



UNIVERSIDADE EDUARDO MONDLANE



FACULDADE DE CIÊNCIAS

DEPARTAMENTO MATEMÁTICA E INFORMÁTICA

CURSO DE LICENCIATURA EM CIÊNCIAS DE INFORMAÇÃO GEOGRÁFICA

Relatório do Trabalho de Licenciatura

Análise da Distribuição Espacial da Malária no Bairro Polana Caniço

“Dissertação apresentada em cumprimento parcial dos requisitos exigidos para a obtenção do grau de Licenciatura em Ciências de Informação Geográfica, da Universidade Eduardo Mondlane”

Autor: Cremildo Gonçalves Manhiça

Maputo, Junho de 2015

Cremildo Gonçalves Manhiça

TEMA

Análise da Distribuição Espacial da Malária no Bairro Polana Caniço

Supervisor: MSc Márcio Fernando Mathe

Maputo, Junho de 2015

Agradecimentos

Em primeiro lugar, agradeço a Deus, por me conceder o dom da vida;

Aos meus queridos pais que sempre me incentivaram a estudar desde pequeno;

Ao Professor dr. Márcio Fernando Mathe e ao dr. Mussagy Mahomed pela orientação, apoio e amizade. Foi uma honra ser orientado por eles;

Ao Centro de Investigação e Treino em Saúde da Polana Caniço pelos dados de malária cedidos e a todos funcionários desta instituição que ajudaram de alguma forma no desenvolvimento do trabalho, em especial, ao meu orientador de estágio dr. Américo Feriano da divisão de Geografia e Demografia.

Aos meus irmãos Tonecas e Albino, minhas irmãs Angelica e Carolina, que sempre me apoiaram e continuam a me apoiar.

A todos meus docentes, em especial aos Drs. Assane, João Dias, Márcio, Comboio, Wisse, Muheca, Ida, Manuel Alves e muitos outros que aqui não citei, que me cederam as ferramentas para que eu pudesse produzir e criar meios de progredir na vida social e académica.

A todos os meus colegas e amigos que sempre estiveram por perto pra auxiliar sempre que fosse necessário em especial atenção para a Lúcia, Horácio, Nota, Cananda, Gilberto, Facuze, Paulo, Israel, Jacinto, Domingos, Queiroz, Helder, Memeco e muitos outros que aqui não citei pelo carinho, companheirismo e espírito de equipa e acima de tudo pelo respeito que todos têm por mim.

Agradeço também a todos os visionários do mundo todo que me inspiraram e contribuíram directa ou indirectamente, para a finalização de mais uma etapa.

Declaração de Compromisso de Honra

Eu, **Cremildo Gonçalves Manhiça**, declaro por minha honra, que o conteúdo constante nas páginas deste trabalho foi por mim elaborado, fruto do meu inteiro esforço, investigação, dedicação e da minha inteira responsabilidade.

De salientar que, a informação contida aqui, reflecte somente a verdade.

(Cremildo Gonçalves Manhiça)

Dedicatória

Dedico este trabalho aos meus queridos pais Gonçalves Sitique e Georgina Albasine pelo imenso amor que sempre tiveram comigo.

Epígrafe

"Suba o primeiro degrau com fé, voce não precisa ver a escada toda somente o primeiro degrau."

[Martin Luter King Jr]

Resumo

Neste trabalho é apresentada uma abordagem metodológica que caracteriza o perfil de risco de transmissão da malária no bairro da Polana caniço a partir de uma análise multidisciplinar com a aplicação de técnicas de Detecção Remota, Sistema de Informação Geográfica e Regressão Logística para mapeamento das áreas de risco de transmissão da malária. Esta abordagem foi composta de um levantamento no terreno de coordenadas geográficas das residências de indivíduos que tiveram malária num determinado período (Janeiro de 2013 a Junho 2014) seguido de uma análise que combinou a análise espacial e geoestatística. Foi desenvolvido um modelo baseado em 3 variáveis, Índice Normalizado de Vegetação, Temperatura da superfície e Índice de Humidade (*Tasselad Cap*), obtidos através do processamento digital de uma imagem multiespectral do Landsat-5 TM, de modo a correlacionar os casos de malária com as variáveis ambientais. O modelo de regressão logística identificou essas 3 variáveis como sendo variáveis explanatórias significativas para a presença dos vectores. Através dos resultados da regressão logística foi possível criar um mapa de probabilidade de ocorrência da malária no bairro da Polana caniço mostrando as áreas mais vulneráveis para a propagação dessa epidemia.

Os resultados obtidos foram validados através de testes geoestatísticos de ajuste de modelos e para o efeito foi utilizado o método ROC (*Relative Operating Characteristic*) e mostrou um ajuste de quase 80%, um desempenho considerado satisfatório para predições espaciais da aptidão de modelos.

Palavras-chave: Regressão logística, modelação espacial, malária, SIG e saúde.

Acrónimos

CENACARTA – Centro Nacional de Cartografia

CDC – Centres of Disease Control

CISPOC – Centro de Investigação e Treino em Saúde da Polana Caniço

DR – Detecção Remota

EGCM – Estratégia Global para o Controlo da Malária

GAMP – The Global Action Malaria Plan

GCPs – Ground Control Points

GLOVIS – Global Visualization Viewer

INGC – Instituto Nacional de Gestão de Calamidades

MICOA – Ministério para a Coordenação da Acção Ambiental

MISAU – Ministério da Saúde

OMS – Organização Mundial de Saúde

PDI – Processamento Digital de Imagens

PNCM – Programa Nacional de Controlo da Malária

RBM – Roll Back Malaria

SIFA – Síndrome Febril Agudo

SIG – Sistemas de Informação Geográfica

SUCEN - Superintendência de Controlo de Endemias

UEM – Universidade Eduardo Mondlane

USGS - United States Geological Survey

Agradecimentos	I
Declaração de Compromisso de Honra	II
Dedicatória	III
Epígrafe	IV
Resumo	V
Acrónimos	VI

Índice

CAPITULO I	5
1. Introdução.....	5
1.1. Motivação.....	6
1.2. Definição do Problema.....	6
1.3. Justificativa do tema.....	7
1.4. Relevância do estudo.....	7
1.5. Objectivos.....	8
1.5.1. Geral.....	8
1.5.2. Específicos:	8
1.6. Descrição da área de estudo	9
CAPITULO II	10
2. REVISÃO BIBLIOGRÁFICA	10
2.1. Especificações Gerais.....	10
2.1.1. Etiologia e Patogenia	10
2.1.2. Ciclo de vida dos Parasitas	11
2.1.2.1. Ciclo do parasita no mosquito (ciclo sexuado)	11
2.1.2.2. Ciclo do parasita no homem (ciclo assexuado)	12
2.1.3. Ecologia dos Vectores da Malária em Moçambique	13
2.1.3.1. O Anopheles gambiae	13
2.1.3.2. O Anopheles arabiensis	14
2.1.3.3. Anopheles funestus	14
2.1.4. Mudanças Climáticas Globais e Doenças Infecciosas	15
2.1.4.1. Mudanças Climáticas e Saúde Pública em Moçambique.....	16
2.1.5. Uso dos produtos de Detecção Remota e Sistemas de Informação Geográfica no Controlo e Prevenção da Malária	17
2.1.6. Controlo Global da Malária	19
2.1.7. Sistema de Informação Geográfica e Álgebra de Mapas.....	20
2.1.7.1. A álgebra de mapas	22
2.1.7.2. Georreferenciación de dados	22
2.1.8. Importância da Integração dos SIG e Análise Espacial na Epidemiologia.....	22
2.1.9. Detecção Remota	23

2.1.9.1.	Processamento Digital de Imagens	24
2.1.9.2.	Realse	27
2.1.9.3.	Composição Colorida.....	28
CAPITULO III.....		29
3.	Material e Métodos.....	29
3.1.	Material	29
3.2.	Métodos.....	30
3.2.1.	Pré-processamento de Imagens de Satélite	31
3.2.1.1.	Correção Geométrica.....	31
3.2.1.1.1.	Método de Interpolação polinomial	32
3.2.1.1.2.	Modelos impíricos.....	32
3.2.1.1.3.	Funções polinomiais Bidimensionais (2D)	33
3.2.1.1.4.	Funções Polinomiais Tridimenssionais	34
3.2.1.1.5.	Funções relacionais	34
3.2.1.2.	Correção Atmosférica	35
3.2.1.2.1.	Método de correção atmosférica FLAASH.....	36
3.2.1.2.2.	Quick Atmospheric Correction	37
3.2.1.2.3.	Dark Object Substraction	37
3.2.1.3.	Métodos de correcção radiométrica	38
3.2.1.3.1.	Procedimentos de Correção absoluta	38
CAPITULO IV.....		42
4.	PROCESSAMENTO DE IMAGENS E CRIAÇÃO DO MODELO.....	42
4.1.	Processamento digital de imagens.....	42
4.1.1.	Cálculo do Índice de Vegetação por Diferença Normalizada (NDVI)	42
4.1.2.	Cálculo do Índice Tasselad Cap.....	45
4.1.3.	Cálculo da Temperatura da Superfície.....	47
4.1.4.	Regressão Logística e Análise	49
4.1.4.1.	Parâmetros necessários para realização da Regressão Logística	49
4.1.4.2.	Coeficientes e constantes	51
4.1.4.3.	Criação do Mapa de probabilidade de ocorrência através dos resultados da Regressão Logística.....	51
4.1.4.4.	Razão de chances (odds ratio).....	52

4.2. Validação do modelo.....	53
4.2.1. Testes Estatísticos de ajuste do Modelo às Observações	54
4.2.1.1. Rho2 de McFadden.....	54
4.2.1.2. Método R2 (ROC)	55
4.2.1.2.1. Requisitos para realização do ROC	55
4.2.1.2.2. Resultados da operação ROC	56
4.2.1.2.3. Criação do Mapa de Risco de transmissão da malária	57
CAPÍTULO V	59
5. CONCLUSÕES	59
5.1. Discussão e Resultados.....	59
5.2. Conclusão	61
Bibliografia	62
ANEXO 1: Resultados da operação ROC	67
ANEXO 2: Resultados da Regressão Logística.....	68
ANEXO 3: Mapa de Risco de transmissão por malária	69

Índice de figuras

Figura 01: Localização geográfica do Bairro Polana Caniço (Computada pelo autor).	9
Figura 02: Ciclo de vida do plasmodiu (CDC, 2004).	13
Figura 03: Componentes da estratégia global de combate a malária (RBM, 2008).	19
Figura 04: Elementos básicos do processo de detecção remota (Zeilhofer, 1996).	24
Figura 05: Imagem em composição colorida nas bandas R-6, G-5, B-4 (Falsa cor) (Computada pelo autor).	29
Figura 06: Fluxograma do pré-processamento das imagens de satélite (Fonte: Adaptado pelo autor).	31
Figura 07: Imagem da tabela de correcção geométrica com os pontos de controlo usados (Computada pelo autor).	35
Figura 08: Fluxograma do Processamento digital (Adaptado pelo autor).	42
Figura 09: Metadata da imagem Landsat TM utilizada no estudo.....	44
Figura 10: Mapa do índice de vegetação por diferença normalizada (Computada pelo autor).	45

Figura 11: Índice Tassaled Cap com as três componentes de Brilho, Verde e Humidade (Computada pelo autor).	47
Figura 12: Temperatura da superfície da área de estudo (Computada pelo autor).	48
Figura 13: Imagem de probabilidade de ocorrência da malária no bairro Polana Caniço (Computada pelo autor).	52
Figura 14: Curva ROC do modelo em estudo, desenhada no Microsoft excel 2012 (Computada pelo autor).	56
Figura 15: Mapa da distribuição espacial dos padrões de risco de infecção por malária (Computada pelo autor).	58

Índice de tabelas

Tabela 1: Resumo do custo global da malária por ano (RBM, 2008).	20
Tabela 2: Valores de Slope e Intercept aplicados para Cross-Calibration (Volgmann <i>et al.</i> , 2001).	39
Tabela 3: valores de Gain e Offset utilizados no método Dark Object Substraction (Song <i>et al.</i> , 2001).	41
Tabela 4: Valores de radiância específica emitida pelo sol (Chander <i>et al.</i> , 2009).	44
Tabela 5: Coeficientes da equação para o cálculo da humidade (Huang <i>et al.</i> , 2002).	46
Tabela 6: valores das constantes K1 e K2 utilizadas para a conversão da temperatura em graus Kelvin (www.processamento digital.br).	48

CAPITULO I

1. Introdução

Em Moçambique, a eclosão de doenças epidémicas como a malária está diretamente associada a expansão da urbanização e a vasta quantidade de coleções hídricas espalhadas por grandes áreas geográficas do país e que contribuem para a existência de criadouros do seu principal vetor, o *Anopheles gambiae* e afectam maioritariamente crianças e indivíduos residentes nos bairros periféricos e em condições de habitação e ambientais precárias que promovem uma maior interação entre agentes infecciosos e populações, aumentando o risco à saúde de grupos populacionais sem acesso a serviços básicos de saúde (Williams, 1990).

