura 36: Resultado do Experimento 75. Fonte: Autor dessa dissertação.

No experimento 75, de imagens de face feminina da Fig.35, de dimensão 320x428, antes da aplicação do software de edição, de rejuvenescimento (a) e após a aplicação (b), teve os seguintes resultados mostrados no quadro da Fig.36, resumidos em: a) para a abordagem *NC*, valor de *tNM* de 0,809, e b) para *AE*, 0,752. O índice de tolerância usado foi de 1% para *NC* e 0,1 para *AE*, e o número de classes geradas foi de 100 para *NC* e 17120 para *AE*. A dimensão da subimagem na abordagem *AE* foi de 4x4. O tempo de execução para *NC* foi de 10s e para *AE*, uma hora.

4.7.1.4 Experimento 76



(a)

(b)



(c)

(d)

Figura 37: (a) Imagem de Face Feminina antes e (b) Depois de procedimento estético; (c) parte central (secção) da imagem (a); e (d) parte central (secção) da imagem (b) . Fonte: <http://daiannepossoly.com.br/video-botox-25-anos-antes-e-depois/>.

Mulher antes e Mulher depois_4	Extensão	= .JPG	Extensão da Imagem	= .JPG	76
	Dimensão da Imagem	= 200x200	Dimensão da Imagem	= 200x200	
	Nº de Classes Geradas	= 100	Nº de Subimagens Geradas	= 5000	
	Tempo de Execução	= 10 seg	Quantidade de Classes Geradas	= 109	
	Tolerancia/Épsilon	= 1%	Tempo de execução	= 7 min	
	tNM	= 0,934	Atributos Estatísticos	= 0,1	
			Dimensão da Subimagem	= 4x4	
			tNM	= 0,839	

Figura 38: Resultados de NC (esquerda) e AE (direita). Fonte: Autor dessa dissertação.

No experimento 76, de imagem de face feminina da Fig. 37, de dimensão 200x200, antes da aplicação de procedimento estético (a) e após a aplicação (b), teve os seguintes resultados mostrados no quadro da Fig.38, resumidos em: a) para a abordagem *NC*, valor de *tNM* de 0,934, e b) para *AE*, 0,839. O índice de tolerância usado foi de 1% para *NC*, e 0,1 para *AE*, e o número de classes geradas foi de 100 para *NC* e 5000 para *AE*. A dimensão da subimagem na abordagem *AE* foi de 4x4. O tempo de execução para *NC* foi de 10s e para *AE*, 7 minutos.

Nota-se que no experimento 73 os valores de *tNM* para ambas as abordagens foram similares, próximos uns dos outros. No experimento 74 os valores de *tNM* se diferenciaram sendo que na abordagem *NC* foi menor em relação à abordagem *AE*. No experimento 75, o resultado de *tNM* foi maior para *AE*, em relação a *NC*. No experimento 76, o *tNM* se deu a partir de imagens de

faces obtidas nos anos 2015 e 2018. Os resultados retornaram um valor de tNM de 0,934 e 0,839, respectivamente, para *NC* e *AE*, para as imagens antes e depois do procedimento estético.

Tabela 4: Resumo os experimentos sobre imagens faciais

	Experimento 73	Experimento 74	Experimento 75	Experimento 76	Valor médio
NC	0,840	0,713	0,809	0,934	0,824
AE	0,850	0,899	0,752	0,839	0,834

Fonte: Autor dessa dissertação

Na Tabela 4 são resumidos os resultados da obtenção de tNM para os experimentos sobre imagens faciais. Nota-se que os valores obtidos para as abordagens *NC* e *AE* foram muito próximos, o que resultou nos valores médios próximos para *NC*, que foi de 0,824, e para *AE*, de 0,834.

4.7.2 Imagens de áreas desmatadas

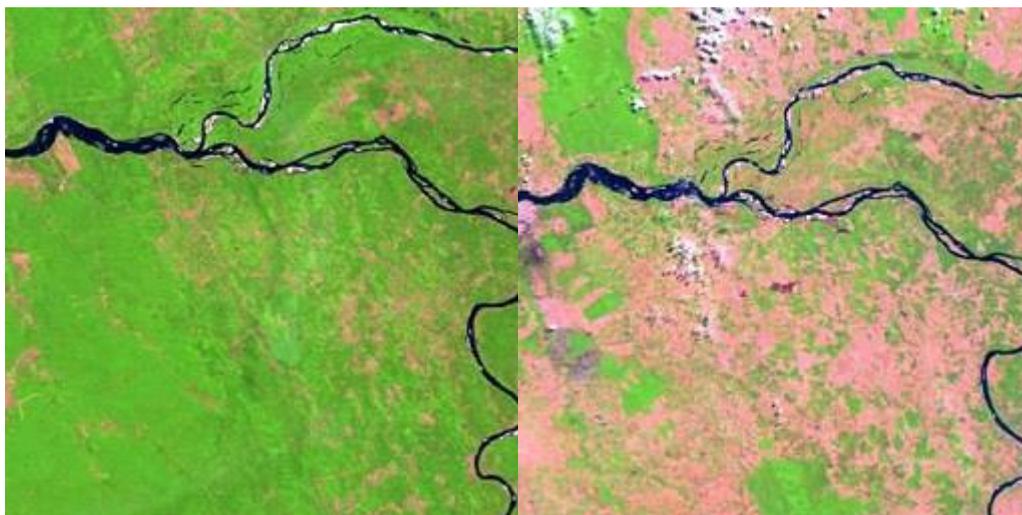
Os experimentos sobre imagens de áreas desmatadas, teve uma inspiração na possibilidade de diferenciar valores de tNM para identificar possíveis áreas de desmatamento em regiões geográficas. Os experimentos foram numerados como 80, referente ao par de imagens da Fig. 39; 81, referente ao par de imagens da Fig.40; e 82, referente ao par de imagens da Fig.41.



(a)

(b)

Figura 39: (a) Imagens de áreas antes do desmatamento, e (b) depois do desmatamento. Fonte: <https://blogs.oglobo.globo.com/ancelmo/post/satelite-flagra-desmatamento-em-ilha-que-costumava-ser-alugada-por-revista.html>



(a)

(b)

Figura 40: (a) imagens de áreas antes do desmatamento, e (b) depois do desmatamento. fonte: <http://g1.globo.com/Amazonia/0,,MUL1363591-16052,00-PROJETO+DE+LEI+PROPOE+ANISTIA+A+QUEM+DESMATOU+ANTES+DE.html>



(a)

(b)

Figura 41: (a) imagem de área antes do desmatamento, e (b) depois do desmatamento.

Fonte: https://elpais.com/elpais/2017/09/12/album/1505218806_296425.html#foto_gal_3

Imagem 1 e 2 respectivamente	Configuração NC (Níveis de Cinza)	Configuração AE (Atributos Estatísticos)	Número de Experimento
Desmatamento Antes e Depois_1	Extensão = .JPG	Extensão da Imagem = .JPG	80
	Dimensão da Imagem = 256x256	Dimensão da Imagem = 256x256	
	Nº de Classes Geradas = 100	Nº de Subimagens Geradas = 8192	
	Tempo de Execução = 10 seg	Quantidade de Classes Geradas = 776	
	Tolerância/Épsilon = 1%	Tempo de execução = 10 min	
	tNM = 0,500	Atributos Estatísticos = 0,1	
Desmatamento Antes e Depois_2	Extensão = .JPG	Extensão da Imagem = .JPG	81
	Dimensão da Imagem = 256x256	Dimensão da Imagem = 256x256	
	Nº de Classes Geradas = 100	Nº de Subimagens Geradas = 8192	
	Tempo de Execução = 10 seg	Quantidade de Classes Geradas = 56	
	Tolerância/Épsilon = 1%	Tempo de execução = 10 min	
	tNM = 0,350	Atributos Estatísticos = 0,1	
Desmatamento Antes e Depois_3	Extensão = .JPG	Extensão da Imagem = .JPG	82
	Dimensão da Imagem = 256x256	Dimensão da Imagem = 256x256	
	Nº de Classes Geradas = 100	Nº de Subimagens Geradas = 8192	
	Tempo de Execução = 10 seg	Quantidade de Classes Geradas = 73	
	Tolerância/Épsilon = 1%	Tempo de execução = 10 min	
	tNM = 0,893	Atributos Estatísticos = 0,1	
		Dimensão da Subimagem = 4x4	
		tNM = 0,935	

Figura 42: Resultado do experimentos 80, 81 e 82. Fonte: Autor dessa dissertação.

Na Fig. 42 é mostrado um quadro resumindo os resultados do processamento de imagens de áreas geográficas, antes e depois do desmatamento, referentes aos experimentos 80, 81 e 82. Com relação ao experimento 80 o valor de tNM baseado em NC foi de 50%, considerando que as imagens obtidas por satélites não mantiveram a mesma tonalidade

influenciando diretamente nesse resultado. No experimento 81, o baixo valor do tNM foi causado em função da ausência do verde na imagem. O valor de tNM para AE para os experimentos 80, 81 e 82 indicaram um índice adequado de similaridade, considerando o desmatamento na região e a diferença de luminosidade entre os pares de imagens, principalmente dos dois primeiros experimentos. Assim nesses casos os valores referentes ao teste indicam que através do cálculo do tNM baseado em AE é possível identificar mudanças em uma região correlatas ao desmatamento.

Tabela 5: Resumo os experimentos sobre imagens de áreas desmatadas

	Experimento 80	Experimento 81	Experimento 82	Valor médio
NC	0,500	0,350	0,893	0,581
AE	0,900	0,763	0,935	0,866

Fonte: Autor dessa dissertação

Na Tabela 5 são resumidos os resultados da obtenção de tNM para os experimentos sobre imagens de áreas desmatadas. Nota-se que os valores obtidos para as abordagens NC e AE foram muito diferentes, resultando nos valores médios de 0,581 e 0,866 para NC e AE , respectivamente. Analisando os pares de imagens é possível notar que apesar das texturas entre os pares de imagens serem similares, a iluminação é diferenciada, o que refletiu nos valores de tNM em NC .

4.7.3 Imagens de Regiões Centrais de Cidades

Neste experimento, são feitos os cálculos de similaridade entre imagens fotográficas obtidas por satélites, de regiões centrais de cidades. São consideradas 26 imagens, dentre elas 6 do continente americano; e mais 5 imagens de cada um dos continentes: europeu, africano, asiático e oceânico, conforme Tabela 4. As imagens das cidades consideradas se encontram no Apêndice - A.

Foram obtidos os resultados de processamentos de tNM nas abordagens NC e AE , para cada par de cidades da Tabela 6, cujos valores são

apresentados no Apêndice-B. O tamanho das imagens é de 256x256 pixels, sendo usado para a tolerância zero para *NC*, e 0,1 para *AE*, em que o tamanho de subimagem foi definido em 8x8. Após a obtenção dos valores de *tNM*, foram calculados os valores da distância de similaridades, denotado *dS*, utilizando o complemento do valor de *tNM*, usando a equação (9),

$$dS = (1-tNM) \quad (9)$$

para todos os pares de imagens de cidades consideradas. Utilizando-se das distâncias *dS*, foi feita a aplicação do Algoritmo C, de classificação, descrito para *TNS*, utilizando uma tolerância de 0,2, e foram obtidas as classes de tolerância para as cidades, cujo resultado, para os valores de *tNM* na abordagem *NC* é apresentada na Tabela 7, onde em cada linha tem-se uma classe de tolerância obtida.

Tabela 6: Cidades cujas imagens foram consideradas

Continente	País	Cidade
AMERICANO	Brasil	Cuiabá - MT
	Brasil	Campo Grande - MT
	México	Cidade do México
	Canadá	Manitoba - Winnipeg
	Canadá	Saskatchewan - Regina
	Canadá	Edmonton - Alberta
EUROPEU	Alemanha	Frankfurt
	Portugal	Lisboa
	Itália	Nápoles
	Itália	Palermo
	França	Lyon
AFRICANO	Libéria	Monróvia
	Congo	Pointe-Noire
	Costa do Marfim	Abobo
	Egito	Porto Said
	Moçambique	Matola
ASIÁTICO	Japão	Sakai
	Japão	Niigata
	Índia	Nova Bombaim
	Cazaquistão	Astana
	Nepal	Catmandu
OCEÂNCIO	Austrália	Newcastle
	Austrália	Adelaide
	Austrália	Camberra
	Austrália	Gold Coast
	Nova Zelândia	Wellington

Fonte: Autor dessa dissertação

Na Fig. 43 é ilustrada a classificação em forma de um gráfico, onde cada retângulo encerra uma das classes da Tabela 7. Para melhor visualização, as cidades de cada continente se encontram coloridas diferentemente, sendo continente americano (preta), europeu (vermelha), africano (azul), asiático (marrom) e australiano (verde).

Pela Fig.43 é possível notar que cidades de um mesmo continente tendem a ficar em mesmas classes, por exemplo: Nápoles e Palermo, no continente europeu; Sakai e Niigata no continente asiático; Wellington e Gold Coast no continente australiano; e Cuiabá, Manitoba, Regina e Edmonton, no continente americano.