Em vários países, os especialistas da área de saúde estão usando cada vez mais os recursos disponíveis para a análise espacial dos padrões de distribuição das doenças e dos riscos ambientais associados a estas, de modo a criar uma base para auxiliar nos planos e nas avaliações na área de saúde, permitindo desta forma analisar a distribuição dos dados das enfermidades no espaço e no tempo, para identificar os factores de risco e mapear as áreas de risco, através dos Sistemas de Geoprocessamento (Barcellos e Bastos 1996, OMS 2009).

A nível do território nacional, não se tem notado realizações de estudos para elucidar o comportamento e a distribuição espacial de doenças pelo meio ambiente, ainda que existam estudos desenvolvidos nesse sentido, a sua publicação não é de fácil acesso. Como forma de responder a este desafio, foi elaborada esta dissertação para auxiliar na compreensão da dinâmica da transmissão e no comportamento dos vectores, de modo a avaliar o padrão espacial das epidemias em municípios e nos bairros periféricos da Cidade de Maputo. A identificação dessas áreas de transmissão e de risco permite que as ações de controlo sejam mais intensificadas e podem ajudar na redução dos surtos e epidemias da doença (OMS, 2009).

1.1.Motivação

A motivação para a escolha do presente tema está associada à necessidade de compreensão da dinâmica de transmissão e comportamento dos vectores transmissores de doenças pelo meio ambiente, bem como o uso de ferramentas de geoprocessamento e análise espacial nos estudos epidemiológicos tornando possível cada vez mais a identificação de padrões dos agravos e correlação das variáveis socio-económicas e ambientais detectando-se a possibilidade de ocorrência de doenças e contribuindo para identificar padrões de mortalidade, morbilidade e dessiminação de epidemias considerando as condições da população residente em municípios e ou regiões.

1.2.Definição do Problema

Os factores ambientais desempenham um papel muito importante no risco de transmissão e contaminação por doenças epidémicas bem como doenças ocasionais associadas ao ambiente, podendo ser divididos em meio ambiente natural e meio ambiente modificado pela acção humana. O impacto de cada um desses grupos varia por área geográfica e depende do contexto socioeconómico em que são observados, neste contexto, o meio ambiente natural inclui topografia, hidrografia, tipo de solo e clima. Estudos realizados no final do século XIX e início do XX já evidenciavam a importância de cada um desses factores na transmissão de doenças, uma das principais epidemias que pode ser causada por esses factores é a malária, em que esses factores poderão mostrar-se favoráveis na ploriferação dos vectores transmissores desta doença. Além disso, o padrão pluviométrico maximiza o risco de transmissão no início e final da estação chuvosa, quando os solos estão mais húmidos e solos argilosos e baixas altitudes favorecem a transmissão da doença (Hirsch, 1883). Se as características descritas anteriormente, por um lado, facilitam a transmissão das doenças, por outro, são factores que por si só não determinam a ocorrência das mesmas. É através da acção do homem, transformando o meio ambiente natural, que questões sanitárias são observadas com diferentes graus de gravidade (Hirsch 1883, Wagley 1964). O meio ambiente modificado pela acção do homem inclui a qualidade da habitação e do local onde a moradia é estabelecida (por exemplo, distância entre a casa e as áreas agrícolas, riachos, estrada, etc).

Segundo o inquerito realizado pelo MISAU em 2007, em Moçambique, a malária é a causa mais comum de atendimento nas consultas externas, bem como a causa mais frequente de

admissão nas unidades sanitárias e representa um grande desafio para as autoridades sanitárias de Moçambique. Cerca de 44% das consultas externas, são devido à malária, enquanto nas admissões, sobretudo nas enfermarias de pediatria é de 57% e em relação às mortes intra-hospitalares, a malária contribui em cerca de 23% e ainda cerca de 14 mil crianças morrem anualmente devido a problemas de saneamento básico no país. Esta estatística possibilita-nos a criação de um modelo para o controlo e monitoramento dos determinantes de saúde de modo a melhorar a eficácia no processo de prevenção e combate da Malária.

1.3. Justificativa do tema

A adopção de novas tecnologias de informação e comunicação para o combate de doenças ambientais se tem expandido em vários países e vem se mostrando um factor eficaz e determinante para a disseminação de várias epidemias. Entretanto, em Moçambique não se tem notado o uso frequente das mesmas devido à falta de pessoal capacitado para este efeito nos sectores de saúde. Com o andar do tempo os Sistemas de Informação Geográfica vem ganhando espaço em várias áreas de actuação em Moçambique, desta forma decidiu-se criar um modelo de investigação que poderá ser usado como um mecanismo para o alcance dos objectivos do Plano Nacional de Controlo da Malária bem como de outras epidemias.

1.4.Relevância do estudo

A aplicação de Sistemas de Informação Geográfica na análise da distribuição espacial da malária no bairro Polana Caniço irá contribuir para:

1. A implementação de medidas de prevenção e controlo mais eficazes;
2. A planificação espacial do processo de fumigação (isto irá permitir aos gestores poder estimar a quantidade exata de insecticidas a ser usadas, o alvo ou local exacto por se fumigar, definir prioridades entre áreas e zonas a serem desinfectadas, etc.);
3. O controlo da dinâmica e propagação da doença (isto irá permitir no processo de identificação da propagação do vector visando a intensificação ou não dos métodos de prevenção);
4. Localização espacial da eclosão da epidemia;
5. Criação de uma estratégia eficaz para o combate à de doenças ambientais.

1.5. Objectivos

1.5.1. Geral

- ✓ Fazer uma análise, com recurso à ferramentas de geoprocessamento, da distribuição espacial da Malária pelo meio ambiente com base em variáveis ambientais no Bairro Polana Caniço (Cidade de Maputo).

1.5.2. Específicos:

Com vista a alcançar o objectivo geral do trabalho, serão realizados os seguintes objectivos específicos:

- ✓ Fazer a análise da informação sobre a malária na área de estudo;
- ✓ Processar e analisar imagens LandSat 5, da área de estudo;
- ✓ Identificar os principais variáveis ambientais que influenciam na distribuição da epidemia da malária;
- ✓ Fazer o levantamento das prováveis áreas de ploriferação dos vectores;
- ✓ Gerar mapas temáticos das áreas de risco de transmissão da malária;

1.6. Descrição da área de estudo

De acordo com a base de dados cartográfica digital do projecto Reestruturação dos Órgãos Locais, o Bairro Polana Caniço localiza-se na cidade de Maputo, no Distrito Municipal Ka Maxaquene entre os paralelos $25^{\circ}55'22''$ e $25^{\circ}57'00''$ de latitude Sul e os meridianos $32^{\circ}35'30''$ e $32^{\circ}38'00''$ de longitude Este, cobrindo uma extensão de 658ha e com uma população de cerca de 92,067 habitantes. Este bairro possui como fronteiras o bairro Ferroviário a Norte, e a Este a Av. Da Marginal, a Av. FPLM a Oeste e o Bairro Sommerschild a Sul.

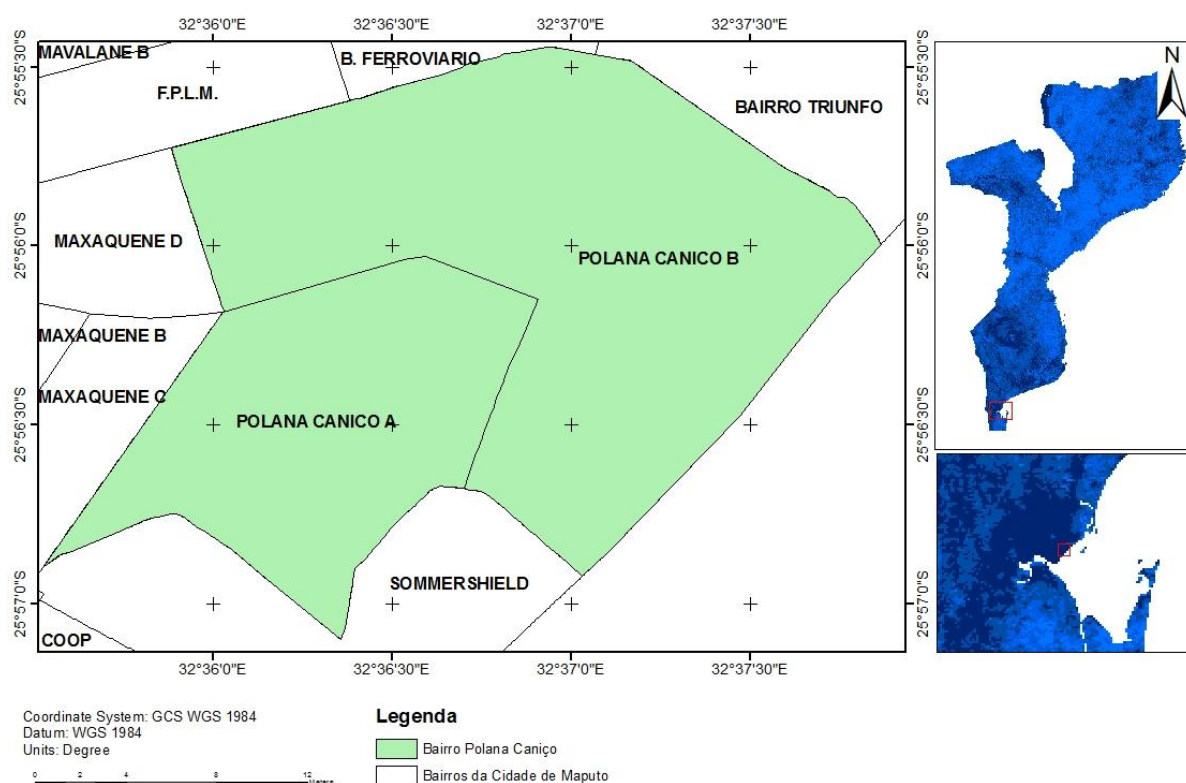


Figura 1. Localização geográfica do Bairro Polana Caniço (Computada pelo autor).

CAPITULO II

2. REVISÃO BIBLIOGRÁFICA

2.1.Especificações Gerais

Os manuais de história da epidemiologia mostram evidências de que o homem pré-histórico já havia sido exposto a malária, estas evidências demonstram a antiguidade e complexidade desta doença. A malária está presente em quase todo o mundo, em particular destaque para os países tropicais e subtropicais onde as temperaturas entre 20°C e 25°C e humidade relativa acima de 60% são frequentes, favorecendo o desenvolvimento dos mosquitos vectores da malária bem como do seu parasita (Martens *et al.* Citados por Arcanjo 2003).

A Malária humana, também conhecida por paludismo ou impaludismo é provavelmente uma das doenças com maior impacto na humanidade. De acordo com a Organização Mundial de Saúde (OMS) estima-se que, anualmente, cerca de 350 a 500 milhões de pessoas sejam infectadas pela malária fazendo um saldo de cerca de um milhão de mortes, dos quais 90% dos casos de malária são registados no continente africano especificamente na África Subsaariana, em que as principais vítimas são crianças abaixo dos cinco anos de idade e mulheres grávidas devido a sua vulnerabilidade e exposição (Who, 2005).

2.1.1. Etiologia e Patogenia

Trata-se de uma patologia infecciosa aguda ou crónica transmitida por um mosquito vector e que, nos seres humanos, é causada por quatro espécies de parasitas protozoários do género *Plasmodium*. São o *Plasmodium falciparum*, *Plasmodium vivax*, *Plasmodium ovale* e *Plasmodium malariae*, sendo que o maior número de mortes é causado pela malária proveniente do *plasmodium falciparum*. Estes parasitas apresentam um ciclo de vida complexo, alternando entre hospedeiros humanos e mosquitos fêmeas do género *Anopheles* (Kasper *et al.*, 2006).