Tabela 7: Tabela de classes em abordagem NC

CLASSES	CIDADES								
Classe 1	Abobo	New Castle	Porto Said						
Classe 2	Abobo	Astana	Cuiabá	Edmonton	Lisboa				
Classe 3	Adelaide	Camberra	Campo Grande	Catmandu	C. do Mexico	Lyon			
Classe 4	Adelaide	Camberra	Campo Grande	Catmandu	C. do Mexico	Nápoles	Palermo		
Classe 5	Adelaide	Camberra	Campo Grande	Catmandu	Nápoles	Palermo	Pointe Noire		
Classe 6	Adelaide	Lisboa	Pointe Noire	Regina					
Classe 7	Adelaide	Lyon	Sakai						
Classe 8	Adelaide	Camberra	Catmandu	Nápoles	Palermo	Pointe Noire	Regina		
Classe 9	Adelaide	Camberra	Catmandu	Nápoles	Palermo	Sakai			
Classe 10	Astana	Cuiabá	Edmonton	Gold Coast	Lisboa	Manitoba	Nápoles	Regina	
Classe 11	Astana	Cuiabá	Edmonton	Gold Coast	Lisboa	Nápoles	Palermo	Regina	
Classe 12	Astana	Cuiabá	Manitoba	Porto Said					
Classe 13	Camberra	Campo Grande	Matola	Nova Bombaim	Pointe Noire				
Classe 14	Camberra	Edmonton	Nápoles	Palermo	Pointe Noire	Regina			
Classe 15	C. do México	Matola	Nova Bombaim						
Classe 16	Edmonton	Gold Coast	Lisboa	Nápoles	Palermo	Pointe Noire	Regina		
Classe 17	Gold Coast	Wellington							
Classe 18	Niigata	Sakai							

Fonte: Autor dessa dissertação

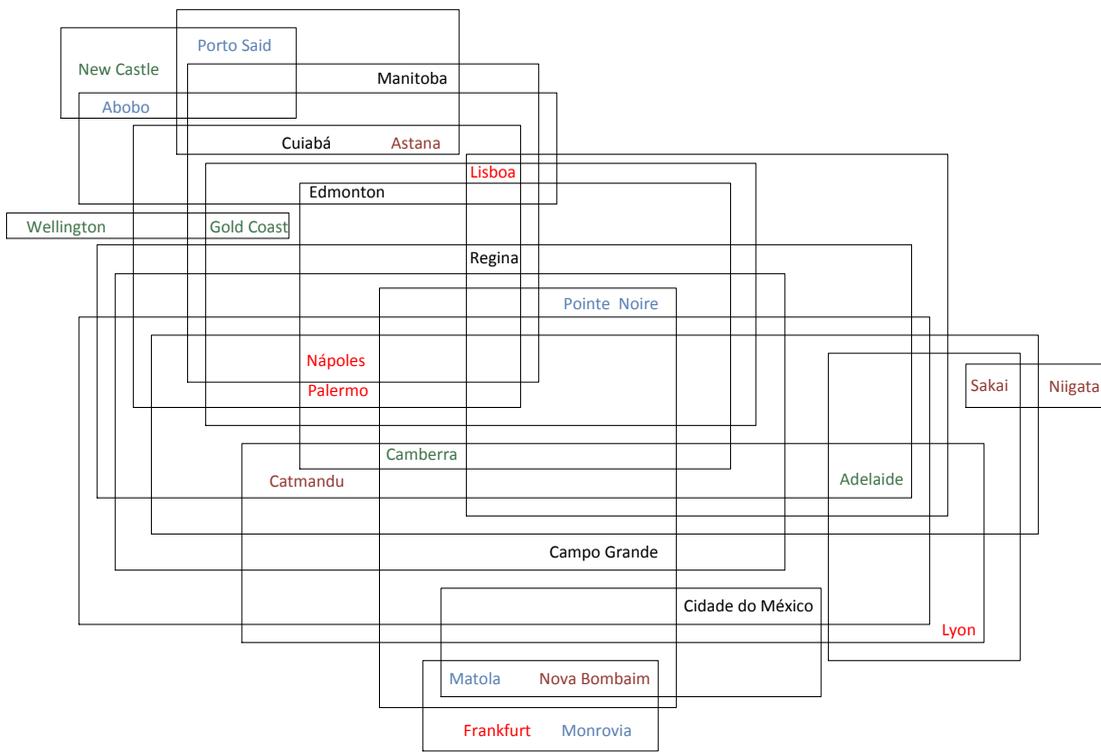


Figure 43: Gráfico de classificação usado os resultados de tNM em NC. Autor dessa dissertação.

Em seguida, foram obtidas as classes de tolerância para as cidades, para o resultado de tNM , na abordagem AE , conforme mostra a Tabela 8, onde em cada linha tem-se uma classe de tolerância obtida.

Tabela 8: Tabela de classes AE

CLASSES	CIDADES						
Classe 1	Abobo	Catmandu					
Classe 2	Adelaide	C. do México	Frankfurt	Porto Said			
Classe 3	Adelaide	C. do México	Lyon	Port Said			
Classe 4	Adelaide	Frankfurt	Lyon	Porto Said			
Classe 5	Adelaide	Frankfurt	Niigata				
Classe 6	Adelaide	Pointe Noire	Regina				
Classe 7	Astana	Campo Grande	Palermo				
Classe 8	Camberra						
Classe 9	Campo Grande	Cuiabá	Manitoba	Pointe Noire			
Classe 10	Catmandu	Gold Coast	Palermo	Pointe Noire	Regina		
Classe 11	C. do México	Edmonton	Lisboa	Lyon	Port Said		
Classe 12	Cuiabá	Gold Coast	Manitoba	Pointe Noire	Palermo	Regina	Wellington
Classe 13	Edmonton	Frankfurt	Monróvia	New Castle			
Classe 14	Edmonton	Lisboa	Lyon	Nápoles	Porto Said		
Classe 15	Frankfurt	Monróvia	New Castle	Sakai			
Classe 16	Frankfurt	Nova Bombaim					
Classe 17	Matola						
Classe 18	Nápoles	Sakai					
Classe 19	Niigata	Sakai					

Fonte: Autor dessa dissertação

Na Fig.44 é ilustrada a classificação em forma de um gráfico, onde cada retângulo encerra uma das classes da Tabela 8. Da mesma forma que a Fig.43, as cidades de cada continente se encontram coloridas diferentemente, sendo continente americano (preta), europeu (vermelha), africano (azul), asiático (marrom) e australiano (verde).

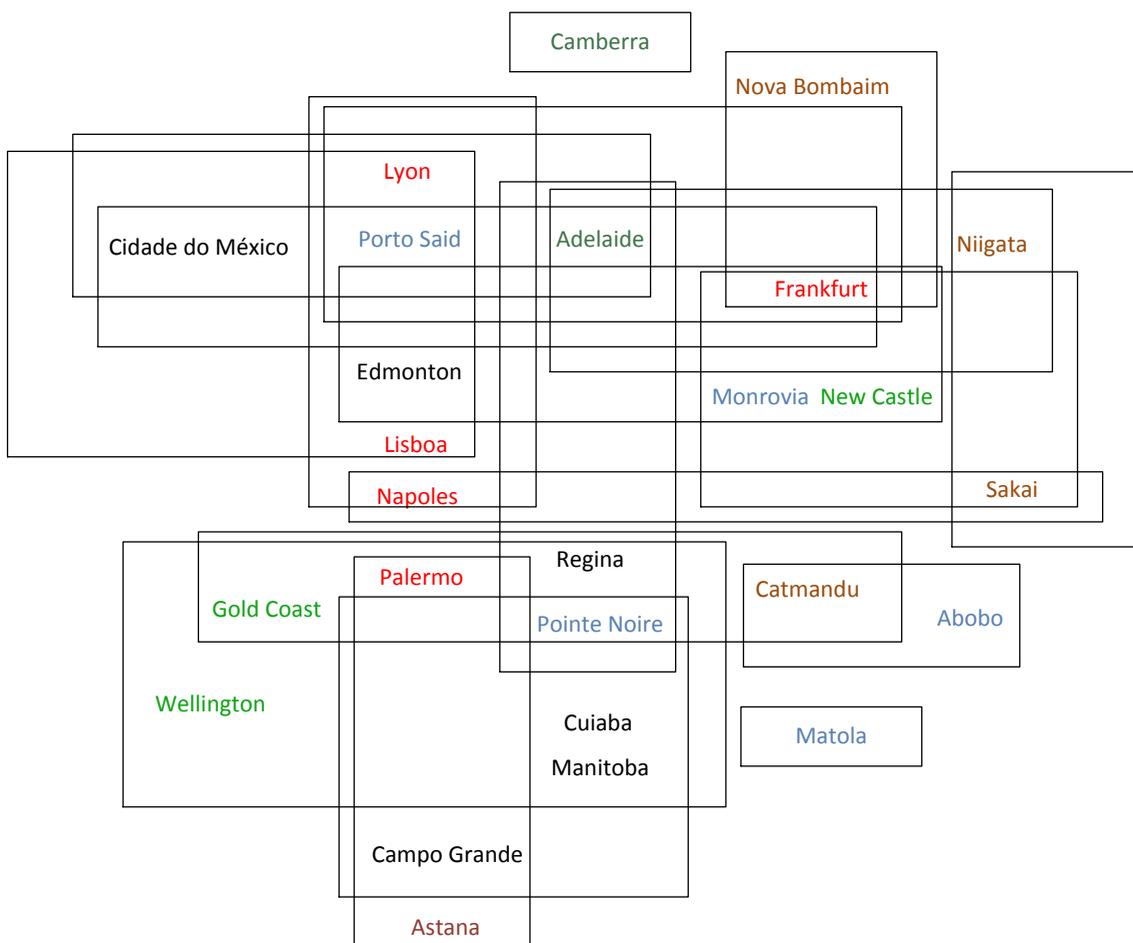


Figure 44: Gráfico de classificação usando os resultados de tNM em AE. Fonte Autor dessa dissertação.

4.8 Análise e Validação dos Resultados

Nesta seção, os resultados obtidos de tNM entre imagens de cidades consideradas são analisadas com mais detalhes, para as duas abordagens. Inicialmente, os pares de cidades e os respectivos tNMs foram ordenados, em ordem decrescente de valores de tNM obtidos. Sendo assim, os resultados de comparação serão analisados quanto aos maiores e menores valores de tNM.

4.8.1 Maiores e Menores Valores de tNM Obtidos

Na Tabela 9, são mostrados os maiores valores de tNM obtidos, quando comparadas as cidades consideradas, usando a abordagem NC. O maior valor

de tNM, 0,950, foi obtido entre as imagens das cidades Regina e Edmonton, ambos do Canadá, no Continente Americano. As imagens dessas duas cidades são mostradas nas Figs. 45(a) e (b), respectivamente.

Tabela 9: Maiores valos de tNM obtidos na abordagem NC.

Cidade 1	Cidade 2	tNM	Cidade 1	Cidade 2	tNM
Regina	Edmonton	0.950	Adelaide	Camberra	0.919
Cid. Mexico	Pointe-Noire	0.944	Lisboa	Astana	0.917
Matola	NovaBombaim	0.943	Manitoba	Astana	0.913
Edmonton	Lisboa	0.942	Campo Grande	Camberra	0.912
Palermo	Adelaide	0.938	Nápoles	Adelaide	0.911
Regina	Nápoles	0.935	Porto Said	Newcastle	0.910
Frankfurt	Monrovia	0.931	Catmandu	Adelaide	0.909
Cid.Mexico	Camberra	0.928	Catmandu	Canberra	0.909
Nápoles	Palermo	0.927	Astana	GoldCoast	0.909
Edmonton	Nápoles	0.924	Regina	Lisboa	0.909
Pointe-Noire	Camberra	0.924	Lisboa	Nápoles	0.905
Edmonton	Astana	0.922	Cuiaba	Lisboa	0.903
Lisboa	Gold Coast	0.921	Pointe-Noire	Adelaide	0.902
Campo Grande	Pointe-Noire	0.921	Abobo	Porto Said	0.900
Campo Grande	Cid.Mexico	0.921	Palermo	Pointe-Noire	0.900

Fonte: Autor dessa dissertação

Na Tabela 10, são mostrados os trinta maiores valores de tNM, na abordagem AE, e nesse caso, o maior valor de tNM foi de 0,936, e obtida entre as imagens de cidades Regina e Pointe Noire, do Continente Americano e do Continente Africano, respectivamente. A imagem da cidade de Pointe Noire é mostrada na Fig. 45(c). O valor de tNM entre as imagens de Regina e Edmonton, na abordagem AE, foi de 0,647, bem baixo em relação à abordagem NC; e o valor de tNM entre as imagens de Regina e Pointe Noire em NC foi de 0,831.

Tabela 10: Maiores valores de tNM obtidos na abordagem AE.

City 1	City 2	tNM	City 1	City2	tNM
Regina	Pointe-Noire	0.936	Palermo	Astana	0.883
Regina	Gold Coast	0.936	Lyon	Porto Said	0.880
Lisboa	Nápoles	0.936	Winnipeg	Wellington	0.878
Pointe-Noire	Gold Coast	0.927	Edmonton	Lisboa	0.877
Nápoles	Lyon	0.922	Campo Grande	Astana	0.877
Edmonton	Nápoles	0.918	Abobo	Catmandu	0.874
Campo Grande	Palermo	0.914	Cuiabá	Campo Grande	0.873
Monrovia	Newcastle	0.911	Winnipeg	Palermo	0.871
Winnipeg	Gold Coast	0.911	Frankfurt	Niigata	0.869
Winnipeg	Regina	0.902	Cid.Mexico	Porto Said	0.867
Sakai	Newcastle	0.902	Nápoles	Sakai	0.866
Winnipeg	Pointe-Noire	0.896	Gold Coast	Wellington	0.863
Frankfurt	Adelaide	0.893	Palermo	Pointe-Noire	0.862
Cuiabá	Winnipeg	0.890	Porto Said	Adelaide	0.861
Edmonton	Lyon	0.886	Campo Grande	Winnipeg	0.859

Fonte: Autor dessa dissertação

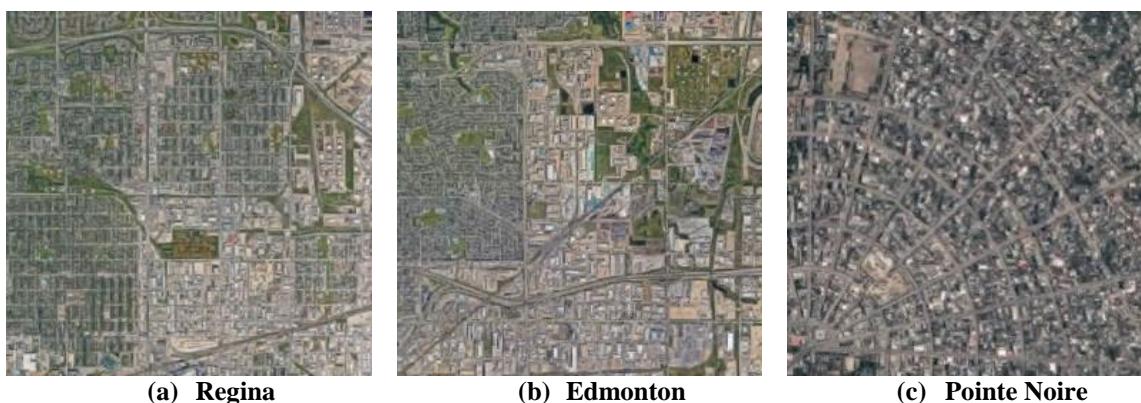


Figura 45: Imagens de cidades: (a) Regina, (b) Edmonton, (c) Pointe Noire, com maiores valores de tNM em NC (Regina x Edmonton); e em AE (Regina x Pointe Noire). Fonte: Autor dessa dissertação

Na Fig. 46 são mostrados em gráfico cartesiano, os valores de tNM obtidos quando a imagem de Regina é comparada com todas as outras cidades consideradas, usando ambas as abordagens. O maior valor de tNM em NC e AE são ressaltados. É também observado que nas duas abordagens, os valores de tNM são tão próximos, mas o comportamento desses valores apresentam uma tendência similar.