De acordo com o SUCEN (Superintendência de Controle de Endemias) do Brasil, os parasitas da malária humana pertencem ao filo *Protozoa* subfilo *Sporozoa*, subordem *Hemosporina*, família *Plasmodiidae* e género *Plasmodium*. Os mosquitos transmissores da malária humana são do género *Anopheles*, da família *Culicidae*, subordem *Nematocera* e ordem *Diptera*.

Enquanto os *Anopheles* machos se alimentam somente de néctar e de seiva vegetal, as fêmeas necessitam de sangue para o desenvolvimento dos óvulos o que faz com que estas últimas procurem sangue humano para se alimentar tornando-se assim os principais vectores transmissores da malária. As fêmeas depositam os ovos em diversas coleções hídricas que apresentam baixas concentrações de matéria orgânica, levando cerca de 7 a 20 dias para os estágios de desenvolvimento que compreendem ovo, larva, pupa e mosquito adulto, dependendo da disponibilidade de alimento e temperatura (Sucen, 2000).

2.1.2. Ciclo de vida dos Parasitas

O ciclo de vida das espécies de parasitas da malária é essencialmente o mesmo, com uma fase sexuada (esporogonia) que ocorre no mosquito *Anopheles* e uma fase assexuada (esquizogonia) que ocorre no hospedeiro vertebrado e devido a isso, o homem é considerado hospedeiro intermediário e o mosquito hospedeiro definitivo (Kasper *et al.*, 2006).

2.1.2.1.Ciclo do parasita no mosquito (ciclo sexuada)

A fêmea do mosquito *Anopheles* ingere sangue humano infectado com parasitas da malária e juntamente com as células vermelhas do sangue ela ingere os gametócitos, células sexuadas. A maturação do gametócito feminino irá formar o gameta feminino ou macrogameta, enquanto o gametócito masculino irá formar o gameta masculino ou microgameta. No estômago do mosquito o microgameta fecunda o macrogameta, formando o zigoto. No período de 18 a 24 horas, o zigoto se torna alongado e móvel e passa a se chamar oocineto. Por sua vez o oocineto se aloja entre a parede externa e as células epiteliais do estômago do mosquito e se transforma em uma pequena esfera com membrana elástica, chamando-se agora de oocisto. No processo de maturação do oocisto, ocorre a esporogonia (meiose seguida de mitoses), formando os esporozoítos que rompem a membrana do oocisto e migram para as glândulas salivares do mosquito. Quando esse mosquito for realizar o repasto sanguíneo, os esporozoítos serão injetados no hospedeiro vertebrado (Kasper *et al.*, 2006).

2.1.2.2.Ciclo do parasita no homem (ciclo assexuado)

A infecção humana começa quando um mosquito *Anopheles* fêmea inocula esporozóites dos plasmódios a partir de sua glândula salivar durante uma refeição de sangue. Essas formas móveis microscópicas do parasita da malária são transportadas rapidamente pela corrente sanguínea até ao fígado, onde invadem as células do parênquima hepático e começam o período de reprodução assexuada. Por sua vez, nas células hepáticas os esporozoítos se reproduzem por esquizogonia ou merogonia (mitose) e recebem o nome de esquizonte. A fase de reprodução assexuada que ocorre no fígado é chamada de esquizogonia exoeritrocítica. No fim do estágio pré-eritrocítico, os esquizontes rompem e liberam, na corrente sanguínea, milhares de merozoítos, um único esporozóite pode produzir cerca de 10 mil a 30 mil merozoítos-filhos. Parte destes parasitas, agora postos em liberdade, é englobada por células fagocitárias e destruída, entretanto, outra parte se fixa nos glóbulos vermelhos dos vasos sinusóides do fígado. Para o *P. vivax* e *P. ovale* muitos desses merozoítos invadem novamente as células hepáticas e permanecem na forma latente. Os merozoítos liberados no sangue invadem os eritrócitos, multiplicam-se de seis a vinte vezes a cada 24 e 72h respectivamente, e passam a se chamar trofozoítos (possui forma de anel). O trofozoíto jovem na hemácia cresce e se divide por processo assexuado (esquizogonia eritrocítica). O núcleo do parasita se divide entre 3 e 5 vezes, seguido também da divisão do citoplasma, formando o esquizonte. Os esquizontes maduros irão se dividir e formar os merozoítos. Quando o processo de esquizogonia é completo, os merozoítos são libertos no plasma. Estes irão invadir eritrócitos sadios e o processo irá se repetir. A multiplicação continua e em aproximadamente duas semanas já existe número suficiente de parasitas para determinar os sintomas clínicos. Após fases sucessivas de esquizogonia, aparecem as estruturas sexuadas, denominadas gametócitos. Após invadir novos eritrócitos, os gametócitos crescem, sem ocorrer divisão do núcleo, e amadurecem tornando-se formas infectantes para o mosquito. Quando os parasitas atingem densidades de aproximadamente 50/ μ l de sangue, começa o estágio sintomático da infecção. A doença em seres humanos é causada pelos efeitos directos da invasão e da destruição eritrocitárias pelo parasita assexuado e pela reação do hospedeiro. Após serem ingeridos durante a picada para alimentar-se de sangue de um mosquito *Anopheles* fêmea, os gametócitos masculino e feminino formam um zigoto no intestino médio do insecto, este amadurece até o oocineto que penetra e encista-se na parede intestinal do mosquito. Por sua vez, o oocisto resultante multiplica-se por divisão assexuada, até romper e libertar grande quantidade de esporozóites

móveis que em seguida migram pela hemolinfa até a glândula salivar do mosquito, onde aguardam a inoculação em outro ser humano na próxima picada (Kasper *et al.*, 2006).




Figura 2: Ciclo de vida do plasmodiu (CDC, 2004).

2.1.3. Ecologia dos Vetores da Malária em Moçambique

O estudo da ecologia dos vetores permite avaliar o nível de vulnerabilidade de uma determinada área, quantificando os fatores de risco, o que possibilita formular medidas mais eficazes no controlo da malária. Segundo fontes citadas no relatório da JEFFARES & GREEN (Pty) Ltd sobre a Avaliação do Impacto Ambiental e na Saúde do Projecto de Reabilitação da Barragem de Nacala, os vetores causadores de malária em humanos que mais ocorrem em Moçambique são o *Anopheles Gambiae*, *Anopheles Arabiensis* e o *Anopheles Funestos*, sendo o *Anopheles Gambiae* o mais frequente (Jeffares & Green, 2010).

2.1.3.1.O *Anopheles gambiae*

Esta é a espécie que causa maior número de casos de malária em Moçambique. As larvas são encontradas mais frequentemente em habitats efêmeros de água doce, formados por poças rasas de água parada, charcos abertos e expostos ao sol, e outras depressões do solo pobre em vegetação. A água é caracteristicamente turva, de baixo a moderado teor de matéria orgânica,

com moderado crescimento de algas. Os adultos são facilmente atraídos pelo sangue humano invadindo, assim, as casas para se alimentarem do sangue dos ocupantes. Tendem também a permanecer dentro das casas imediatamente após se alimentarem, deslocando-se para locais de repouso ao ar livre depois de 12 a 24 horas. Tem sido reportado, que os adultos são mais prevalentes nos meses mais frios de Maio e Junho após a estação chuvosa. O *Anopheles gambiae* parece apresentar maior preferencia por sangue humano e uma maior tendência a envadir casas para se alimentar do que o *Anopheles arabiensis* e também prefere as áreas de maior humidade relativa do que o *Anopheles arabiensis* (Simmons, 1943).

2.1.3.2.O Anopheles arabiensis

Esta espécie de água doce é muito semelhante em biologia e comportamento ao *An. gambiae*, no entanto, esta espécie parece mostrar uma tendência maior para estar ao ar livre e alimentar-se de animais com maior frequência do que o *An. gambiae*, sendo assim considerado um vector menos eficiente do que seu parente próximo. Embora ambas as espécies ocorram frequentemente em conjunto, o *An. arabiensis* aparece mais frequentemente em zonas áridas e savanas com vegetação escassa da África tropical, preferindo humidade mais baixa do que o *an. gambiae*. Por uma série de razões, esta espécie é considerada mais difícil de controlar devido à sua resistência em ambientes mais severos e às características comportamentais dos adultos (Who 2008, Simmons 1943).

2.1.3.3.Anopheles funestus

É também um vector da malária amplamente espalhado, se posicionando em segundo depois do *an. gambiae* em muitas áreas. Partilha de muitas características epidemiológicas e fisiológicas com o *an. gambiae*, alimenta-se predominantemente do sangue dos seres humanos, sendo uma espécie geralmente robusta e de longa vida, que é muito susceptível de infectar, e facilmente entra e permanece nas casas. Tem um voo muito longo, mas não tem uma tendência tão forte para invadir as casas como o *an. gambiae*. As larvas preferem locais de águas límpidas permanentes e semi-permanentes, com vegetação emergente. Encontra-se comumente em córregos, especialmente em águas debaixo de uma sombra, pântanos, escoamentos, campos de arroz, e nas margens de rios lentos com capim. As flutuações sazonais nos números da população adulta são semelhantes ao *Anopheles gambiae*, muitas vezes uma espécie se torna

mais destacada que a outra no que diz respeito à transmissão da malária, dependendo da época. Os adultos tanto se alimentam no interior como no exterior das casas, preferindo os seres humanos, mas facilmente se alimentam o sangue de animais (Who, 2008).

2.1.4. Mudanças Climáticas Globais e Doenças Infecciosas

As mudanças climáticas são uma realidade inegável e resultam, sobretudo, das acções humanas e colocam em sério perigo a saúde do Homem e de outros seres vivos. Informações contidas na revista científica da UEM explicam que as manifestações dessas mudanças ocorrerem em múltiplos sectores e aos diferentes níveis, sendo que no sector da saúde, as manifestações incluem a ocorrência de distúrbios psicossociais, em consequência dos eventos climáticos extremos como seca, cheias, ciclones, bem como de alterações nos padrões de ocorrência de doenças transmitidas por vectores (como malária) e por água contaminada (como cólera e outras doenças diarreicas). Alguns dos efeitos das mudanças climáticas já se fazem sentir em Moçambique, incluindo a ocorrência com relativa frequência de eventos climáticos, como vagas de calor e de frio, secas e cheias (Mohsin e Vergara, 2012).

Segundo Mc Michael *et al.* citados por Vasconcelos (2004), o resultado das mudanças ambientais inclui alteração na composição atmosférica, degradação dos solos, escassez de água, perda de biodiversidade entre outros. Suas pesquisas prevêem que o desenvolvimento económico-social e o aumento substancial da população até 2050, principalmente nos países pouco desenvolvidos, serão uma das causas dos problemas ambientais. Estes autores explicam que dentre esses problemas há o aumento de antigas e novas doenças infecciosas, ameaçando a vida de milhões de pessoas em todo o mundo. As emissões antropogénicas de gases na atmosfera, vinculados ao desflorestamento são indicadas como factores que induzem ao aquecimento da superfície da Terra. É também aceite pelos cientistas que este aquecimento pode causar uma expansão de insetos transmissores de doenças como a malária, febre-amarela, leishmaniose, entre outras, principalmente nos trópicos. A atividade biológica e a distribuição geográfica do parasita da malária (espécies do género *Plasmodium*) e do vetor (*Anopheles*) são sensíveis a variações climáticas, especialmente temperatura e precipitação.

Para prever a influência das variações climáticas sobre a distribuição e incidência da malária, Martens *et al.* (1995) utilizaram modelação matemática. O modelo avalia os efeitos das mudanças globais sobre a malária e consiste na ligação de vários módulos ou sistemas, entre eles o sistema do clima, sistema da malária que subdivide em (humano e do mosquito) e sistema de impacto. Estes sistemas são ligados diretamente de forma que a saída de um significaria a

entrada do outro. A precipitação e temperatura são os principais factores que atuam no potencial risco de transmissão da malária, esses factores são derivados do sistema climático (Martens *et al.*, 1995).

A interação entre o sistema humano e do mosquito determina o grau de transição entre população humana susceptível, infectada e imune. O sistema de impacto estima o impacto na saúde descrito pela morbilidade e mortalidade da malária. Os cientistas concluíram que um aumento da temperatura pode levar à expansão das áreas de ocorrência de malária. As principais mudanças ocorreriam em áreas onde os mosquitos transmissores já existem, mas os parasitas são limitados pela temperatura. A precipitação exerce influência sobre a malária porque parte do ciclo de vida do mosquito ocorre na água. As chuvas em quantidade moderada podem facilitar a proliferação dos mosquitos vetores, mas se ocorrerem, em excesso, destroem os criadouros dos mosquitos, eliminando assim as larvas que ficam depositadas em poças de água, nas margens de rios, por exemplo. A precipitação também pode elevar a humidade relativa e consequentemente a longevidade do mosquito adulto (Martens *et al.*, 1995).

2.1.4.1.Mudanças Climáticas e Saúde Pública em Moçambique

Pela situação geográfica e características socioeconómicas da sua população, Moçambique é, por muitos, considerado um país vulnerável ao impacto das mudanças climáticas. Entre as razões, citam-se uma costa de cerca de 2700 km, cerca de 60% da população habita em zonas costeiras com dependência socioeconómica nos recursos costeiros, grande vulnerabilidade aos ciclones e à subida do nível do mar, infraestruturas sanitárias inadequadas e limitados recursos de alerta e resposta aos eventos extremos da natureza (INGC, 2009).

O Governo de Moçambique criou o Ministério para a Coordenação da Acção Ambiental (MICOA), através do Decreto Presidencial nº 2/94, com a finalidade de promover uma melhor coordenação de todos os sectores de actividades e incentivar uma utilização correcta e responsável dos recursos naturais do país. Entre as suas obrigações, cabe ao MICOA exercer o controlo e a fiscalização sobre as actividades económicas e sociais no que se refere às suas implicações ambientais. É nesse contexto que em 1997 foi criada a Lei do Ambiente (Lei nº 20/97) que tem como objectivo fornecer um quadro legal básico para o uso e gestão correcta do ambiente e seus componentes de modo a assegurar um desenvolvimento sustentável do país (Mohsin e Vergara, 2012).

2.1.5. Uso dos produtos de Detecção Remota e Sistemas de Informação Geográfica no Controlo e Prevenção da Malária

O conhecimento da dinâmica das espécies transmissoras da malária é um requisito essencial para a utilização eficaz de dados de detecção remota com a finalidade de quantificar e monitorar as áreas de crescimento das mesmas. Ao longo do tempo, vários autores usaram dados ambientais para classificar os habitats onde as larvas dos mosquitos transmissores da malária estariam presentes ou ausentes, desta forma combinaram variáveis como a altitude em relação ao nível do mar, presença de plantas aquáticas de diferentes gêneros, características da água e identificaram corretamente de 60 a 100% das áreas positivas e negativas para as larvas dos vectores, integraram também dados de detecção remota, sistema de informação geográfica e pesquisas de campo para prever a dinâmica das populações de *Anopheles* em Chiapas, no México. Imagens TM-Landsat foram analisadas na época de chuva (limitada devido às nuvens) e de estiagem, identificando 16 unidades de cobertura do solo. Habitats individuais foram classificados dentro dessas unidades usando análise de agrupamento *clustering* (Roberts *et al.*, 1996).

Cíntia Vasconcelos e Evelyn Moraes utilizaram imagens do sensor TM-Landsat 5 dos anos 1996 e 2001, aplicaram o modelo linear de mistura espectral nas bandas originais 3, 4 e 5 para gerar as três componentes referentes à vegetação, ao solo e à sombra. Para realizar o modelo linear de mistura, foram capturados da imagem TM-Landsat composição colorida (R-3, G-4 e B-5) *pixels* puros de solo, sombra e vegetação e aplicaram o algoritmo de segmentação de imagens para agrupar os “pixels” adjacentes e semelhantes para formar regiões homogêneas. O resultado da classificação supervisionada foi comparado às imagens obtidas pelo modelo linear de mistura e pelas respostas espectrais dos alvos nas bandas 3R, 4G e 5B do sensor TM-Landsat5 foram combinadas com os resultados da classificação supervisionada permitindo assim prever a distribuição espacial da malária no município de Jacundá-PA (Camara, 2001).

Os autores Rejmankova *et al.* (1995), utilizaram dados do satélite SPOT-HRV para prever a densidade do mosquito *An. albimanus* ao norte de Belize, baseando-se na distância entre áreas com habitações humanas de vários tamanhos e próximas ao rio e locais pantanosos. Por essa combinação de classes, eles selecionaram dois grupos, aqueles localizados a menos de 500 metros do habitat do vector e a mais de 1500 metros. As áreas com distâncias maiores que 1500 metros do habitat apresentaram uma baixa densidade do mosquito, enquanto as áreas com distâncias menores de 500 metros apresentaram maior densidade. Dados do satélite SPOT

foram também utilizados por Roberts *et al.* (1996) para prever a distribuição do vetor da malária em Belize usando como critério para determinar a densidade dos mosquitos a distância das casas ao habitat dos vectores (*An. pseudopunctipennis* e *An. darlingi*) como é o caso de florestas, córregos, etc. Foram identificadas cinco classes de cobertura do solo para prever a distribuição do mosquito e apresentaram um resultado com uma exatidão maior que 90%.

Em 1992, Wood *et al.* utilizaram imagens do sensor, Landsat thematic mapper (com 30m de resolução) e Sistemas de Informação Geográfica e conseguiram identificar grandes áreas de produção de mosquitos na Califórnia, conseguiram detectar e correlacionar a reflectância da plantação do arroz na sua fase de crescimento com a densidade das larvas do *Anopheles freeborni*. Foram também medidas distâncias entre a fonte de alimento e os campos de plantação do arroz utilizando os SIG e os resultados revelaram que as plantações de arroz em fase de crescimento localizados em áreas próximas a pastagens e outras fontes de alimento contribuíram para o aumento da produção das larvas de mosquitos. Comparativamente às plantações mais distantes estes resultados tiveram uma precisão de cerca de mais de 85% (Shri, 2000).

Uma das mais recentes aplicações da detecção remota foi o caso da previsão das temporadas de ocorrência de malária no Quênia usando imagens dos satélites NOAA e Meteostat.

A temperatura na superfície da terra, reflectância na banda média do infravermelho, precipitação e valores do NDVI foram derivados dos dados de satélites. Estas variáveis foram correlacionadas com a percentagem do total dos casos positivos de malária em cada mês utilizando temporal fourier analysis. O NDVI em cada mês precedente tinha cada vez maior correlação com os casos positivos de malária. Os valores do NDVI entre 0.35-0.40 indicavam cerca de 5% dos casos anuais de malária em cada mês. Concluíram que os mapas temporais da malária baseados no NDVI de 0.4 tinham maior precisão (Shri, 2000).

2.1.6. Controlo Global da Malária

O controlo global da malária contribuirá significativamente para alcançar os objectivos de desenvolvimento do milénio, traçados pelas Nações Unidas, em que todos os países membros se comprometeram a alcançar até 2015. Para além da redução do peso da malária, uma luta com sucesso contra a malária terá um efeito positivo sobre a saúde materno-infantil e sobre a redução da pobreza, o que por sua vez irá aumentar a estabilidade global (PNCM, 2007). Na Conferência Ministerial de Amsterdão de 1992, foram enunciados os objetivos do controlo global da malária: I. Prevenção da mortalidade; II. Redução da morbilidade e das perdas económicas e sociais (Silveira e Rezende, 2001). Para que estes objetivos se concretizem em redução e controlo da malária nos diversos países que estão propensos a esta infecção, há que se considerar as diferenças sociais, ambientais e económicas de cada região. Segundo o RBM (2008), a Estratégia Global para o Controlo da Malária (EGCM) possui três elementos básicos para sua implementação:

1. Controlo da malária, usando as ferramentas disponíveis;
2. Erradicação ou eliminação da malária;
3. Pesquisa de novas tecnologias aplicadas no combate a malária.




Figura 3: Componentes da estratégia global de combate a malária (RBM, 2008).

O Plano Estratégico do Programa Nacional de Controlo da Malária (PNCM) elaborado em colaboração com vários parceiros de implementação em Moçambique, delineia as actividades de controlo e prevenção da malária, além de metas de cobertura de várias intervenções com o objectivo de expandir os esforços da luta contra a malária até ao nível dos agregados familiares. O impacto das principais intervenções propostas no plano estratégico irá reflectir-se na redução do número dos casos de infecção por malária, contudo, é necessária uma avaliação geral da situação e que servirá de base para uma monitorização e avaliação dos indicadores-chave de progresso e de impacto das intervenções em curso. Por outro lado, ainda não existe informação que estabeleça a relação entre a cobertura das principais intervenções de controlo da malária e

o grau de redução dos níveis de infecção da doença no país. Assim sendo a medição da cobertura das intervenções e os níveis de infecção da doença (prevalência da infecção malárica e da anemia em crianças e em mulheres grávidas) constitui uma ferramenta base para a avaliação do progresso e do impacto dos esforços empreendidos para a redução da gravidade da doença (PNCM, 2007).

A implementação de uma estratégia de controlo geralmente enfrenta três principais problemas: resistência institucional à mudança; falta de recursos humanos treinados e redução dos orçamentos e na efetiva aplicação dos recursos disponíveis (Silveira e Rezende, 2001). Segundo o GAMP (*the Global Action Malaria Plan*), Moçambique faz parte dos países cujas acções de controlo e eliminação da malária envolvem maiores custos e deverão ser prioritárias de modo a alcançar as metas estabelecidas nos objectivos de desenvolvimento do milénio (RBM, 2008).

Tabela 1: Resumo do custo global da malária por ano (RBM, 2008).

Custo (US\$ millions)	2009	2010	2015	2020	2025
Prevenção	3,728	3,982	3,724	3,864	2,576
Gestão do custo/caso	968	1,359	550	226	87
Custos do Programa	638	839	764	787	714
Custos do Controlo global e erradicação	5,335	6,18	5,037	4,877	3,378
Custos de Pesquisa	759	759	800	681	460
Custo Total	6,094	6,939	5,837	5,559	3,838

2.1.7. Sistema de Informação Geográfica e Álgebra de Mapas

Os Sistemas de Informação Geográficas (SIG) podem ser definidos segundo o contexto de sua utilização e em função do problema a resolver, desta forma ao longo do tempo alguns autores procuraram por uma definição que mais se pudesse enquadrar. Aronoff (1989) definiu os SIG como sendo um conjunto de procedimentos, manual ou automáticos, utilizados no sentido do armazenamento, e manipulação de informação georreferenciada, Cowen (1988) definiu-os como sendo um sistema de apoio na tomada de decisão envolvendo informação georreferenciada num ambiente de resolução de problemas. Ainda neste contexto, Azemoy, Smith e Sicherman (1981) surgiram com uma definição mais abrangente e que definia os SIG

como sendo um conjunto de informações automáticas, que fornecem aos profissionais, capacidade avançada de armazenamento, acesso, manipulação e visualização de informação georreferenciada (IICT, 2009).

Scholten e Stillwell (1990) definem três funções principais possibilitadas por um SIG que requerem vários componentes, de acordo com o objetivo pretendido. A primeira é o armazenamento, gestão e integração de grandes quantidades de dados georreferenciados. Um dado georreferenciado pode ser concebido como contendo dois tipos de informações, dados cartográficos ou de localização, que são coordenadas de pontos (nós) bi ou tridimensionais, linhas (segmentos) ou áreas (polígonos) e dados descritivos ou não-localizados são características (feições) ou atributos de pontos, linhas ou áreas. Estes dados podem ser obtidos através da digitação de dados e a digitalização de mapas ou a transferência eletrônica de bases de dados pré-existentes, cujo custo dependerá da qualidade desejada. Neste processo ocorrerá a conferência, conversão, reformatação, correção e edição, para remover erros existentes nos dados originais ou introduzidos durante o processo de aquisição destes. Para os dados gráficos será necessária a escolha do tipo de estrutura de dados a ser armazenada considerando-se relações entre velocidade e volume, formatos raster ou vector e quantidade de camadas e objectos (Goodchild, 2009).

A segunda função principal dos SIG é prover meios para realizar análises relacionadas especificamente a componentes geográficos dos dados. As operações mais comuns são a pesquisa de dados e a busca de informações de acordo com algum critério de seleção, seja pela sua localização, proximidade, tamanho, valor, etc e a análise espacial que envolve modelação e análise de padrões espaciais e de relacionamento de dados (Goodchild, 2009).