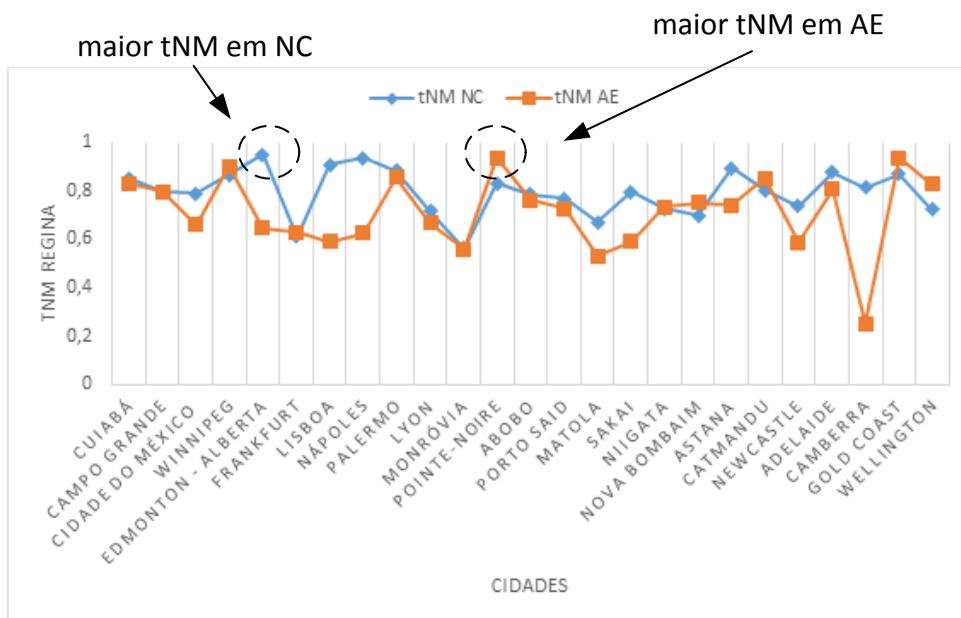


Figura 46: Valores de tNM para NC e AE, entre a imagem de Regina comparada com imagens de todas as outras cidades consideradas, mostrando o maior valor em ambas as abordagens. Fonte: Autor dessa dissertação.

Na Tabela 11, são mostrados os pares de cidades e os respectivos tNMs, para os cinco menores valores de tNM, na abordagem NC, e o menor valor, 0,349, foi obtido entre as imagens de Monrovia e Newcastle. Curiosamente, na abordagem AE, o valor de 0,911 foi obtido entre essas cidades. Isso significa que apesar dos atributos de níveis de cinza serem diferentes, os atributos estatísticos são parecidos entre essas imagens, como pode ser verificado nas Figs. 47(a) e (b), respectivamente.

Tabela 11: Cinco menores valores de tNM, obtidos para a abordagem NC.

Cidade 1	Cidade 2	tNM
Frankfurt	Porto Said	0.402
Monrovia	Abobo	0.396
Frankfurt	Newcastle	0.388
Monrovia	Porto Said	0.362
Monrovia	Newcastle	0,349



(a) Monrovia



(b) Newcastle

Figura 47: Imagens de Cidades: (a) Monrovia, (b) Newcastle, com menor valor de tNM na abordagem NC. Fonte: Autor dessa dissertação

Na Fig. 48, é mostrado o gráfico cartesiano de tNM entre a imagem de Monrovia e todas as outras cidades consideradas no experimento, destacando o menor valor de tNM na abordagem NC.

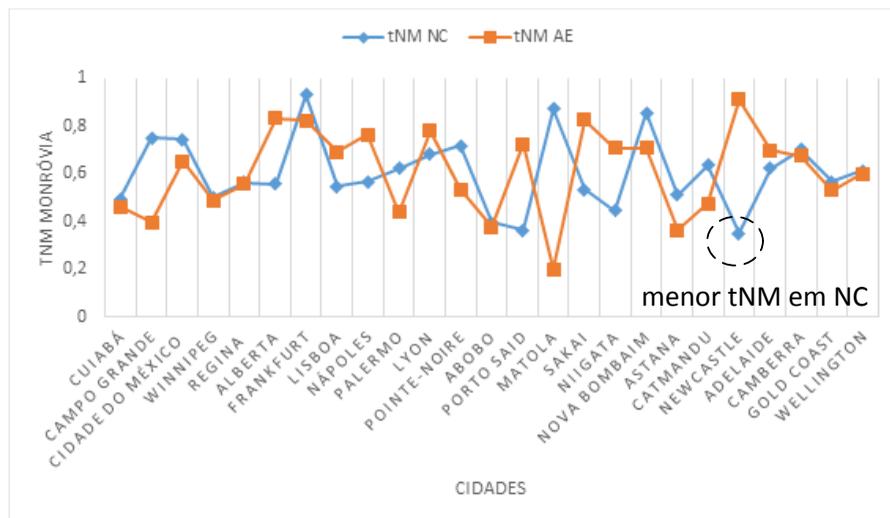
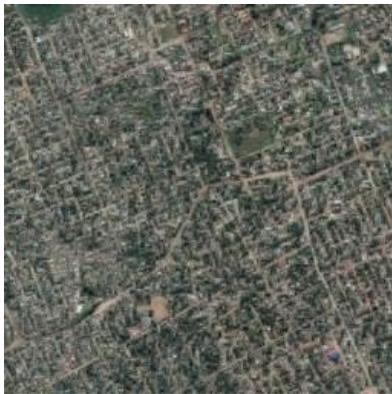


Figura 48: Valores de tNM para NC e AE, obtidos quando a imagem de Monrovia é computada com imagens de todas as outras cidades consideradas, destacando o menor valor em NC. Fonte: Autor dessa dissertação

Na Tabela 12, são mostrados os cinco menores valores de tNM na abordagem AE, e o menor valor, 0,062, obtido entre as imagens de Matola e Camberra, dos Continentes Africano e Australiano, respectivamente. Nota-se que o tNM entre essas duas imagens de cidades na abordagem NC foi de 0,802, não tão baixa quanto em AE. As imagens dessas duas cidades são mostradas nas Figs. 49 (a) e (b), respectivamente.

Tabela 12: Cinco menores valores de tNM obtidos para a abordagem AE.

Cidade	Cidade	tNM
Cuiaba	Camberra	0.154
Astana	Camberra	0.129
Catmandu	Camberra	0.126
Abobo	Camberra	0.125
Matola	Camberra	0.062



Matola



Camberra

Figura 49: Imagens de cidades: (a) Matola, (b) Camberra, com menores valores de tNM na abordagem AE. Fonte: Autor dessa dissertação

Na Fig.50, é mostrado o gráfico cartesiano de tNM entre as imagens de Matola e todas as outras cidades consideradas, destacando o menor valor em AE. Nota-se que quase todos os valores de tNM em NC superaram os valores em AE, significando os tons de cinza entre as imagens foram semelhantes, porém a textura da imagem de Matola é mais diferente das demais cidades.

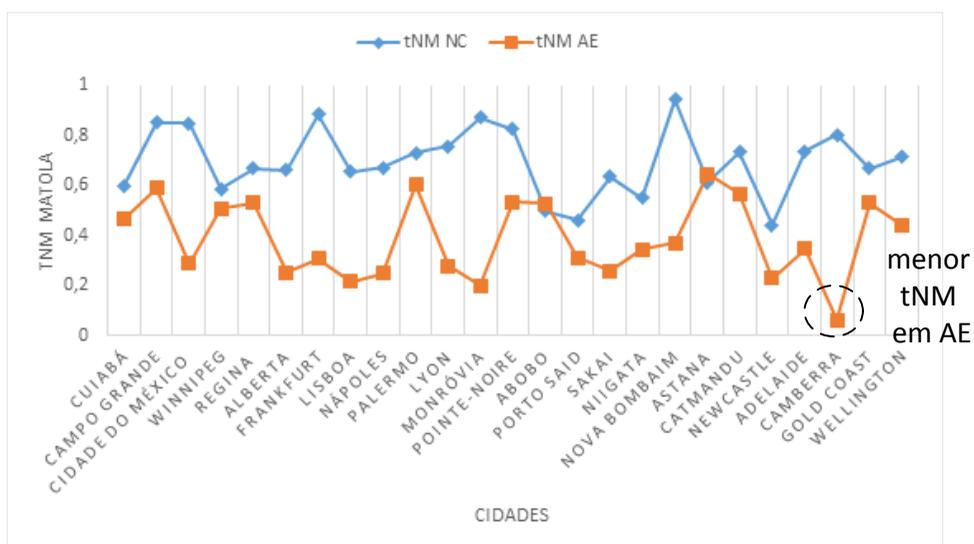


Figura 50: Valores de tNM para NC e AE, obtidas comparando a imagem de Matola com demais imagens de cidades consideradas, destacando o menor valor de tNM na abordagem AE. Fonte: Autor dessa dissertação

4.8.2 Comparação Entre as Duas Abordagens

Para a comparação entre as duas abordagens *NC* e *AE*, foram desenvolvidos gráficos ilustrativos em que os valores de *tNM* nas duas abordagens são comparados. A Fig.51 mostra um desses gráficos, que corresponde aos valores de *tNM* da cidade de Cuiabá versus demais cidades, conforme Tabela 13 (a) para *NC*, e Tabela 13(b) para *AE*.

Nota-se que apesar dos valores de *tNM* não coincidirem, os comportamentos dos valores são semelhantes, se situando na faixa entre os valores 0,5 a 0,9. No caso da cidade de Camberra, por exemplo, houve uma diferença maior entre as duas abordagens.

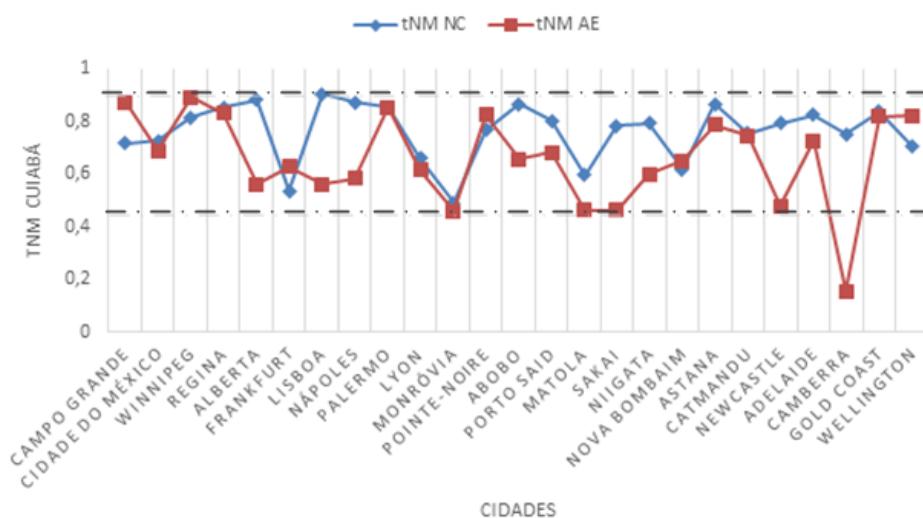


Figura 51: Gráfico comparativo das abordagens NC e AE, para os valores de tNM obtidas para a cidade de Cuiabá versus demais cidades. Fonte: Autor dessa dissertação.

Nota-se também que os valores de tNM na abordagem *AE* são na maioria menores que os valores de tNM na abordagem *NC*, sendo o valor médio de tNM para *AE* de 0,65, e para *NC*, de 0,76. A comparação de resultados entre tNM para as abordagens *NC* e *AE*, no entanto, deve levar em consideração que dependendo do fator de tolerância usado, o valor de tNM varia.

Considerando-se que os valores de tNM obtidos nas duas abordagens, serem compatíveis com os pares de imagens em questão é possível concluir que os respectivos algoritmos são corretos, o que valida o desenvolvimento. No Apêndice C são mostrados os gráficos comparativos para *NC* e *AE*, para todas as cidades consideradas nesta dissertação.

Tabela 13: Valores de tNM em ordem decrescente na abordagem NC de Cuiabá versus demais cidades, e o valor médio.

Lisboa	0,903
Edmonton	0,882
Nápoles	0,873
Abobo	0,867
Astana	0,865
Palermo	0,855
Regina	0,854
Gold Coast	0,839
Adelaide	0,826
Winnipeg	0,814
Porto Said	0,804
Niigata	0,792
Newcastle	0,792

Sakai	0,784
Pointe-Noire	0,767
Catmandu	0,755
Camberra	0,752
Cidade do México	0,726
Campo Grande	0,718
Wellington	0,708
Lyon	0,659
Nova Bombaim	0,62
Matola	0,597
Frankfurt	0,537
Monróvia	0,493

Valor médio de tNM = 0,760

Tabela 14: Valores de tNM em ordem decrescente na abordagem AE de Cuiabá versus demais cidades, e o valor médio.

Winnipeg	0,890
Campo Grande	0,873
Palermo	0,852
Regina	0,831
Pointe-Noire	0,825
Wellington	0,821
Gold Coast	0,817
Astana	0,788
Catmandu	0,746
Adelaide	0,726
Porto Said	0,681
Cidade do México	0,687
Abobo	0,656

Nova Bombaim	0,650
Frankfurt	0,628
Lyon	0,615
Niigata	0,600
Nápoles	0,585
Lisboa	0,562
Edmonton	0,561
Newcastle	0,478
Matola	0,464
Sakai	0,464
Monróvia	0,461
Camberra	0,154

Valor médio de tNM = 0,65

4.8.3 Média de Valores de tNM entre Continentes

Na Tabela 14, ilustra-se os valores médios e desvio padrão de tNM calculados entre cidades de um mesmo continente, em negrito, e entre cidades de continentes diferentes, na abordagem NC. Pode se notar que a média entre diferentes continentes foi próximo a 0,700, como mostrado na última linha, de *média*², onde o valor correspondente é uma média dos valores da coluna, excluindo o valor médio de tNM do mesmo continente, mostrado na diagonal. O valor médio de tNM no mesmo continente está acima do valor médio entre diferentes continentes, somente para o Continente Americano, com o valor médio de 0,808, mostrando que em outros continentes os tipos de cidades são diversificados quanto ao nível de cinza.

Tabela 15: Média de tNM entre continentes, em abordagem NC.

Continentes	Americano	Europeu	Africano	Asiático	Australiano
Americano	0.808 ± 0.082	0.788 ± 0.188	0.719 ± 0.128	0.763 ± 0.089	0.777 ± 0.090
Europeu	0.788 ± 0.188	0.706 ± 0.169	0.704 ± 0.141	0.754 ± 0.108	0.748 ± 0.138
Africano	0.719 ± 0.128	0.704 ± 0.141	0.509 ± 0.177	0.682 ± 0.135	0.696 ± 0.141
Asiático	0.763 ± 0.089	0.754 ± 0.108	0.682 ± 0.135	0.652 ± 0.129	0.726 ± 0.113
Australiano	0.777 ± 0.090	0.748 ± 0.138	0.696 ± 0.141	0.726 ± 0.113	0.594 ± 0.215
média ²	0.761 ± 0.123	0.748 ± 0.143	0.700 ± 0.136	0.731 ± 0.111	0.736 ± 0.120

Fonte: Autor dessa dissertação

A Tabela 15 corresponde à média e desvio padrão de tNM entre cidades de mesmo continente, em negrito, e entre diferentes continentes, em abordagem AE. Pode-se notar que a média entre diferentes continentes, foi próximo de 0,600, como mostra a última linha, *média*². Nesta abordagem, o valor médio de tNM do mesmo continente foi acima da média entre diferentes continentes, na maioria dos casos, com exceção do Continente Africano, em que o tNM médio foi de 0,630.

Tabela 16: *tNM* médio entre continentes em abordagem AE.

Continentes	Americano	Europeu	Africano	Asiático	Australiano
Americano	0.729 ± 0.134	0.693 ± 0.142	0.622 ± 0.179	0.648 ± 0.125	0.642 ± 0.222
Europeu	0.693 ± 0.142	0.752 ± 0.120	0.600 ± 0.219	0.624 ± 0.161	0.644 ± 0.167
Africano	0.622 ± 0.179	0.600 ± 0.219	0.630 ± 0.197	0.612 ± 0.161	0.569 ± 0.237
Asiático	0.648 ± 0.125	0.624 ± 0.161	0.612 ± 0.161	0.728 ± 0.096	0.613 ± 0.219
Australiano	0.642 ± 0.222	0.644 ± 0.167	0.569 ± 0.237	0.613 ± 0.219	0.748 ± 0.090
média ²	0.651 ± 0.167	0.640 ± 0.172	0.600 ± 0.199	0.624 ± 0.166	0.617 ± 0.211

Fonte: Autor dessa dissertação

4.9 Discussões

Os resultados foram discutidos à medida que foram sendo apresentados, os experimentos. Os valores dos resultados obtidos nos mostram que é viável a aplicação do cálculo do *tNM* em abordagem *NC* e *AE*.

Um fato interessante que foi possível observar é que, em determinados casos, não é possível observar o nível de similaridade entre as imagens, visualmente; porém o valor de *tNM* demonstra a existência de similaridade.

Quando se trata do cálculo do *tNM* em relação às características estatísticas observamos que quando o *tNM* indica que os pares de imagens são similares pelos atributos de textura, os mesmos são similares visualmente, em todos os experimentos praticamente.

Na abordagem *NC*, a iluminação na imagem pode alterar as classificações, o que sugere que o uso de equalização de histograma para níveis de cinza possa melhorar o resultado de *tNM*.

Os atributos estatísticos utilizados como funções de prova foram: contraste, energia, entropia e uniformidade, porém, outros atributos poderiam ser usados.

4.10 Considerações Finais

No capítulo 4 foram descritos experimentos e os resultados. Foram também apresentadas as discussões acerca desses resultados, com a intenção de validar o trabalho desenvolvido.

Capítulo 5

Conclusões e Propostas de Trabalhos Futuros

Neste capítulo apresentamos as conclusões finais, contribuições e trabalhos futuros.

5.1 Conclusões

Este trabalho de mestrado considerou a aplicação da teoria *NS* com tolerância, *TNS*, principalmente no uso da medida de similaridade *tNM*. A forma de aplicação de *TNS* e *tNM* é bastante aberta, ficando ao desenvolvedor a incumbência de escolha dos atributos para verificar se dois conjuntos são próximos.

O trabalho desenvolvido foi focado em verificação de similaridades em pares de imagens, usando *tNM*, e os atributos escolhidos como funções de prova foram os níveis de cinza e funções estatísticas sobre a distribuição de níveis de cinza dos pixels nas imagens. Com isso foram definidas duas abordagens: (1) a abordagem *NC* referente ao uso direto dos níveis de cinza como funções de prova, e a (2) abordagem *AE*, que considera os atributos estatísticos sobre a distribuição dos pixels na imagem. Ao longo do trabalho ambas as abordagens foram exploradas e os resultados foram comparados.

Os resultados de valores de *tNM* dependem, no entanto, do fator de tolerância, na verificação de similaridade, portanto, a comparação dos valores de *tNM* em relação às duas abordagens, deve levar isso em consideração.

Um outro fator que deve ser levado em conta são as próprias imagens. Como no *TNS*, as comparações entre imagens são feitas com o uso de atributos, a escolha das imagens influencia no resultado. Por exemplo, na comparação entre duas imagens de cidades, a escolha da região central das cidades foi feita manualmente. Se uma outra pessoa tivesse feito a escolha da região central, o resultado deveria ser diferente, pois existiria uma diferença de posicionamento da região central na escolha, mesmo que pequena.

Os fatos descritos indicam que o trabalho desenvolvido deve ser visto como uma ferramenta que apresenta também uma tolerância em relação aos resultados, em função dos fatores como fator de tolerância usada no *TNS*, e em função da escolha das imagens.

Um outro fator que deve ser considerado é que o cálculo de *tNM* é baseado em classes que se diferenciam em níveis de cinza ou classes de subimagens que se diferenciam em atributos estatísticos, porém é levado em consideração apenas a existência de elementos nessas classes em ambas as imagens sendo comparadas, sem levar em consideração o posicionamento desses elementos. Isso pode resultar em duas imagens incluindo objetos totalmente diferentes, serem consideradas similares.

A comparação dos resultados obtidos com outros trabalhos, na comparação de cidades ao redor do mundo, encontrados na literatura, não foi realizada nesta dissertação, o que pode ser sugerido como continuidade.

5.2 Principais Contribuições

As principais contribuições do presente trabalho de dissertação são:

- Desenvolvimento de um método automático para comparar imagens a partir de níveis de cinza dos pixels, usando o conceito de *TNS* e *tNM*.
- Desenvolvimento de um método automático para comparar imagens a partir de atributos estatísticos sobre a distribuição dos níveis de cinza de pixels, no conceito de *TNS* e *tNM*.
- Desenvolvimento de um método de comparação de centros urbanos, por imagens de satélites, usando as duas abordagens de obtenção de *tNM*.

5.3 Trabalhos Futuros

Como descrito, os resultados de obtenção de *tNM* dependem do fator de tolerância usado. Como a comparação entre as imagens dos centros urbanos foi desenvolvida usando um certo valor de tolerância, 0,1 para *AE* e nenhuma tolerância para *NC*, tamanho das imagens de 256x256, e tamanho de

subimagens de 8x8 para *AE*, outros processamentos poderiam ser feitos como trabalhos futuros usando outros parâmetros, comparando os resultados.

Um outro trabalho futuro seria desenvolver comparações dos resultados obtidos a partir do uso de *tNM* de classificação de cidades com os resultados de classificação usando outros métodos, descritos na literatura.

O uso de outros atributos estatísticos como funções de prova também pode ser um tema de trabalho futuro.

Outras funções de prova, que não sejam níveis de cinza nem atributos estatísticos, incluindo funções que consideram a forma dos objetos nas imagens, também podem ser exploradas como trabalhos futuros.

É possível encontrar diversos algoritmos que tratam de textura, contudo não foi encontrado nenhum trabalho que utilizasse destes recursos, para o cálculo do nível de similaridade entre imagens. Assim alguns possíveis trabalhos futuros são elencados a seguir:

- Utilização dos princípios de textura para implementação de um código para recuperação de imagens baseada em conteúdos fazendo uso desses princípios.
- Como o código se mostrou aceitável para reconhecimento de cidades a partir de imagens, explorar essa vertente.
- Identificação e classificação de fungos em folhas visto que o método proposto tem a propriedade de extrair características de textura da imagem, sendo possível identificar as que relacionam certos fungos.

5.4 Considerações Finais

Este capítulo abordou a conclusão, elencou as principais contribuições bem como os possíveis trabalhos futuros que podem ser desenvolvidos.

Referências

Ankita, J., Gakare, Singh, K. R., Peters, J. F. (2016) - Wavelet-Based Tolerance Near Set Approach in Classifying Hand Images: A Review. IEEE Sponsored World Conference on Futuristic Trends in Research and Innovation for Social Welfare (WCFTR'16).

Artero, A. O. (2009) - Inteligência Artificial: Teoria e Prática. 1ª ed. São Paulo: Livraria da Física.

Baraldi, A. & Parmiggiani, F. (1995) - An investigation of the textural characteristics associated with gray level co-occurrence matrix statistical parameters. Geoscience and Remote Sensing, IEEE Transactions on, v. 33, n. 2, pp. 293–304.

Domingues, G. S. Silva, F. N. Comin, C. H.; Costa, L. F. (2018) -. Topological characterization of world cities, Journal of Statistical Mechanics: Theory and Experiment, 083212, pp. 1- 18.

Google Maps (2018) - Serviço de pesquisa e visualização de mapas e imagens de satélite da terra gratuito na web. Disponível em: <<https://www.google.com/maps/>>. Acesso em 01 de novembro de 2018.

Hall-Beyer, M. (2005) - GLCM Texture: A Tutorial. Versão 3.0.

Haralick, R., Shanmugam, K., Dinstein, I. (1973) - Textural features for image classification. Systems, Man and Cybernetics, IEEE Transactions on, SMC-3, n. 6, p. 610–621.

Henry, C. J. (2010) - Near Sets: Theory and applications. University of Manitoba, Canada.

Eakins, J. & Graham, M. (2019) – Revisão do estado arte sobre Recuperação de imagens baseado em conteúdo (CBIR). <<http://www.leeds.ac.uk/educol/documents/00001240.htm>>. Acesso em 03 de Janeiro de 2019

Nicoletti, M. C. & Hruschka, E. R. Jr. (2006) - Fundamentos da Teoria dos Grafos Para Computação. São Carlos-SP, EDUFSCar.

OpenStreetMap (2018) - Mapa do mundo criado por qualquer pessoa de uso livre sob uma licença aberta. Disponível em: <<https://www.openstreetmap.org/>>. Acesso em 25 de outubro de 2018.

PAVEL, M. (1993) - Fundamentals of Pattern Recognition. New York: Marcel Dekker, Inc.

Pawlak, Z. & Peters, J. (2007) - Systemy Wspomagania Decyzji I, v. 57.

Pawlak, Z. (1981). Classification of objects by means of attributes. Institute for Computer Science. Polish Academy of Sciences. Tech. Rep. PAS 429.

Peters, J. F. (2007) - Near Sets. General theory about nearness of objects, Applied Mathematical Sciences. v. 1 n. 53, p. 2609–2029.

Peters, J. F. & Wasilewski, P. (2009) - Foundations of near sets. Elsevier Science, vol. 179, no. 18, pp. 3091–3109.

Ramanna, S. & Chitcharoen, D. (2013) – Flow Graphs: Analysis with Near Sets, Mathematics in Computer Science, Volo. 7, pp. 11-29.

Russel, S. & Norvig, P. (2004) - Inteligência Artificial. 2ª ed. Rio de Janeiro-RJ: Elsevier.