A terceira função principal envolve a organização e gestão de grandes quantidades de dados e a forma como estas informações podem ser facilmente acessadas por todos usuários. Um SIG precisa ser ágil para exibir dados em mapas de boa qualidade. Os mapas inicialmente feitos à mão, são agora um produto implícito de todo trabalho feito dentro do SIG. Entretanto, para diferentes propósitos, outras formas de apresentação dos dados (gráficos e tabelas) algumas vezes são necessárias para uso combinado com os mapas (Goodchild, 2009).

2.1.7.1.A álgebra de mapas

A álgebra de mapas pode ser compreendida como uma extensão da álgebra tradicional, com um conjunto de operadores em que as variáveis manipuladas são campos geográficos. As operações sobre campos geográficos podem ser classificadas como pontuais, zonais e de vizinhança, das quais as principais operações sobre campos geográficos são soma, subtração, divisão, multiplicação, média, máximo/mínimo, funções trigonométricas, combinação booleana, fatiamento, reclassificação e ponderação (Silva e Machado, 2010).

2.1.7.2.Georreferenciação de dados

Georreferenciação de uma imagem ou um mapa ou qualquer outra forma de informação geográfica é um método usado de modo a tornar suas coordenadas conhecidas num dado sistema de referência. Este processo inicia-se com a obtenção das coordenadas (pertencentes ao sistema no qual se pretende georreferenciar) de pontos da imagem ou do mapa a serem georreferenciados, conhecidos como pontos de controlo. Os pontos de controlo são locais que oferecem uma feição física perfeitamente identificável, tais como intersecções de estradas e de rios, represas, pistas de aeroportos, edifícios proeminentes, topos de montanha, entre outros. A obtenção das coordenadas dos pontos de controlo pode ser realizada em campo (a partir de levantamentos topográficos, GPS – Sistema de Posicionamento Global), ou ainda por meio de mesas digitalizadoras, ou outras imagens ou mapas (em papel ou digitais) georreferenciados (Camara *et al.*, 2001).

2.1.8. Importância da Integração dos SIG e Análise Espacial na Epidemiologia

A tecnologia de análise de dados no contexto de sua localização vem sendo cada vez mais valorizada na gestão do sistema de saúde, por auxiliar um planeamento baseado na análise da distribuição espacial das doenças, da localização dos serviços e dos riscos ambientais, e também pelo facto de poder incorporar o indivíduo ao ambiente e as relações a sua volta. Entretanto, saúde pública e ambiente são influenciados pelos padrões de ocupação do espaço, não basta descrever as características das populações, mas é necessário localizar o mais precisamente possível onde estão acontecendo os agravos, que serviços a população está procurando, o local de potencial de risco ambiental. Planeamento, monitoria e avaliação de

programas, estudo de contexto sócio-econômico, vigilância em saúde, todas as ações essenciais à reorientação das acções do sector de saúde são beneficiadas por uma visão, incorporando a distribuição espacial (Bastos *et al.*, 1999).

Segundo Bastos *et al.* a análise da distribuição espacial de agravos possibilita determinar padrões da situação de saúde de uma área, evidenciar disparidades espaciais que levam à delimitação de áreas de risco para mortalidade ou incidência de eventos mórbidos. Ainda segundo Bastos os SIG tornam possível mapear indicadores básicos de saúde, mortalidade, doenças de notificação compulsória e analisar acidentes relacionados ao trabalho. Através da análise da difusão geográfica e exposição de agentes específicos pode-se gerar e analisar hipóteses de investigação. Também é possível planejar e programar actividades de prevenção e controlo de doenças em grupos homogêneos segundo um determinado risco e fazer a monitoria e avaliação dos mesmos (Bastos *et al.*, 1999).

2.1.9. Detecção Remota

A Detecção Remota descreve técnicas e métodos para aquisição de informações sobre objectos ou fenômenos relacionados a esses objectos sem que haja contato directo entre eles (Novo, 1989). A aquisição desta informação é feita através de sensores, que são equipamentos capazes de coletar energia proveniente do objecto, converte-la em sinal passível de ser registrado e apresenta-lo em forma adequada para a extração de informação. Estes sensores remotos podem ser sistemas fotográficos (fotografias aéreas) ou óptico-eletrônicos (imagens de satélite) (Alföldi, 1996).

Segundo Zeilhofer (1996) em geral, Detacção Remota envolve 7 elementos básicos que são:

- a) Fonte de energia ou iluminação – o primeiro requerimento de DR é a disponibilidade de uma fonte de energia que ilumina o objecto de interesse.
- b) Radiação e atmosfera – como a energia se desloca da sua fonte para os objetos monitorados, ela terá contato e interações com a atmosfera pela qual ela passa. Esta interação se repete uma segunda vez na volta da radiação dos objectos para o sensor.
- c) Interação com o objecto monitorado – após a passagem pela atmosfera, a energia interage com o objecto. As interações dependem das características do objecto e da radiação.

d) Registo da energia pelo sensor – após a reflexão da energia pelo objecto ou após a emissão pelo objecto, é necessário um sensor para coletar e mensurar o fluxo da radiação electromagnética.

e) Transmissão, recepção, e processamento – a energia registada pelo sensor deve ser transmitida, normalmente em forma electrónica, para uma estação de recepção e processamento, onde os dados são processados e gerada uma imagem digital).

f) Interpretação e Análise – a imagem processada é interpretada, visualmente e/ou digitalmente, para extrair informação sobre os objectos que foram iluminados.

g) Aplicação – o elemento final do processo de DR é alcançado, quando é aplicada a informação extraída da imagem sobre os objectos para um entendimento melhor, a criação de nova informação, ou para assistir na solução de um problema específico.




Figura 4: Elementos básicos do processo de detecção remota (Zeilhofer, 1996).

2.1.9.1. Processamento Digital de Imagens

Segundo Mascarenhas e Velasco (1989) entende-se por processamento digital de imagens a análise e a manipulação destas, via computador com o objectivo de facilitar a identificação e a extração da informação.

O processamento digital de imagens pode ser dividido em três etapas independentes: pré-processamento, realce e classificação. O pré-processamento refere-se ao processamento inicial de dados brutos para correção radiométrica da imagem, correção atmosférica, correção de distorções geométricas e remoção de ruído. “As técnicas de realce mais comuns em

processamento digital de imagens são: realce de contraste, filtragem, operação aritmética, transformação IHS e componentes principais. Já as técnicas de classificação podem ser divididas em classificação supervisionada e classificação não supervisionada” (Zeilhofer, 1996).

a) Correção Radiométrica

As correções radiométricas visam eliminar ruídos e degradações, devidos aos efeitos atmosféricos, e do sistema sensor. A radiância detectada por um sensor é composta pela radiância dos alvos da superfície da Terra somada com a radiância resultante do espalhamento que a radiação eletromagnética sofre pela atmosfera. Esse espalhamento é maior quanto menor for o comprimento de onda da radiação. Pode-se corrigir os efeitos atmosféricos das imagens utilizando modelos matemáticos que consideram a temperatura, a humidade relativa e outros dados do local de interesse (Novo, 2010).

Segundo Divino Figueredo (2005), as principais correções radiométricas são o “stripping” aplicado ao longo das linhas com base em padrão sucessivo, que aparecem na imagem em decorrência da diferença ou desajuste de calibração dos detectores, e o “dropped lines”, aplicado entre linhas com base em padrão anômalo na imagem, que ocorre pela perda de informação na gravação ou na transmissão dos dados. Outra técnica utilizada consiste na subtração de uma constante dos valores de nível de cinza de todos os *pixels* de uma determinada banda. Essa constante corresponde ao menor valor de nível de cinza dos *pixels* daquela banda (Divino 2005, Zeilhofer 1996).

Os erros devidos ao sistema sensor causam ruídos nas imagens. Estes ruídos podem ser pontuais ou apresentar-se em forma de linhas, e podem ser periódicos ou aleatórios. O método de correção a ser aplicado dependerá do tipo de erro. Por exemplo, se houver perda de uma linha inteira, pode-se atribuir aos *pixels* dessa linha a média dos valores dos pixels das linhas vizinhas (Toutin, 2003).

b) Correção Geométrica e Registro

Todas as imagens obtidas a partir de detecção remota precisam ser corrigidas segundo algum sistema de coordenadas para terem precisão cartográfica e adquirirem propriedades de escala e de projeção (Santos, 2013).

Segundo Richards (1986) as distorções geométricas das imagens podem estar relacionadas a factores como rotação da Terra durante o imageamento, curvatura da Terra; ao grande campo de visada de alguns sensores; variações na altitude, velocidade e atitude da plataforma. Estas distorções podem ser corrigidas, pelo menos parcialmente, por meio de modelos matemáticos que descrevem as distorções existentes. Após a aquisição dos coeficientes deste modelo, uma função de mapeamento é criada para a construção da nova imagem corrigida. Um modelo frequentemente utilizado é o polinomial, cujos coeficientes são estimados a partir de pontos de controlo identificáveis na imagem, e com localização geodésica precisamente conhecida. Cruzamento de estradas, pontes, feições geológicas podem ser tomados como pontos de controlo (Envi, 2012). Os pontos de controlo devem ser igualmente distribuídos em toda a imagem, caso contrário as regiões com poucos ou nenhum ponto podem sofrer mais distorções ainda. É importante também que os pontos sejam posicionados com precisão, sobre a imagem. “Para que duas imagens sejam perfeitamente coincidentes no espaço é necessário que sofram um tipo de transformação espacial conhecido por *registro*”. O registro se faz necessário para realizar uma análise multitemporal, sobrepondo imagens de datas diferentes, juntar imagens adjacentes para a montagem de um mosaico, sobrepor imagens de sensores diferentes (Divino, 2005).

c) Correção Atmosférica

A interferência atmosférica é um dos principais factores de degradação nas imagens, muitas vezes comprometendo a análise e interpretação das mesmas. A intensidade deste efeito depende do comprimento de onda, portanto, ele afecta de modo diferente a cada uma das bandas espectrais (Ouaidrari e Vermote, 1999). A correção da imagem pode ser feita por meio de modelos matemáticos baseados em parâmetros atmosféricos que normalmente são desconhecidos, dificultando a aplicação dos modelos. Estes parâmetros devem ser obtidos na hora e data de passagem do satélite, por meio de estações meteorológicas e isto é um procedimento difícil (Longley *et al.*, 2008).

Na prática utiliza-se técnicas mais simples, que produzem resultados satisfatórios. A técnica do “mínimo histograma” é uma delas, e baseia-se no facto de que, sombras de nuvens densas e de relevo e corpos de água limpa, por hipótese, deveriam ter radiância nula, conseqüentemente níveis de cinza zero. Portanto, valores de níveis de cinza não nulos, encontrados nestas áreas são considerados provenientes de efeito aditivo do espalhamento atmosférico (Divino 2005). A técnica consiste em subtrair de cada *pixel* de cada banda espectral

de toda a imagem, o menor valor medido nestas áreas. Outro método alternativo de correção atmosférica é o da regressão de bandas. Este método assume que entre duas bandas altamente correlacionadas, a equação da recta de melhor ajuste deveria passar pela origem dos eixos, caso não houvesse efeito aditivo da atmosfera. Porém, devido a este efeito, a reta corta o eixo das abcissas em algum ponto maior que zero. O valor da ordenada do ponto de interceção representa o valor adicionado devido a efeitos atmosféricos naquela banda. Este valor, que é a constante da equação da recta, é subtraído da banda considerada (Longley *et al.*, 2008).

2.1.9.2.Realse

a) Realse de Contraste

A técnica de realce de contraste tem por objectivo melhorar a qualidade das imagens sob os critérios subjetivos do olho humano. O contraste entre dois objectos pode ser definido como a razão entre os seus níveis de cinza médios. A manipulação do contraste consiste numa transferência radiométrica em cada "*pixel*", com o objectivo de aumentar a discriminação visual entre os objectos presentes na imagem, realizado-se a operação ponto a ponto, independentemente da vizinhança. Esta transferência radiométrica é realizada com ajuda de histogramas, que são manipulados para obter o realce desejado (Zeilhofer, 1996).

b) Histogramas

A escolha do mapeamento directo adequado é, em geral, essencialmente empírica. Entretanto, um exame prévio do histograma da imagem pode ser útil. O histograma é uma das formas mais comuns de se representar a distribuição dos níveis de cinza (NC) de uma imagem, e a mais utilizada em PDI. O histograma fornece a informação de quantos *pixels* na imagem possuem um determinado NC, definido entre 0 (preto) a 255 (branco) para uma imagem quantificada em 8 bits. Outra característica é que o histograma não apresenta nenhuma informação espacial da imagem, e sim uma função de probabilidade de encontrar um NC referente a um objecto qualquer da imagem. Normalmente tem-se no eixo X a distribuição dos NC e no eixo Y a frequência em que ocorrem (Câmara, 2001).

Um histograma descreve a distribuição estatística dos níveis de cinza em termos do número de amostras ("*pixels*") com cada nível, e esta distribuição pode também ser dada em termos da percentagem do número total de *pixels* na imagem. Pode ser estabelecida uma analogia entre o histograma de uma imagem e a função densidade de probabilidade, que é um modelo

matemático da distribuição de tons de cinza de uma classe de imagens. Segundo Zeilhofer (1996), os histogramas podem ser uni-dimensionais, isto é, para apenas uma banda, ou multi-dimensionais quando representa a distribuição de duas ou mais bandas, sendo o de duas dimensões o mais simples, assim sendo, o histograma de duas bandas, ou scattergrama, permite analisar visualmente o grau de correlação entre duas bandas e decidir sobre tipo de técnica de aumento de contraste a ser aplicado a imagens multi-espectrais.

A forma do histograma fornece informações importantes como a intensidade média e espalhamento dos valores de NC, sendo este último a medida de contraste da imagem e quanto maior o espalhamento ao longo do eixo dos NCs, maior o contraste da imagem (Alföldi, 1996).

c) Filtragem

A aplicação de filtros é amplamente discutida na literatura. Portanto a importância prática destas operações no trabalho com imagens de sistemas passivos é limitada. Com a crescente utilização de imagens de Radar (que possuem um alto grau de ruído “*speckle*”), as técnicas de filtragem ganharam nova importância. As técnicas de filtragem são transformações da imagem “*pixel*” a “*pixel*”, que não dependem apenas do nível de cinza de um determinado “*pixel*”, mas também do valor dos níveis de cinza dos *pixels* vizinhos, na imagem original. Os filtros funcionam como janelas ou máscaras móveis que se deslocam sobre a imagem (Zeilhofer, 1996).

2.1.9.3. Composição Colorida

Trata-se de um dos artifícios de maior utilidade na interpretação das informações da Detecção Remota. Ela é fundamental para uma boa identificação e discriminação dos alvos terrestres. O olho humano é capaz de discriminar mais facilmente matrizes de cores do que tons de cinza. A composição colorida é produzida na tela do computador, ou em outro dispositivo qualquer, atribuindo-se as cores primárias (vermelha, verde e azul) a três bandas espectrais quaisquer. Este artifício é também conhecido como composição RGB (do inglês: Red, Green, Blue). Associando, por exemplo, a banda 3 à cor vermelha (R), a banda 4 à cor verde (G) e a banda 5 à cor azul (B), produz-se uma composição colorida representada por 345 (RGB), (Novo, 2010).



Figura 5: imagem em composição colorida nas bandas R-6, G-5, B-4 (Falsa cor) (Computada pelo autor).

CAPITULO III

3. Material e Métodos

3.1.Material

Neste trabalho foram usadas imagens de satélite LandSat-5 do sensor Thematic Mapper (TM), adquiridas por “*download*” no endereço electrónico da GLOVIS-USGS, foi também usada uma imagem IKONOS e Shapefiles da divisão administrativa, ambos fornecidos pelo CENACARTA. Os dados de malária usados foram extraídos de uma base de dados de um estudo de vigilância denominado SIFA (Síndrome Febril Agudo), essa informação foi disponibilizada pelo Centro de Investigação e Treino em Saúde da Polana Caniço (CISPOC), entidade que conduzia o estudo de vigilância.

Outra parte dos dados usados foi gerada através do processamento das imagens de satélite acima mencionadas, processamento e ou georreferenciação da informação sobre malária ou então por busca categorizada na internet.

Para o processamento de dados foram usados o *software* ArcGIS 10.2 para o Geoprocessamento: criação, edição, análise, consulta, junção, impressão dos dados (*software* disponível grátis – 60 dias), o *software* Envi 5.1 Service Pack 3 para o processamento digital de imagens de satélites, o Idrisi *software* para a realização da regressão logística e um receptor GPS (Global Positioning System) do fabricante GARMIN para colher as coordenadas dos pontos de interesse. Foi também usado o Microsoft Office no módulo MS Excel 2010 – para manipulação dos dados de saúde, MS word 2010 - para edição do relatório e MS Visio 2010 para o desenho do fluxograma de trabalho.

3.2.Métodos

A abordagem metodológica que este trabalho segue, é uma adaptação da metodologia proposta por Roberts e Rodrigues (s.d.) em que os passos preconizados pelos autores para a aplicação de dados de detecção remota com o objectivo de prever a distribuição espacial de vectores de doenças são:

- 1- Definição dos determinantes e variáveis ambientais que podem indicar a presença ou não do vector, como é o caso da temperatura, águas paradas, humidade do solo, drenagens de águas deficientes, precipitação, presença de pequenos lagos e lagoas que oscilam conforme a época do ano e são excelentes sítios de reprodução para os mosquitos do género anophelis;
- 2- Definição da escala adequada, em função do tipo de indicador, variável ou determinante para detectar os factores ambientais pelos sensores remotos;
- 3- Associação de dados de campo com os dados de sensores remotos;
- 4- Previsão de ocorrência de casos de malária com base nos resultados da etapa 3;
- 5- Verificação da precisão dos resultados (exatidão das previsões de localização dos vectores) em campo.

3.2.1. Pré-processamento de Imagens de Satélite

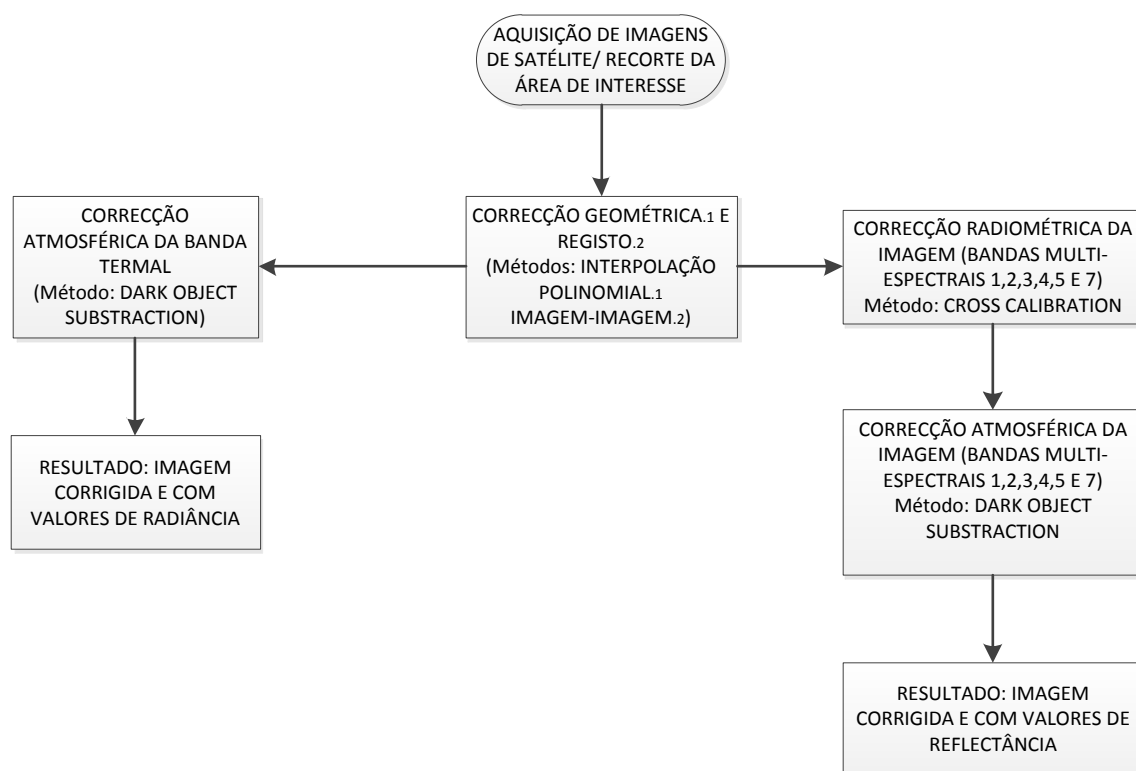


Figura 6: Fluxograma do pré-processamento das imagens de satélite (Fonte: Adaptado pelo autor).

3.2.1.1. Correção Geométrica

A função dos programas de correção geométrica é reorganizar os pixels da imagem em relação a um determinado sistema de projeção cartográfica. Segundo Richards (1986), as distorções geométricas das imagens podem estar relacionadas a factores como rotação da terra durante o processo de aquisição da imagem, curvatura da terra, ao grande campo de visada de alguns sensores, variações na altitude, velocidade e altitude da plataforma bem como da falta de linearidade de alguns sensores.

O processo de correção geométrica envolve basicamente duas etapas. A primeira consiste na determinação da função que relaciona o sistema de referência ao da imagem a ser corrigida e a segunda consiste no cálculo por reamostragem dos valores de nível de cinza dos *pixels* na imagem corrigida. Utilizando um mapa, ou uma imagem previamente registados, como sistema de referência, pode-se registrar uma imagem de forma que seus *pixels* se tornem referenciados a esse sistema, ou seja, a valores de latitude e longitude ou coordenadas UTM (Toutin, 2003).

A função aplicada para correção geométrica é determinada a partir das coordenadas de pontos de controlo na imagem a ser corrigida e no sistema de referência utilizado, esses pontos de controlo devem ser poucos e bem definidos, podendo ser baseados em cruzamento ou bifurcações do sistema hídrico, cruzamento entre o sistema de drenagem e pontes rodoviárias, barragens e extremidades de aeroportos (Bannari *et al.*, 1995).

Neste trabalho as imagens usadas foram registadas com Datum WGS-1984 Zona-36 Sul, através do método imagem-imagem tomando como base uma imagem previamente registada também sofreu uma correção geométrica usando o algoritmo de interpolação polinomial de primeira ordem e o método usado foi o do vizinho mais próximo através de 6 pontos de controlo terrestres adquiridos usando como base a imagem previamente corrigida. Abaixo segue a descrição promenorizada do algoritmo de interpolação polinomial.

3.2.1.1.1. Método de Interpolação polinomial

Algumas distorções geométricas associadas a órbita da plataforma, distorções da terra e sistema de projecção necessitam de modelos e funções matemáticas para a sua correcção geométrica e podem usar tanto modelos empíricos bi-dimensionais e tridimensionais (como é o caso de funções polinomiais ou funções relacionais tridimensionais) bem como modelos físicos e determinísticos bidimensionais e tridimensionais (Richards, 1986).

3.2.1.1.2. Modelos empíricos

Estes modelos podem ser usados quando os parâmetros do sistema de aquisição ou então os modelos físicos tridimensionais não estão disponíveis. Uma vez que esse modelo não reflecte as fontes de distorções eles não necessitam de informação prévia de nenhum componente do sistema (plataforma, sensor, projecção) (Santos, 2013). Segundo Toutin (2003). Esses modelos empíricos são baseados em diferentes funções matemáticas tais como:

Função polinomial bidimensional:

$$P_{2D}(XY) = \sum_{i=0}^m \sum_{j=0}^n a_{ij} X^i Y^j, \text{ (eq: 1)}$$

Função polinomial tridimensional:

$$P_{3D}(XYZ) = \sum_{i=0}^m \sum_{j=0}^n \sum_{k=0}^p a_{ijk} X^i Y^j Z^k, \text{ (eq: 2)}$$

Função relacional (RFs) tridimenssional:

$$R_{3D}(XYZ) = \frac{\sum_{i=0}^m \sum_{j=0}^n \sum_{k=0}^p a_{ijk} X^i Y^j Z^k}{\sum_{i=0}^m \sum_{j=0}^n \sum_{k=0}^p b_{ijk} X^i Y^j Z^k}, \text{ (eq: 3)}$$

onde: X, Y, Z são coordenadas geográficas ou projectadas;

i, j, k são índices inteiros crescentes;

m, n e p são valores inteiros compreendidos entre 0 e 3 com “m + n (+ p)” sendo a ordem da função polinomial que geralmente é do terceiro grau.