Singh, K. R., Khedgaonkar, R. S., Gawande, S. P. (2011) - A New Approach to Local Plastic Surgery Face Recognition Using Near Sets, International Journal of Engineering Science and Technology (IJEST), NCICT Special issue, pp. 71 - 75.

Theodoridis, S. & Koutroumbas, K. (2003) - Pattern Recognition, 2th edition. USA: Elsevier.

Wallpapers Craft (2018) - Desktop wallpapers, hd backgrounds. Disponível em: <<https://www.openstreetmap.org/>>. Acesso em 07 de novembro de 2018.

Wolski, M. (2010) – Perception and classification. A note on near sets and rough sets, Fundamenta Informaticae, Vol.101, pp.143-155.

Apêndice A

Imagens de Cidades

Utilizadas

A seguir são apresentadas as imagens utilizadas para os experimentos de classificação de cidades, tanto para AE quanto NC.

A1 - Cidades do Continente Americano



Campo Grande – Brasil



Cidade do México - México



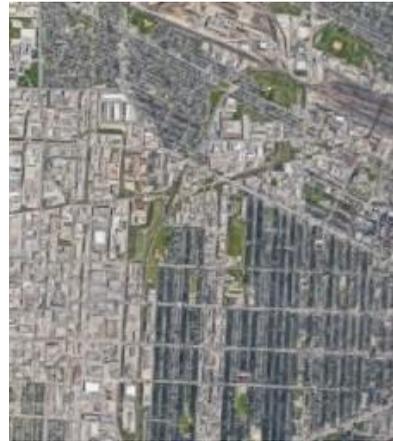
Cuiabá – Brasil



Edmonton – Alberta -
Canadá



Regina – Saskatchewan -
Canadá

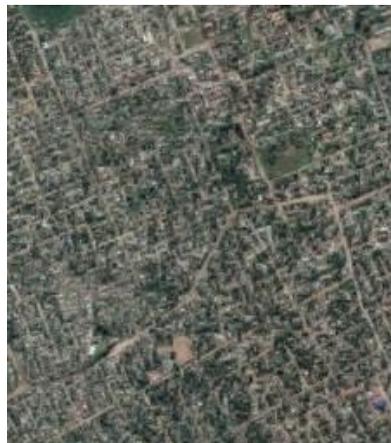


Winnipeg – Manitoba –
Canadá

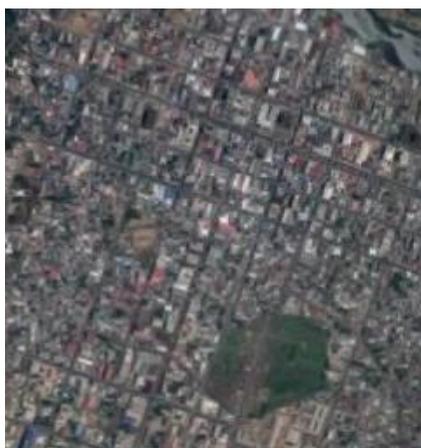
A2 – Cidades do Continente Africano



Abobo – Costa do Marfim



Matola – Moçambique



Monróvia - Libéria

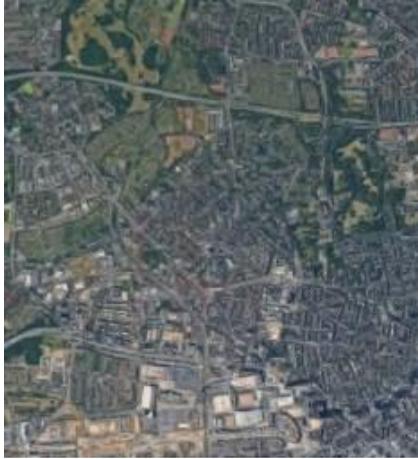


Pointe Noire – República do
Congo



Porto Said - Egito

A3 – Cidades do Continente Europeu



Frankfurt - Alemanha



Lisboa - Portugal



Lyon - França

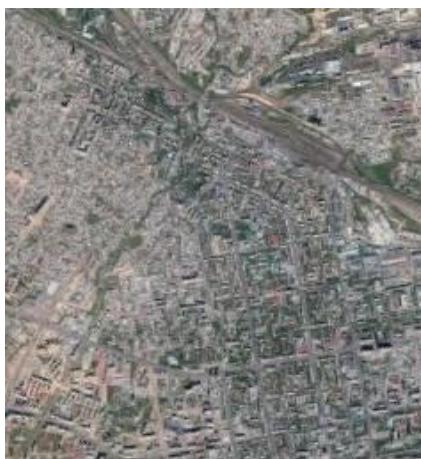


Nápoles - Itália



Palermo - Itália

A4 – Cidades do Continente Asiático



Astana - Cazaquistão



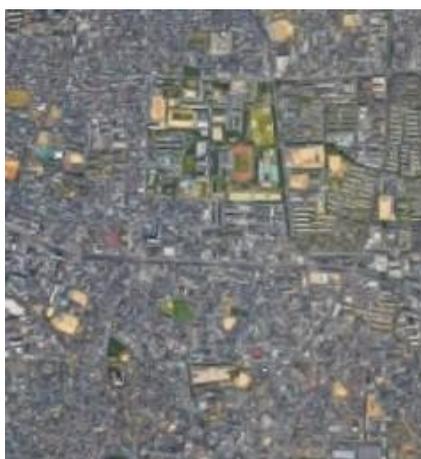
Catmandu – Nepal



Niigata – Japão



Nova Bombaim



Sakai - Japão

A5 – Cidades do Continente Oceânico



Adelaide – South Australia



Canberra – Capital da Austrália



Gold Coast - Queensland



New Castle – New South Wales



Wellington – Nova Zelândia

Apêndice B

Resultados de cálculo de tNM entre as cidades

A seguir são apresentadas as listagens dos resultados do cálculo de tNM para *NC* e *AE*, seguindo a ordem decrescente pelos valores de tNM, em que uma cidade das 26 cidades é utilizada para o cálculo com as outras 25 cidades iterativamente.

B1 - Valores de tNM em abordagem NC

(1/10)

Cidade	Cidade	tNM
Regina - Saskatchewan	Pointe-Noire	0,936
Regina - Saskatchewan	Gold Coast	0,936
Lisboa	Nápoles	0,936
Pointe-Noire	Gold Coast	0,927
Nápoles	Lyon	0,922
Edmonton - Alberta	Nápoles	0,918
Campo Grande-MT	Palermo	0,914
Monróvia	Newcastle	0,911
Manitoba - Winnipeg	Gold Coast	0,911
Manitoba - Winnipeg	Regina - Saskatchewan	0,902
Sakai	Newcastle	0,902
Manitoba - Winnipeg	Pointe-Noire	0,896

(cont.)

(2/10)

Cidade	Cidade	tNM
Frankfurt	Adelaide	0,893
Cuiabá-MT	Manitoba - Winnipeg	0,89
Edmonton - Alberta	Lyon	0,886
Palermo	Astana	0,883
Lyon	Porto Said	0,88
Manitoba - Winnipeg	Wellington	0,878
Edmonton - Alberta	Lisboa	0,877
Campo Grande-MT	Astana	0,877
Abobo	Catmandu	0,874
Cuiabá-MT	Campo Grande-MT	0,873
Manitoba - Winnipeg	Palermo	0,871
Frankfurt	Niigata	0,869
Cidade do México	Porto Said	0,867
Nápoles	Sakai	0,866
Gold Coast	Wellington	0,863
Palermo	Pointe-Noire	0,862
Porto Said	Adelaide	0,861
Campo Grande-MT	Manitoba - Winnipeg	0,859
Regina - Saskatchewan	Palermo	0,857
Nápoles	Porto Said	0,856
Pointe-Noire	Wellington	0,852
Cuiabá-MT	Palermo	0,852
Palermo	Gold Coast	0,851

(cont.)

(3/10)

Cidade	Cidade	tNM
Regina - Saskatchewan	Catmandu	0,851
Cidade do México	Adelaide	0,851
Catmandu	Gold Coast	0,846
Frankfurt	Lyon	0,843
Cidade do México	Nápoles	0,842
Cidade do México	Lyon	0,842
Edmonton - Alberta	Porto Said	0,837
Frankfurt	Newcastle	0,835
Edmonton - Alberta	Frankfurt	0,833
Edmonton - Alberta	Monróvia	0,833
Cuiabá-MT	Regina - Saskatchewan	0,831
Regina - Saskatchewan	Wellington	0,829
Cidade do México	Lisboa	0,828
Lisboa	Lyon	0,828
Monróvia	Sakai	0,826
Cidade do México	Edmonton - Alberta	0,825
Cuiabá-MT	Pointe-Noire	0,825
Niigata	Adelaide	0,825
Frankfurt	Porto Said	0,824
Lyon	Adelaide	0,823
Cuiabá-MT	Wellington	0,821
Frankfurt	Monróvia	0,821
Frankfurt	Nova Bombaim	0,82
Frankfurt	Sakai	0,819
Cuiabá-MT	Gold Coast	0,817
Edmonton - Alberta	Newcastle	0,816
Pointe-Noire	Catmandu	0,811
Palermo	Wellington	0,81
Sakai	Niigata	0,809
Campo Grande-MT	Pointe-Noire	0,807
Regina - Saskatchewan	Adelaide	0,806
Palermo	Catmandu	0,805
Lisboa	Porto Said	0,803
Pointe-Noire	Adelaide	0,802
Adelaide	Gold Coast	0,798
Cuiabá-MT	Astana	0,788
Campo Grande-MT	Gold Coast	0,799
Nova Bombaim	Adelaide	0,798

(cont.)

(4/10)

Cidade	cidade	tNM
Campo Grande-MT	Regina - Saskatchewan	0,797
Adelaide	Wellington	0,792
Manitoba - Winnipeg	Catmandu	0,791
Campo Grande-MT	Wellington	0,784
Manitoba - Winnipeg	Astana	0,782
Lyon	Newcastle	0,78
Lyon	Monróvia	0,779
Astana	Catmandu	0,777
Nova Bombaim	Wellington	0,772
Niigata	Newcastle	0,767
Edmonton - Alberta	Adelaide	0,765
Lyon	Niigata	0,765
Nápoles	Monróvia	0,763
Astana	Gold Coast	0,762
Regina - Saskatchewan	Abobo	0,76
Newcastle	Adelaide	0,753
Porto Said	Wellington	0,753
Regina - Saskatchewan	Nova Bombaim	0,751
Manitoba - Winnipeg	Adelaide	0,748
Frankfurt	Wellington	0,748
Cuiabá-MT	Catmandu	0,746
Porto Said	Nova Bombaim	0,743
Nápoles	Newcastle	0,742
Pointe-Noire	Astana	0,742
Sakai	Adelaide	0,742
Lyon	Sakai	0,741
Pointe-Noire	Nova Bombaim	0,741
Sakai	Nova Bombaim	0,74
Campo Grande-MT	Catmandu	0,74
Niigata	Nova Bombaim	0,74
Regina - Saskatchewan	Astana	0,739
Nova Bombaim	Gold Coast	0,739
Palermo	Abobo	0,734
Cidade do México	Wellington	0,734
Regina - Saskatchewan	Niigata	0,733
Niigata	Gold Coast	0,731
Frankfurt	Nápoles	0,73
Regina - Saskatchewan	Porto Said	0,727

(cont.)

(5/10)

Cidade	Cidade	tNM
Catmandu	Adelaide	0,727
Pointe-Noire	Porto Said	0,726
Cuiabá-MT	Adelaide	0,726
Monróvia	Porto Said	0,724
Nova Bombaim	Newcastle	0,722
Frankfurt	Pointe-Noire	0,72
Edmonton - Alberta	Nova Bombaim	0,719
Porto Said	Niigata	0,719
Edmonton - Alberta	Sakai	0,718
Niigata	Catmandu	0,715
Lyon	Nova Bombaim	0,715
Porto Said	Gold Coast	0,713
Nápoles	Adelaide	0,712
Edmonton - Alberta	Niigata	0,712
Porto Said	Newcastle	0,712
Manitoba - Winnipeg	Nova Bombaim	0,71
Porto Said	Sakai	0,708
Monróvia	Niigata	0,707
Monróvia	Nova Bombaim	0,707
Astana	Wellington	0,704
Cidade do México	Frankfurt	0,704
Cidade do México	Manitoba - Winnipeg	0,703
Frankfurt	Gold Coast	0,702
Monróvia	Adelaide	0,699
Pointe-Noire	Niigata	0,697
Pointe-Noire	Abobo	0,691
Lisboa	Monróvia	0,69
Palermo	Adelaide	0,688
Cuiabá-MT	Cidade do México	0,687
Cidade do México	Pointe-Noire	0,687
Catmandu	Wellington	0,687
Nova Bombaim	Catmandu	0,682
Cuiabá-MT	Porto Said	0,681
Lyon	Wellington	0,68
Cidade do México	Gold Coast	0,676
Monróvia	Camberra	0,676
Abobo	Gold Coast	0,675

(cont.)