Cada polinómio bidimenssional da 1ª, 2ª ou 3ª ordem terá 3, 6 e 10 termos desconhecidos e cada polinómio tridimenssional da 1ª, 2ª e 3ª ordem terá 4, 10 e 20 termos desconhecidos assim como as funções relacionais (RFs) de 1ª, 2ª e 3ª ordem terão 8, 20 e 40 termos desconhecidos. Estas funções polinomiais “inteligentes” reflectem melhor a geometria em ambos os eixos e reduzem o erro dos parametros (“*over-parametrization*”) e a correlacção entre os termos (Okotomo, 1988).

3.2.1.1.3. Funções polinomiais Bidimensionais (2D)

As funções polinomiais de 1ª ordem (6 termos) permitem fazer a correcção da translação, rotação e obliquidade em ambos os eixos enquanto as funções polinomiais da 2ª ordem (12 termos) permitem para além dos parâmetros mencionados acima, a correcção da distorção e da concavidade em ambos os eixos assim como os da 3ª ordem permitem todas as correcções das mesmas distorções que os da 2ª e os restantes que não correspondem a nenhum parametro físico do sistema de aquisição da imagem. Estudos anteriores demonstraram que os polinómios de 3ª ordem introduziam erros em relação ao posicionamento dos pixels em imagens como o Landsat-TM e SPOT-HRV (Caloz e Collet, 2001).

Segundo Bannari *et al.* (1995), já que as funções polinomiais bidimenssionais não reflectem as fontes das distorções durante a formação da imagem elas estão limitadas a imagens com pequenas distorções pelo facto destas funções fazerem a correcção das distorções locais usando os pontos de controlo terrestres, são muito sensíveis a introduzir erros e por consequência essas funções não devem ser usadas quando a precisão geométrica se fizer necessária (Leeuw *et al.*, 1988).

3.2.1.1.4. Funções Polinomiais Tridimensionais

As funções tridimensionais são uma extensão das funções bidimensionais adicionando o termo “Z” relacionado à terceira dimensão da terra, no entanto elas estão sujeitas aos mesmos problemas que qualquer função empírica desta forma elas também são usadas para imagens pequenas, necessitam de enúmeros pontos de controle regularmente distribuídos, fazem uma correção local a nível dos pontos de controle, são sensíveis a erros tem pouca robustez e consistência, o seu uso deve ser limitado a imagens menores ou sistematicamente corrigidas (Leeuw *et al.*, 1988).

3.2.1.1.5. Funções relacionais

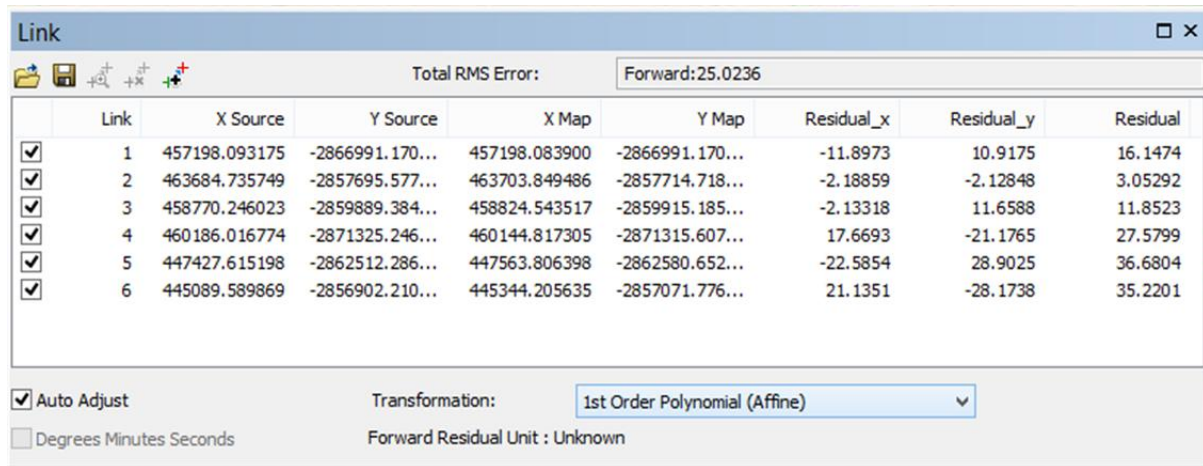
Segundo Madini, (1999) as funções relacionais podem ser usadas em duas vertentes:

- 1) Para aperfeiçoar um modelo físico tridimensional previamente estabelecido; e
- 2) Para computar os termos desconhecidos das funções polinomiais usando os pontos de controle terrestres (GCPs).

Esta primeira denominada *terrain-independent*, apesar de usar o modelo digital do terreno e os pontos de controle terrestres para remover as disproporções nas funções relacionais, é feita em duas etapas. Na primeira etapa define-se uma grelha regular tridimensional da imagem e a grelha das coordenadas da imagem, ambos são computados usando o modelo físico previamente estabelecido, desta forma, a grelha de pontos e o modelo de terreno e as coordenadas da imagem bidimensional são usados como pontos de controle terrestres (GCPs) para resolver as funções relacionais e determinar os termos desconhecidos (Leeuw *et al.*, 1988).

A segunda também denominada *terrain-independent* pode ser executado usando os mesmos métodos utilizados pelas funções polinomiais. Uma vez que há cerca de 40 e 80 parâmetros para as quatro funções polinomiais de 2ª e 3ª ordem, um mínimo de 20 e 40 GCPs respectivamente, são necessários para resolver as funções relacionais tridimensionais. Uma vez que as funções relacionais bem como as polinomiais fazem uma correção local a nível dos pontos de controle e as distorções entre os GCPs não são inteiramente eliminados, maior número de pontos de controle será necessário para reduzir a propagação dos erros num ambiente operacional (Petrie, 2002).

Uma aproximação semelhante à descrita anterior poderá também ser usada para imagens mais largas (SPOT, Landsat, IRS, RADARSAT) e o número de GCPs poderá aumentar proporcionalmente ao tamanho das imagens (Yang, 2001).



Link	X Source	Y Source	X Map	Y Map	Residual_x	Residual_y	Residual
1	457198.093175	-2866991.170...	457198.083900	-2866991.170...	-11.8973	10.9175	16.1474
2	463684.735749	-2857695.577...	463703.849486	-2857714.718...	-2.18859	-2.12848	3.05292
3	458770.246023	-2859889.384...	458824.543517	-2859915.185...	-2.13318	11.6588	11.8523
4	460186.016774	-2871325.246...	460144.817305	-2871315.607...	17.6693	-21.1765	27.5799
5	447427.615198	-2862512.286...	447563.806398	-2862580.652...	-22.5854	28.9025	36.6804
6	445089.589869	-2856902.210...	445344.205635	-2857071.776...	21.1351	-28.1738	35.2201

☒ Auto Adjust
☐ Degrees Minutes Seconds
 Transformation: 1st Order Polynomial (Affine)
 Forward Residual Unit : Unknown

Figura 7: Imagem da tabela de correcção geométrica com os pontos de controlo usados (Computada pelo autor).

3.2.1.2. Correção Atmosférica

A correção atmosférica de imagens de satélite é feita com a intenção de minimizar os efeitos atmosféricos na radiância de uma cena, visto que a atmosfera, por causa dos fenômenos de espalhamento, absorção e refração da energia electromagnética, afecta a radiância reflectida pela superfície que é captada pelo sensor. Dependendo da aplicação, nem sempre é necessário fazer a correção atmosférica, mas para estudos de monitoramento da superfície terrestre ao longo do tempo esse pré-processamento é imprescindível para deixar os dados multitemporais na mesma escala radiométrica (Song *et al.*, 2001).

A correção atmosférica também é necessária para o cálculo de índices de vegetação computados a partir de duas ou mais bandas espectrais, visto que as bandas são afectadas diferentemente pelo espalhamento atmosférico (Sanches *et al.*, 2011).

Ao longo do tempo, técnicas e programas que visam corrigir os efeitos da atmosfera vêm sendo desenvolvidos e aprimorados e, neste contexto alguns modelos padrões de atmosfera e outros baseados na teoria da transferência radioativa (Chandrasekhar, 1960), vêm sendo utilizados para a melhoria deste processo. Para modelos baseados na teoria da transferência radioativa é preciso ter informações sobre parâmetros da atmosfera local no horário de aquisição das imagens de satélite, o que permite um melhor embasamento físico na correção atmosférica. No

entanto, a coleta de todos os parâmetros que permitam uma caracterização minuciosa e completa da atmosfera, sobre uma determinada área em um determinado instante, nem sempre é possível de ser realizada. Segundo Mather, (1999) os modelos de atmosfera padrões são frequentemente mais utilizados, mas isso resulta em perda de acurácia, a qual não pode ser avaliada. Além disso, a visibilidade atmosférica, que é um parâmetro de grande peso no resultado final da correção, muitas vezes é inferida e como a visibilidade atmosférica varia significativamente, a chance de inferir errado o valor desse parâmetro é grande. Neste contexto, o ideal seria um método de correção atmosférica baseado somente nos dados obtidos das imagens de satélite (Murakami *et al.*, 2001, Sanches *et al.*, 2011).

Alguns métodos de correção atmosférica baseados somente em dados obtidos das imagens de satélite são apresentados abaixo.

3.2.1.2.1. Método de correção atmosférica FLAASH

FLAASH (Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes) é um algoritmo desenvolvido pela *Spectral Sciences, Inc.*, sob o patrocínio do Laboratório de Pesquisa da Força Aérea dos EUA, com a finalidade de corrigir os efeitos atmosféricos em imagens de reflectância de sensores hiper-espectrais e multi-espectrais em comprimentos de onda do visível, do infravermelho próximo, de ondas curtas e das regiões do infravermelho (Envi 2009, Golden *et al.* 2009)

O programa corrige os efeitos atmosféricos de imagens de sensores multi-espectrais adquiridas em qualquer vertical (nadir) ou inclinação geométrica. Para isso, utiliza o código de transferência radioativa MODTRAN4 e executa a correção para o efeito de adjacência (mistura de pixel devido ao espalhamento de superfície), e também calcula a visibilidade média da cena (aerossol/nevoa) (Golden, 2009). O FLAASH opera na faixa espectral entre 0,4 e 2,5 μm , e os processamentos são feitos *pixel a pixel*. O modelo parte da imagem de radiância que chega ao sensor e permite obter a reflectância de superfície a partir da derivação de parâmetros atmosféricos como albedo, altitude da superfície, coluna de vapor e água, profundidade óptica de aerossóis e nuvens, além da temperatura da superfície e atmosfera (Kruse, 2004).

A versão inicial do FLAASH utiliza o infravermelho médio através do comprimento de ondas ultravioletas onde a emissão térmica pode ser negligenciada, nesta situação, a radiância

espectral L^* a cada *pixel* do sensor pode ser parametrizada segundo (Staenz *et al.* 1996, Vermote *et al.* 1995, Williams *et al.* 1992) através da seguinte fórmula:

$$L^* = Ap / (1 - \rho_e S) + \frac{B \rho_e}{1 - \rho_e S} + L^*_a \text{ (eq: 4)}$$

Onde ρ é a reflectância de cada *pixel* na superfície, ρ_e é a média da reflectância na superfície em certa região, S é o albedo esférico da atmosfera, L^*_a é a radiância com o efeito *backscattered* da atmosfera, A e B são os coeficientes que dependem das condições geométricas da atmosfera.

3.2.1.2.2. Quick Atmospheric Correction

É um módulo de correção atmosférica para imagens multi-espectrais e hiper-espectrais na faixa entre 0,4 a 2,5 μm . Esse módulo efectua a correção atmosférica a partir de modelos empíricos utilizando somente as informações contidas na cena, não necessitando de informações auxiliares. O processamento, significativamente mais rápido, consiste na busca da resposta espectral média dos objectos que compõem a cena (Envi, 2009).