(6/10)

Cidade	Cidade	tNM
Manitoba - Winnipeg	Niigata	0,674
Abobo	Niigata	0,673
Manitoba - Winnipeg	Frankfurt	0,672
Regina - Saskatchewan	Lyon	0,667
Lisboa	Adelaide	0,666
Lyon	Pointe-Noire	0,66
Cidade do México	Regina - Saskatchewan	0,66
Edmonton - Alberta	Wellington	0,659
Cuiabá-MT	Abobo	0,656
Lisboa	Newcastle	0,655
Cidade do México	Monróvia	0,651
Niigata	Wellington	0,65
Cuiabá-MT	Nova Bombaim	0,65
Manitoba - Winnipeg	Abobo	0,649
Manitoba - Winnipeg	Porto Said	0,649
Campo Grande-MT	Adelaide	0,648
Regina - Saskatchewan	Edmonton - Alberta	0,647
Matola	Astana	0,646
Nápoles	Nova Bombaim	0,644
Nápoles	Wellington	0,64
Lyon	Gold Coast	0,637
Palermo	Nova Bombaim	0,636
Regina - Saskatchewan	Frankfurt	0,63
Manitoba - Winnipeg	Lyon	0,63
Frankfurt	Lisboa	0,629
Cuiabá-MT	Frankfurt	0,628
Nápoles	Niigata	0,626
Cidade do México	Newcastle	0,626
Lisboa	Wellington	0,625
Regina - Saskatchewan	Nápoles	0,625
Palermo	Porto Said	0,625
Campo Grande-MT	Porto Said	0,622
Campo Grande-MT	Cidade do México	0,621
Frankfurt	Palermo	0,621
Newcastle	Wellington	0,618
Cidade do México	Palermo	0,618
Frankfurt	Catmandu	0,615
Cuiabá-MT	Lyon	0,615

(cont.)

(7/10)

Cidade	cidade	tNM
Campo Grande-MT	Abobo	0,613
Edmonton - Alberta	Gold Coast	0,61
Edmonton - Alberta	Pointe-Noire	0,609
Cidade do México	Nova Bombaim	0,608
Palermo	Matola	0,603
Edmonton - Alberta	Camberra	0,602
Campo Grande-MT	Nova Bombaim	0,601
Cuiabá-MT	Niigata	0,6
Cidade do México	Niigata	0,6
Monróvia	Wellington	0,6
Nápoles	Pointe-Noire	0,599
Abobo	Nova Bombaim	0,593
Campo Grande-MT	Matola	0,591
Regina - Saskatchewan	Sakai	0,591
Regina - Saskatchewan	Lisboa	0,591
Astana	Adelaide	0,59
Manitoba - Winnipeg	Edmonton - Alberta	0,586
Abobo	Astana	0,585
Cuiabá-MT	Nápoles	0,585
Regina - Saskatchewan	Newcastle	0,585
Palermo	Niigata	0,584
Newcastle	Gold Coast	0,583
Abobo	Adelaide	0,581
Sakai	Wellington	0,576
Porto Said	Catmandu	0,574
Manitoba - Winnipeg	Nápoles	0,572
Pointe-Noire	Sakai	0,571
Lisboa	Pointe-Noire	0,57
Newcastle	Camberra	0,568
Matola	Catmandu	0,568
Cuiabá-MT	Lisboa	0,562
Frankfurt	Abobo	0,562
Cuiabá-MT	Edmonton - Alberta	0,561
Lisboa	Sakai	0,561
Nápoles	Gold Coast	0,56
Regina - Saskatchewan	Monróvia	0,558
Manitoba - Winnipeg	Lisboa	0,558
Catmandu	Newcastle	0,553

(cont.)

(8/10)

Cidade	Cidade	tNM
Nova Bombaim	Astana	0,553
Sakai	Gold Coast	0,552
Lisboa	Gold Coast	0,552
Pointe-Noire	Newcastle	0,552
Campo Grande-MT	Lyon	0,549
Palermo	Lyon	0,549
Niigata	Astana	0,549
Cidade do México	Sakai	0,548
Sakai	Catmandu	0,547
Campo Grande-MT	Frankfurt	0,547
Lyon	Catmandu	0,544
Lisboa	Camberra	0,541
Campo Grande-MT	Niigata	0,541
Lisboa	Nova Bombaim	0,538
Monróvia	Pointe-Noire	0,535
Pointe-Noire	Matola	0,533
Matola	Gold Coast	0,532
Regina - Saskatchewan	Matola	0,532
Monróvia	Gold Coast	0,531
Cidade do México	Astana	0,529
Abobo	Matola	0,526
Abobo	Sakai	0,526
Manitoba - Winnipeg	Sakai	0,525
Edmonton - Alberta	Palermo	0,518
Manitoba - Winnipeg	Newcastle	0,515
Edmonton - Alberta	Catmandu	0,511
Frankfurt	Astana	0,509
Campo Grande-MT	Nápoles	0,507
Manitoba - Winnipeg	Matola	0,506
Campo Grande-MT	Lisboa	0,504
Lisboa	Niigata	0,5
Nápoles	Palermo	0,499
Lisboa	Palermo	0,499
Porto Said	Astana	0,494
Cidade do México	Catmandu	0,493

(cont.)

(9/10)

Cidade	Cidade	tNM
Campo Grande-MT	Edmonton - Alberta	0,489
Manitoba - Winnipeg	Monróvia	0,487
Abobo	Wellington	0,484
Palermo	Sakai	0,479
Cuiabá-MT	Newcastle	0,478
Lyon	Abobo	0,476
Monróvia	Catmandu	0,474
Abobo	Porto Said	0,47
Cuiabá-MT	Matola	0,464
Cuiabá-MT	Sakai	0,464
Nápoles	Camberra	0,464
Palermo	Newcastle	0,464
Cuiabá-MT	Monróvia	0,461
Nápoles	Catmandu	0,458
Porto Said	Camberra	0,453
Abobo	Newcastle	0,444
Matola	Wellington	0,443
Palermo	Monróvia	0,439
Nova Bombaim	Camberra	0,438
Lyon	Astana	0,438
Lyon	Camberra	0,436
Lisboa	Astana	0,428
Edmonton - Alberta	Astana	0,43
Campo Grande-MT	Sakai	0,413
Frankfurt	Camberra	0,419
Edmonton - Alberta	Abobo	0,411
Sakai	Astana	0,41
Cidade do México	Abobo	0,407
Cidade do México	Camberra	0,406
Sakai	Camberra	0,405
Adelaide	Camberra	0,403
Nápoles	Abobo	0,4
Campo Grande-MT	Monróvia	0,397
Campo Grande-MT	Newcastle	0,396
Nápoles	Astana	0,386

(cont.)

(10/10)

Cidade	Cidade	tNM
Monróvia	Abobo	0,377
Lisboa	Catmandu	0,375
Matola	Nova Bombaim	0,368
Monróvia	Astana	0,363
Astana	Newcastle	0,363
Matola	Adelaide	0,348
Matola	Niigata	0,344
Porto Said	Matola	0,312
Camberra	Wellington	0,31
Frankfurt	Matola	0,308
Cidade do México	Matola	0,286
Lisboa	Abobo	0,286
Lyon	Matola	0,278
Manitoba - Winnipeg	Camberra	0,258
Matola	Sakai	0,257
Pointe-Noire	Camberra	0,257
Edmonton - Alberta	Matola	0,253
Regina - Saskatchewan	Camberra	0,249
Camberra	Gold Coast	0,247
Nápoles	Matola	0,247
Matola	Newcastle	0,23
Lisboa	Matola	0,215
Niigata	Camberra	0,211
Monróvia	Matola	0,198
Campo Grande-MT	Camberra	0,175
Palermo	Camberra	0,165
Cuiabá-MT	Camberra	0,154
Astana	Camberra	0,129
Catmandu	Camberra	0,126
Abobo	Camberra	0,125
Matola	Camberra	0,062

ANEXO B2 – Valores de tNM em abordagem AE

(1/9)

Cidade	Cidade	tNM
Regina - Saskatchewan	Edmonton - Alberta	0,95
Cidade do México	Pointe-Noire	0,944
Matola	Nova Bombaim	0,943
Edmonton - Alberta	Lisboa	0,942
Palermo	Adelaide	0,938
Regina - Saskatchewan	Nápoles	0,935
Frankfurt	Monróvia	0,931
Cidade do México	Camberra	0,928
Nápoles	Palermo	0,927
Edmonton - Alberta	Nápoles	0,924
Pointe-Noire	Camberra	0,924
Edmonton - Alberta	Astana	0,922
Lisboa	Gold Coast	0,921
Campo Grande-MT	Pointe-Noire	0,921
Campo Grande-MT	Cidade do México	0,921
Adelaide	Camberra	0,919
Lisboa	Astana	0,917
Manitoba - Winnipeg	Astana	0,913
Campo Grande-MT	Camberra	0,912
Nápoles	Adelaide	0,911
Porto Said	Newcastle	0,91
Catmandu	Adelaide	0,909
Catmandu	Camberra	0,909
Astana	Gold Coast	0,909
Regina - Saskatchewan	Lisboa	0,909
Lisboa	Nápoles	0,905
Cuiabá-MT	Lisboa	0,903
Pointe-Noire	Adelaide	0,902
Abobo	Porto Said	0,9
Palermo	Pointe-Noire	0,9
Lyon	Catmandu	0,899
Edmonton - Alberta	Gold Coast	0,899
Regina - Saskatchewan	Astana	0,896
Edmonton - Alberta	Palermo	0,895
Abobo	Newcastle	0,89
Sakai	Catmandu	0,885

(cont)

(2/9)

Cidade	Cidade	tNM
Regina - Saskatchewan	Palermo	0,885
Frankfurt	Nova Bombaim	0,885
Palermo	Camberra	0,885
Frankfurt	Matola	0,884
Lisboa	Palermo	0,883
Cuiabá-MT	Edmonton - Alberta	0,882
Cidade do México	Adelaide	0,877
Regina - Saskatchewan	Adelaide	0,877
Manitoba - Winnipeg	Gold Coast	0,875
Manitoba - Winnipeg	Edmonton - Alberta	0,873
Cuiabá-MT	Nápoles	0,873
Monróvia	Matola	0,872
Campo Grande-MT	Nova Bombaim	0,871
Regina - Saskatchewan	Gold Coast	0,871
Cidade do México	Nova Bombaim	0,868
Cuiabá-MT	Abobo	0,867
Sakai	Niigata	0,86
Cuiabá-MT	Astana	0,865
Manitoba - Winnipeg	Regina - Saskatchewan	0,865
Manitoba - Winnipeg	Lisboa	0,865
Lyon	Camberra	0,865
Cidade do México	Palermo	0,864
Pointe-Noire	Catmandu	0,858
Cidade do México	Catmandu	0,858
Cuiabá-MT	Palermo	0,855
Palermo	Catmandu	0,855
Monróvia	Nova Bombaim	0,854
Cuiabá-MT	Regina - Saskatchewan	0,854
Campo Grande-MT	Matola	0,851
Lisboa	Adelaide	0,848
Cidade do México	Matola	0,848
Sakai	Adelaide	0,848
Nápoles	Pointe-Noire	0,847
Campo Grande-MT	Palermo	0,846
Nápoles	Gold Coast	0,846
Pointe-Noire	Nova Bombaim	0,846

(cont)

(3/9)

Cidade	Cidade	tNM
Nápoles	Camberra	0,842
Porto Said	Astana	0,841
Cuiabá-MT	Gold Coast	0,839
Nápoles	Catmandu	0,839
Palermo	Gold Coast	0,838
Regina - Saskatchewan	Pointe-Noire	0,831
Nova Bombaim	Camberra	0,831
Abobo	Astana	0,831
Manitoba - Winnipeg	Nápoles	0,83
Campo Grande-MT	Catmandu	0,828
Edmonton - Alberta	Pointe-Noire	0,827
Cidade do México	Lyon	0,826
Cuiabá-MT	Adelaide	0,826
Nápoles	Sakai	0,826
Sakai	Camberra	0,824
Pointe-Noire	Matola	0,824
Gold Coast	Wellington	0,823
Lyon	Adelaide	0,823
Palermo	Astana	0,822
Lisboa	Pointe-Noire	0,819
Cidade do México	Nápoles	0,816
Regina - Saskatchewan	Camberra	0,815
Palermo	Sakai	0,814
Cuiabá-MT	Manitoba - Winnipeg	0,814
Lisboa	Abobo	0,81
Manitoba - Winnipeg	Porto Said	0,81
Cuiabá-MT	Porto Said	0,804
Lyon	Sakai	0,809
Campo Grande-MT	Nápoles	0,808
Campo Grande-MT	Lyon	0,808
Campo Grande-MT	Adelaide	0,806
Regina - Saskatchewan	Catmandu	0,805
Edmonton - Alberta	Camberra	0,805
Edmonton - Alberta	Abobo	0,804
Pointe-Noire	Gold Coast	0,804
Matola	Camberra	0,802
Campo Grande-MT	Regina - Saskatchewan	0,798
Lyon	Pointe-Noire	0,797

(cont)

(4/9)

Cidade	Cidade	tNM
Adelaide	Gold Coast	0,797
Astana	Newcastle	0,796
Astana	Adelaide	0,795
Regina - Saskatchewan	Sakai	0,795
Cuiabá-MT	Niigata	0,792
Cuiabá-MT	Newcastle	0,792
Edmonton - Alberta	Catmandu	0,791
Campo Grande-MT	Frankfurt	0,79
Cidade do México	Regina - Saskatchewan	0,789
Regina - Saskatchewan	Abobo	0,787
Lisboa	Porto Said	0,786
Lisboa	Camberra	0,785
Edmonton - Alberta	Porto Said	0,785
Pointe-Noire	Sakai	0,784
Cuiabá-MT	Sakai	0,784
Campo Grande-MT	Edmonton - Alberta	0,783
Cidade do México	Edmonton - Alberta	0,78
Cidade do México	Frankfurt	0,779
Campo Grande-MT	Gold Coast	0,779
Campo Grande-MT	Lisboa	0,778
Manitoba - Winnipeg	Palermo	0,778
Abobo	Gold Coast	0,777
Edmonton - Alberta	Sakai	0,777
Cidade do México	Sakai	0,776
Cidade do México	Lisboa	0,775
Manitoba - Winnipeg	Abobo	0,775
Niigata	Catmandu	0,775
Lyon	Nova Bombaim	0,774
Palermo	Lyon	0,774
Porto Said	Gold Coast	0,772
Lisboa	Wellington	0,771
Nova Bombaim	Adelaide	0,77
Pointe-Noire	Wellington	0,769
Campo Grande-MT	Wellington	0,769
Regina - Saskatchewan	Porto Said	0,769
Niigata	Adelaide	0,768
Cuiabá-MT	Pointe-Noire	0,767

(cont)

(5/9)

Cidade	Cidade	tNM
Lisboa	Newcastle	0,766
Nápoles	Abobo	0,766
Lisboa	Catmandu	0,765
Nova Bombaim	Catmandu	0,763
Nápoles	Niigata	0,764
Cidade do México	Gold Coast	0,762
Palermo	Wellington	0,76
Palermo	Niigata	0,76
Lisboa	Sakai	0,759
Lyon	Matola	0,758
Pointe-Noire	Astana	0,757
Frankfurt	Pointe-Noire	0,757
Palermo	Nova Bombaim	0,757
Newcastle	Camberra	0,757
Manitoba - Winnipeg	Adelaide	0,756
Cuiabá-MT	Catmandu	0,755
Campo Grande-MT	Sakai	0,755
Edmonton - Alberta	Newcastle	0,753
Cuiabá-MT	Camberra	0,752
Frankfurt	Camberra	0,751
Newcastle	Gold Coast	0,751
Campo Grande-MT	Monróvia	0,749
Camberra	Gold Coast	0,748
Cidade do México	Wellington	0,748
Nápoles	Lyon	0,745
Nápoles	Wellington	0,745
Manitoba - Winnipeg	Newcastle	0,744
Cidade do México	Monróvia	0,743
Edmonton - Alberta	Wellington	0,743
Palermo	Abobo	0,743
Astana	Wellington	0,741
Abobo	Niigata	0,738
Nápoles	Porto Said	0,737
Regina - Saskatchewan	Newcastle	0,737
Matola	Adelaide	0,736

(cont)

(6/9)

Cidade	Cidade	tNM
Adelaide	Wellington	0,736
Matola	Catmandu	0,735
Frankfurt	Lyon	0,734
Astana	Camberra	0,732
Palermo	Matola	0,729
Niigata	Camberra	0,729
Manitoba - Winnipeg	Wellington	0,728
Regina - Saskatchewan	Niigata	0,727
Cuiabá-MT	Cidade do México	0,726
Campo Grande-MT	Astana	0,725
Edmonton - Alberta	Niigata	0,725
Lisboa	Niigata	0,725
Manitoba - Winnipeg	Pointe-Noire	0,723
Regina - Saskatchewan	Wellington	0,723
Monróvia	Pointe-Noire	0,718
Cuiabá-MT	Campo Grande-MT	0,718
Astana	Catmandu	0,718
Regina - Saskatchewan	Lyon	0,717
Nápoles	Newcastle	0,716
Matola	Wellington	0,715
Camberra	Wellington	0,714
Sakai	Astana	0,714
Abobo	Adelaide	0,713
Catmandu	Gold Coast	0,709
Cuiabá-MT	Wellington	0,708
Cidade do México	Astana	0,708
Pointe-Noire	Niigata	0,707
Campo Grande-MT	Manitoba - Winnipeg	0,703
Edmonton - Alberta	Lyon	0,703
Nápoles	Nova Bombaim	0,702
Monróvia	Camberra	0,701
Manitoba - Winnipeg	Camberra	0,7
Regina - Saskatchewan	Nova Bombaim	0,699
Palermo	Porto Said	0,697
Nova Bombaim	Wellington	0,697

(cont)

(7/9)

Cidade	Cidade	tNM
Cidade do México	Niigata	0,692
Abobo	Sakai	0,692
Manitoba - Winnipeg	Sakai	0,69
Sakai	Gold Coast	0,689
Lyon	Niigata	0,689
Frankfurt	Catmandu	0,687
Manitoba - Winnipeg	Catmandu	0,686
Edmonton - Alberta	Adelaide	0,686
Lyon	Monróvia	0,682
Niigata	Astana	0,681
Frankfurt	Adelaide	0,681
Lisboa	Lyon	0,677
Cidade do México	Manitoba - Winnipeg	0,676
Palermo	Newcastle	0,674
Nova Bombaim	Gold Coast	0,673
Lisboa	Nova Bombaim	0,673
Nápoles	Matola	0,672
Regina - Saskatchewan	Matola	0,669
Frankfurt	Palermo	0,669
Sakai	Nova Bombaim	0,669
Matola	Gold Coast	0,667
Catmandu	Wellington	0,666
Porto Said	Niigata	0,666
Porto Said	Adelaide	0,665
Edmonton - Alberta	Matola	0,662
Cuiabá-MT	Lyon	0,659
Pointe-Noire	Abobo	0,655
Manitoba - Winnipeg	Niigata	0,654
Lisboa	Matola	0,654
Niigata	Gold Coast	0,654
Campo Grande-MT	Niigata	0,652
Abobo	Catmandu	0,652
Edmonton - Alberta	Nova Bombaim	0,648
Niigata	Newcastle	0,648
Newcastle	Adelaide	0,642
Abobo	Camberra	0,639

(cont)

(8/9)

Cidade	Cidade	tNM
Porto Said	Sakai	0,637
Sakai	Wellington	0,636
Matola	Sakai	0,634
Monróvia	Catmandu	0,634
Lyon	Gold Coast	0,633
Lyon	Astana	0,631
Nova Bombaim	Astana	0,628
Frankfurt	Wellington	0,624
Palermo	Monróvia	0,623
Monróvia	Adelaide	0,623
Cuiabá-MT	Nova Bombaim	0,62
Pointe-Noire	Porto Said	0,616
Sakai	Newcastle	0,614
Frankfurt	Nápoles	0,614
Abobo	Wellington	0,613
Monróvia	Wellington	0,612
Cidade do México	Abobo	0,611
Regina - Saskatchewan	Frankfurt	0,611
Matola	Astana	0,611
Lyon	Wellington	0,605
Manitoba - Winnipeg	Nova Bombaim	0,603
Porto Said	Wellington	0,603
Manitoba - Winnipeg	Lyon	0,602
Edmonton - Alberta	Frankfurt	0,601
Campo Grande-MT	Abobo	0,599
Frankfurt	Gold Coast	0,598
Cuiabá-MT	Matola	0,597
Newcastle	Wellington	0,597
Porto Said	Camberra	0,596
Pointe-Noire	Newcastle	0,596
Porto Said	Catmandu	0,593
Frankfurt	Lisboa	0,591
Frankfurt	Sakai	0,587
Manitoba - Winnipeg	Matola	0,585
Niigata	Wellington	0,584
Niigata	Nova Bombaim	0,582

(cont)

(9/9)

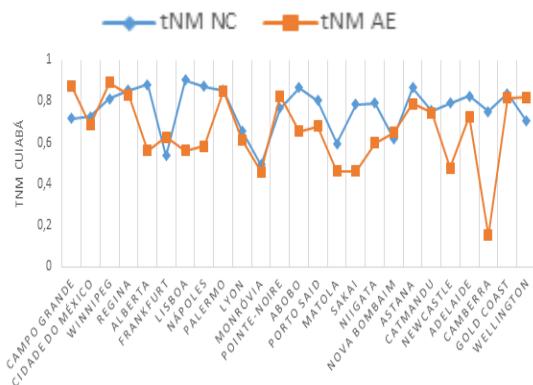
Cidade	Cidade	tNM
Campo Grande-MT	Porto Said	0,573
Catmandu	Newcastle	0,57
Cidade do México	Porto Said	0,568
Monróvia	Gold Coast	0,568
Nápoles	Monróvia	0,566
Regina - Saskatchewan	Monróvia	0,563
Campo Grande-MT	Newcastle	0,56
Edmonton - Alberta	Monróvia	0,555
Lyon	Abobo	0,553
Frankfurt	Astana	0,552
Cidade do México	Newcastle	0,551
Matola	Niigata	0,55
Lisboa	Monróvia	0,548
Cuiabá-MT	Frankfurt	0,537
Monróvia	Sakai	0,533
Manitoba - Winnipeg	Frankfurt	0,53
Abobo	Nova Bombaim	0,518
Monróvia	Astana	0,511
Manitoba - Winnipeg	Monróvia	0,5
Lyon	Porto Said	0,498
Abobo	Matola	0,498
Cuiabá-MT	Monróvia	0,493
Frankfurt	Niigata	0,493
Porto Said	Nova Bombaim	0,479
Lyon	Newcastle	0,475
Porto Said	Matola	0,46
Nova Bombaim	Newcastle	0,46
Monróvia	Niigata	0,445
Matola	Newcastle	0,442
Frankfurt	Abobo	0,437
Frankfurt	Porto Said	0,402
Monróvia	Abobo	0,396
Frankfurt	Newcastle	0,388
Monróvia	Porto Said	0,362
Monróvia	Newcastle	0,349
Campo Grande-MT	Porto Said	0,573

Apêndice C

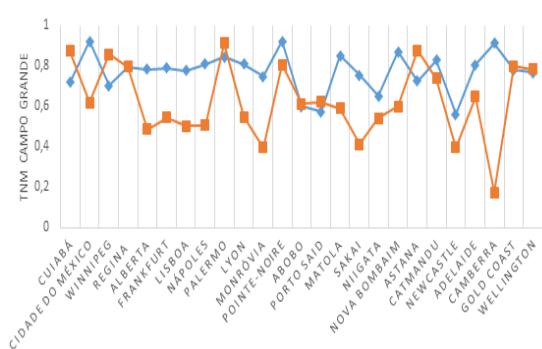
Gráficos do Cálculo de tNM

Este apêndice contém os gráficos dos valores de tNM de uma cidade comparada com as demais cidades, dispostos em anexos de C1 a C5, em que as cidades estão separadas por continentes.

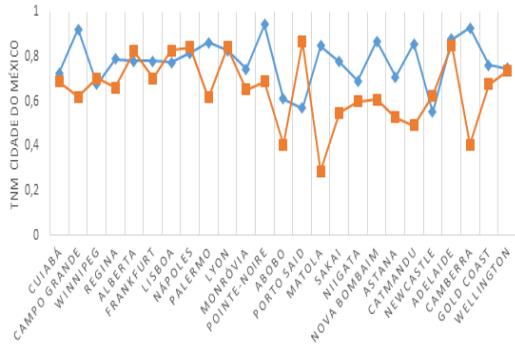
C1 – Gráfico de tNM - Cidades do Continente Americano



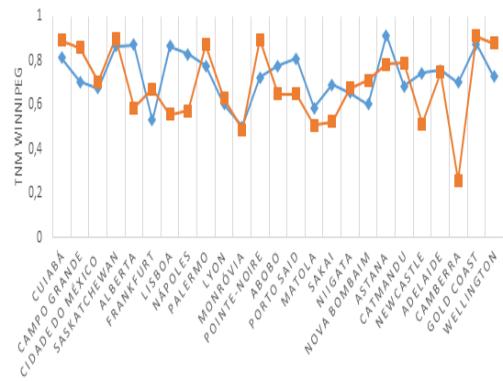
Cuiabá



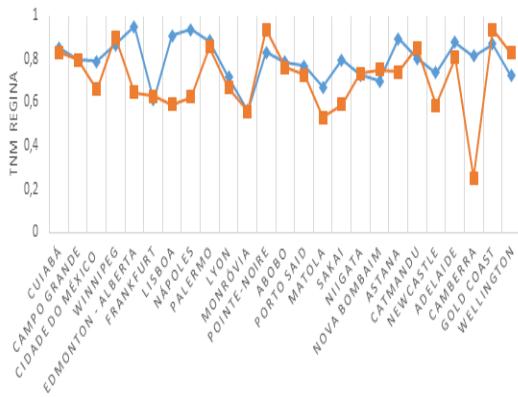
Campo Grande



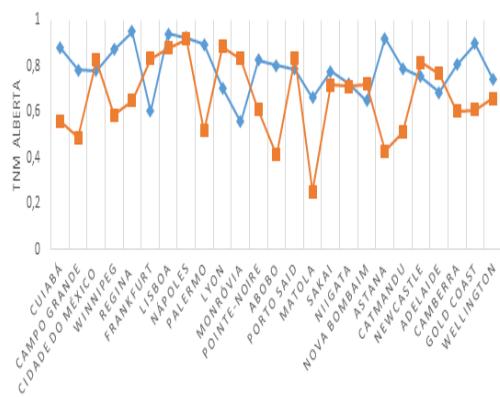
Cidade do México



Winnipeg

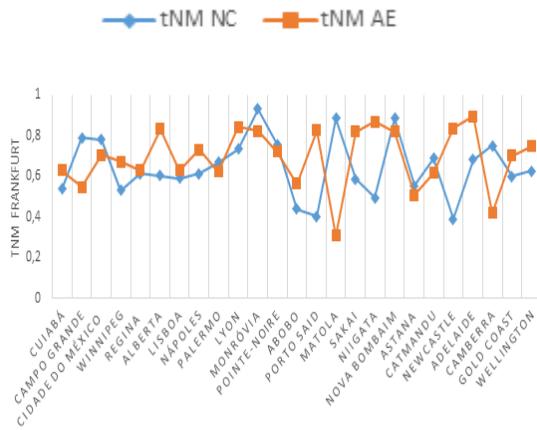


Regina

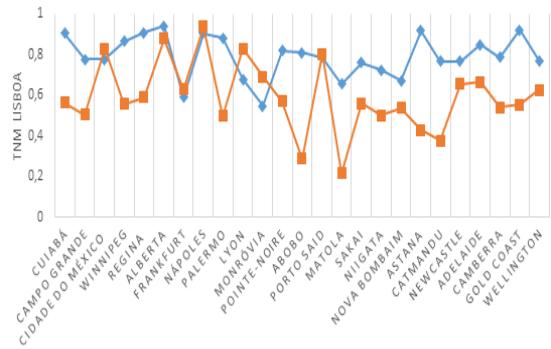


Edmonton - Alberta

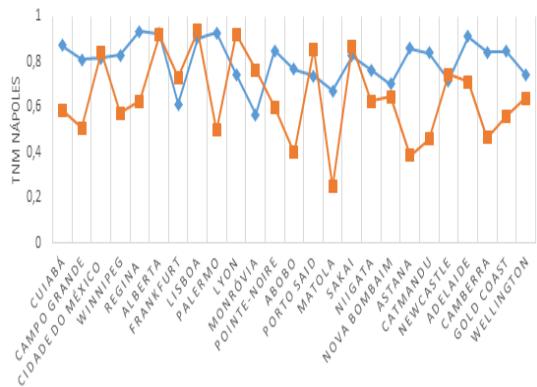
C2 – Gráfico de tNM - Cidades do Continente Europeu



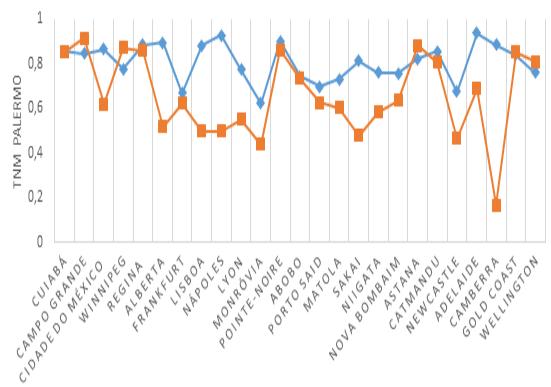
Frankfurt



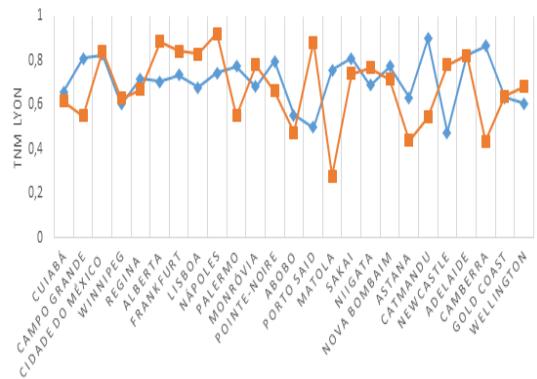
Lisboa



Nápoles

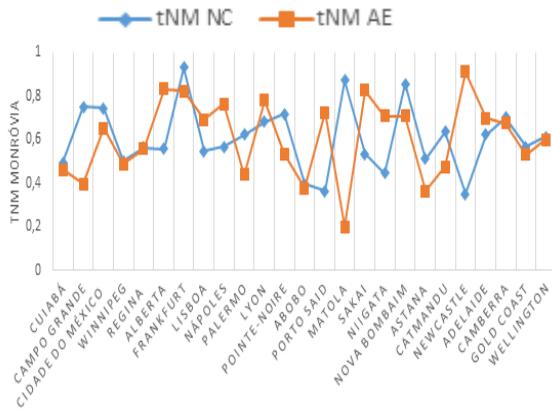


Palermo

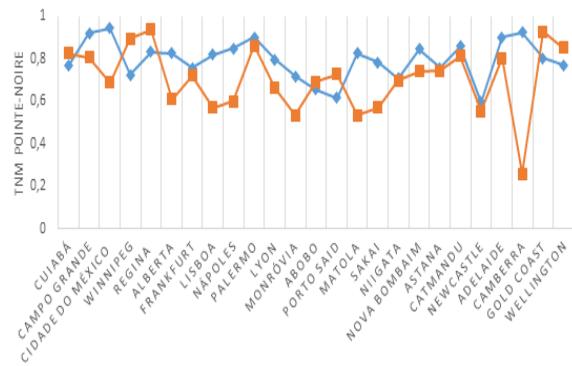


Lyon

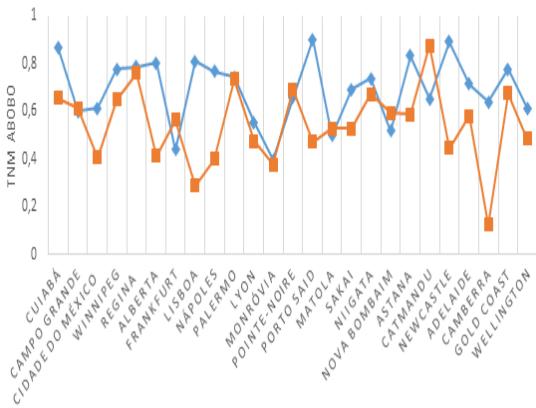
C3 – Gráfico de tNM - Cidades do Continente Africano



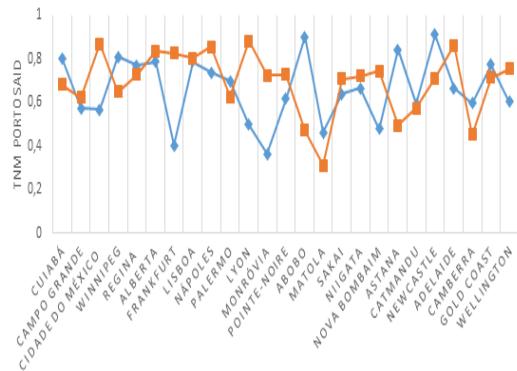
Monróvia



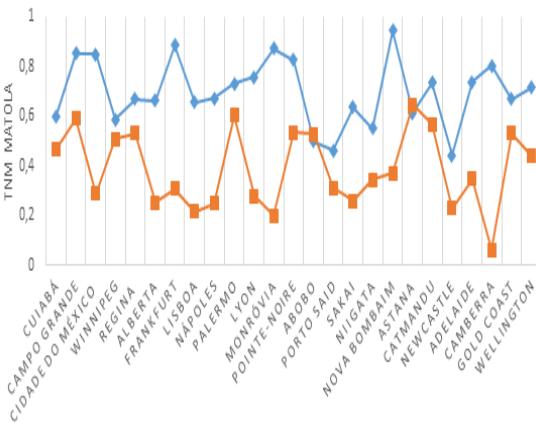
Pointe Noire



Abobo

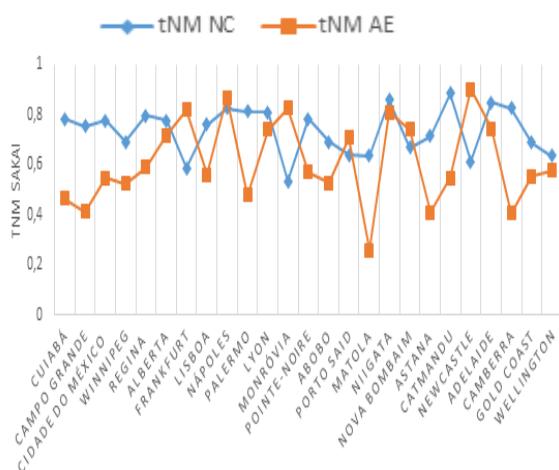


Porto Said

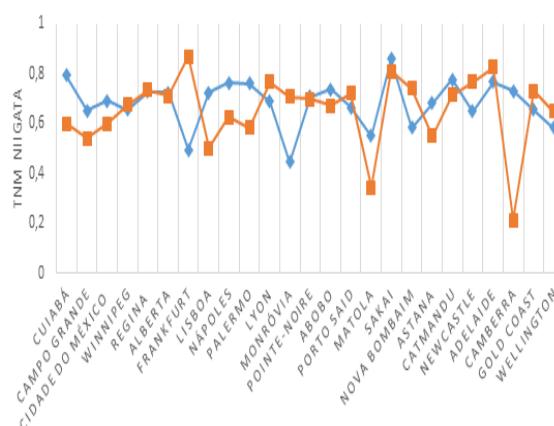


Matola

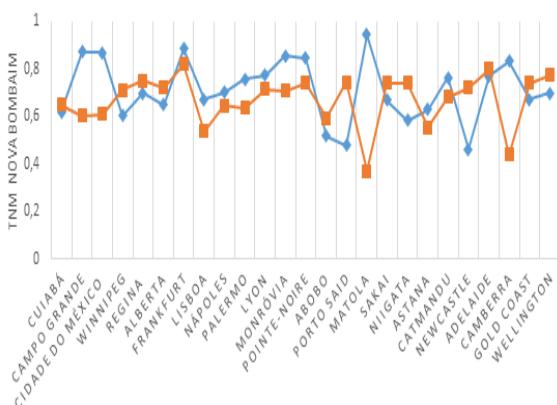
C4 – Gráfico de tNM - Cidades do Continente Asiático



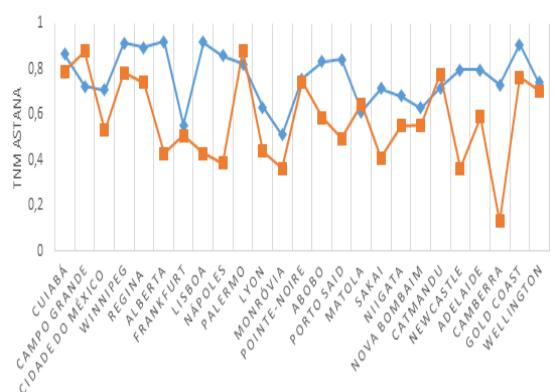
Sakai



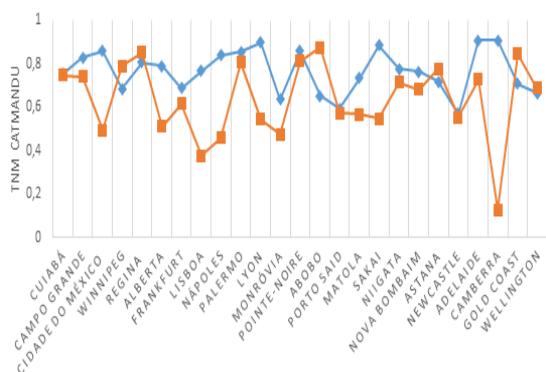
Niigata



Nova Bombaim

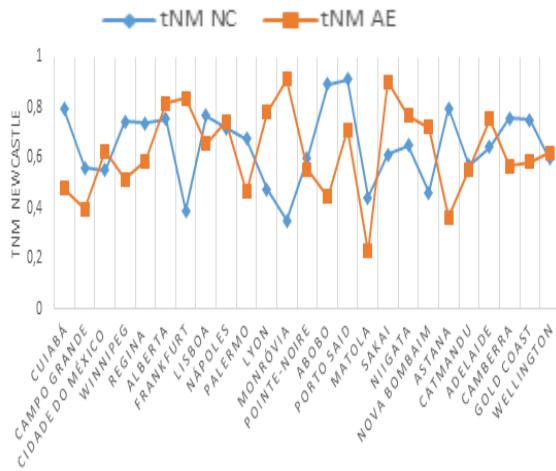


Astana

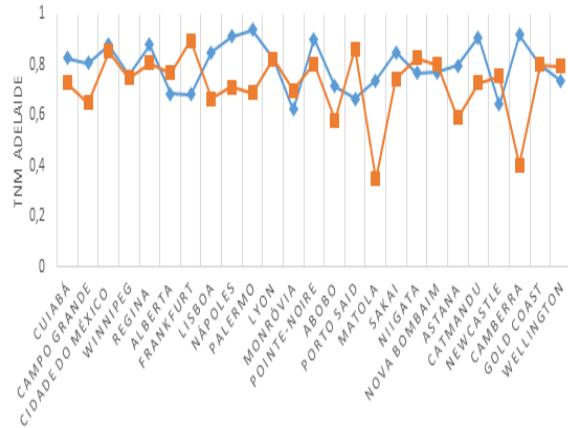


Catmandu

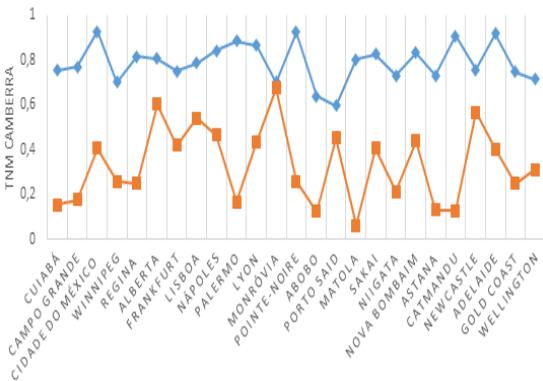
C5 – Gráfico de tNM - Cidades do Continente Oceânico



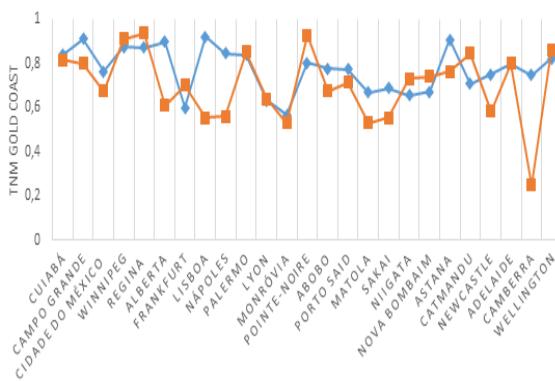
New Castle



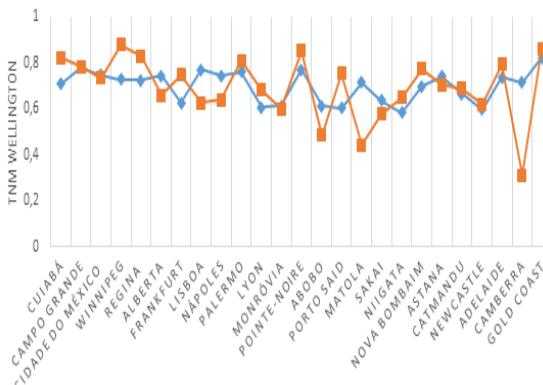
Adelaide



Camberra



Gold Coast



Wellington