3.2.1.2.3. Dark Object Subtraction

O método de correção atmosférica DOS (Dark Object Subtraction) proposto por Chavez (1988 e 1989) é um método de correção do espalhamento atmosférico no qual a interferência atmosférica é estimada diretamente a partir dos números digitais (ND) da imagem de satélite, sendo ignorada a absorção atmosférica. Para a aplicação desta técnica não há a necessidade de se obter dados sobre as condições atmosféricas na data de obtenção das imagens. No método DOS assume-se que há uma grande probabilidade de existir alvos (*pixels*) escuros nas imagens, como sombras ocasionadas pela topografia ou por nuvens, os quais deveriam apresentar níveis de cinza muito baixos na imagem, equivalentes a cerca de 1% de reflectância (Chavez, 1989). Contudo, esses *pixels* sombreados apresentam valores de ND nas imagens superiores aos esperados, consequência do espalhamento atmosférico, e por isso esses *pixels* escuros servem de referência para a correção do espalhamento atmosférico. Para a aplicação da correção DOS, a partir da análise do histograma de frequência de NDs de uma das bandas da imagem, de preferência a banda de menor comprimento de onda, um valor de *pixel* escuro é escolhido. Em

seguida, um modelo de espalhamento atmosférico é selecionado e o valor de espalhamento é estimado por banda espectral, sendo os valores de espalhamento estimados normalizados de acordo com os ganhos e compensações usados pelo sistema imageador para coletar os dados. A correção é feita pela subtração dos valores estimados para toda a imagem, assumindo um espalhamento uniforme em toda a cena, o que raramente acontece (Chavez, 1988).

Este método está melhor descrito no módulo de correção radiométrica absoluta abaixo

3.2.1.3. Métodos de correção radiométrica

Os métodos de correção radiométrica em imagens de satélites podem ser agrupados em duas categorias que são a correção radiométrica Absoluta e a Relativa (Thome *et al.* 1997, Tokota *et al.* 1999, Du *et al.* 2002).

A correção radiométrica absoluta faz a conversão dos valores digitais da imagem (DN) para radiância no sensor ($\text{W m}^{-2} \mu\text{m}^{-1} \text{sr}^{-1}$) e, por meio da correção atmosférica faz a conversão dos valores de radiância em reflectância na superfície da terra.

A correção radiométrica relativa é utilizada para remover ou normalizar a variação entre as imagens e o ganho radiométrico dos dados normalizadas num mesmo sistema de referência, não necessariamente em unidades físicas, é usado também para normalizar diferenças entre detectores individuais e geralmente é feita no estágio de geração do produto (L. Paolini *et al.*, 1996).

Neste trabalho, o método de correção radiométrica absoluta usado consistiu na combinação do método “*cross-calibration*” desenvolvido por Volgelmann *et al.* (2001), com o algoritmo de correção atmosférica baseado na aproximação Dark Object Subtraction (DOS) apresentado por Song *et al.* (2001).

3.2.1.3.1. Procedimentos de Correção absoluta

Dark Object Subtraction é o método de correção atmosférica mais simples e ainda assim mais usado para classificação de imagens e estudos de detecção de mudanças e já provou ser tão fiável quanto os outros algoritmos de correção atmosférica (Song *et al.*, 2001).

Este algoritmo assume a existência de objectos com reflectância zero ou infima na superfície da terra (dark objects). Se um *dark object* for encontrado na imagem este devera corresponder ao menor valor digital no histograma de toda a cena, apartir deste mínimo é possível estimar a radiância padrão de toda a cena e assim corrigir os efeitos atmosféricos em toda a imagem (Teillet e Fedosejevs 1995, Song *et al.* 2001).

Quando tratar-se de estudos onde se usa imagens TM e ETM+ e requer-se uma consistência radiométrica entre as imagens, uma especial atenção devera ser tomada devido às diferenças significativas nas respostas dos sensores, pois existe uma grande diferença nas respostas das bandas espectrais dos sensores TM e ETM+ (Taillet *et al.*, 2001).

De modo a reduzir estas diferenças é necessário efectuar uma *cross-calibration* antes mesmo de fazer a correcção radiométrica absoluta, desta forma qualquer discrepância radiométrica entre os sensores será reduzida usando as propriedades radiométricas do ETM+ o que constitue uma vantagem. Desta forma segundo Vogelmann *et al.* (2001) os valores digitais do Landsat TM (L5_Q5) primeiro são convertidos a valores digitais do Landsat ETM+ (L5_Q7) usando a fórmula abaixo e os valores de declive (*slope*) e *intersept* propostos por Vogelmann *et al.* (2001).

$$L5_{Q7} = L5_{Q5}slope + intersept, \text{ (eq: 5)}$$

Os valores de *slope* e *intersept* para *cross-calibration* foram derivados a partir da utilização de uma imagem Landsat TM e uma ETM+ com cerca de 30min de diferença da data que aquisição e o esquema gerado a partir desta calibração pode ser aplicado a quaisquer imagens de qualquer lugar do mundo, isto acontece devido a uma maior aproximação linear na resposta dos sensores.

Com a imagem TM calibrada de acordo com os parâmetros do sensor ETM+ ela já é tratada como se seus parâmetros fossem do sensor ETM+ e a correcção absoluta já pode ser efectuada.

Tabela 2: Valores de Slope e Intercept aplicados para Cross-Calibration (Volgmann *et al.*, 2001).

Band	Slope	Intercept
1	0.9398	4.2934
2	1.7731	4.7289
3	1.5348	3.9796
4	1.4239	7.0320
5	0.9828	7.0185
7	1.3017	7.6568

O método de correcção absoluta baseado na aproximação Dark Object Subtraction consiste em primeiro eliminar ou minimizar os efeitos resultantes da calibração do sensor transformando os valores digitais originais (Q) da imagem em valores da radiância no satélite.

$$L_{sat} = Q_{gain} + offset, \text{ (eq: 6)}$$

Onde L_{sat} é a radiância no satélite, Q é o valor digital da imagem, e $gain$ e $offset$ são os valores do sensor ETM+ da tabela acima e são usados para o sensor TM uma vez que as imagens TM foram calibradas de modo a que sejam equiparadas as do ETM+ (Vogelmann *et al.*, 2001).

Depois é necessário converter os valores de radiância no satélite em valores de reflectância na superfície da terra o que envolve corrigir os efeitos causados pela geometria de iluminação e condições atmosféricas. Para o efeito usamos o método DOS melhorado (Chavez 1996), denotado por DOS3. (Cong *et al.* 2002). Este método inclui o DOS básico com a excepção da transmissão atmosférica pelo meio a partir do sol até a superfície (T_z) que é calculado através da fórmula: $T_z = \exp\left(-\frac{\tau_r}{\cos\theta_z}\right)$, (eq: 7)

Onde: θ_z é o ângulo zenital do sol, e τ_r refere à dispersão dos raios e é caculado de acordo com Kaufman (1989).

$$\tau_r = 0.008569\lambda^{-4}(1+0.0113\lambda^{-2}+0.00013\lambda^{-4}), \text{ (eq: 8)}$$

Onde: λ é o comprimento de onda em cada banda em micrometros.

A equação seguinte mostra o cálculo final que transforma as imagens em valores de reflectância na superfície da terra.

$$\rho = \frac{(L_{sat}-L_{haze})\pi d^2}{E_0 \cos\theta_z T_z}, \text{ (eq: 9)}$$

Onde ρ é a reflectância na superfície da terra, L_{haze} é a radiância atmosférica ou *path radiance* (*haze*), d é a distância do sol em unidades astronómicas, E_0 é a irradiância exoatmosférica, θ_z é o ângulo zenital do sol e T_z corresponde à transmissão do sol para a superfície terrestre.

Tabela 3: valores de Gain e Offset utilizados no método Dark Object Subtraction (Song *et al.*, 2001).

Band	Gain	Offset
1	0.775	26.2
2	0.795	26.4
3	0.619	25.0
4	0.637	25.1
5	0.125	21.1
7	0.043	20.35

Segundo Song *et al.* (2001) L_{haze} pode ser calculado usando a fórmula:

$$L_{haze} = Q_{min}gain + offset - \frac{(0.01\cos\theta_z T_z E_0)}{\pi d^2}, \quad (\text{eq: 10})$$

Essa é a combinação dos métodos *cross-calibration* e *atmospheric correction* para gerar imagens radiometricamente consistentes.

4. PROCESSAMENTO DE IMAGENS E CRIAÇÃO DO MODELO

4.1.Processamento digital de imagens

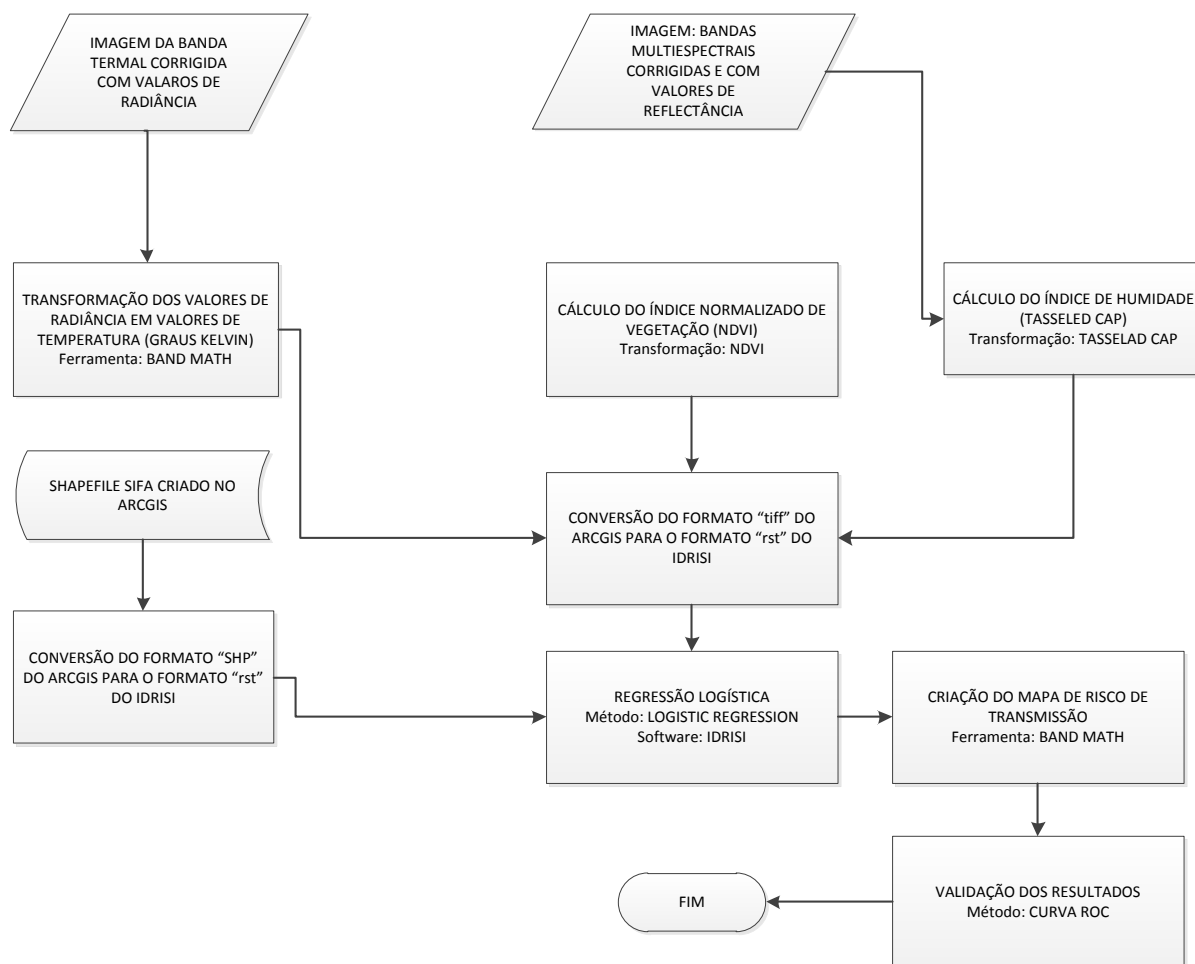


Figura 8: Fluxograma do Processamento digital (Adaptado pelo autor).

4.1.1. Cálculo do Índice de Vegetação por Diferença Normalizada (NDVI)

O NDVI, proposto por Rouse *et al.* (1973), é frequentemente usado para estabelecer relações entre o padrão de evolução da cobertura vegetal ao longo do tempo e também já foi usado para várias outras finalidades como é o caso do estudo do movimento de massas, estudo da humidade dos solos bem como no estudo de incidência de doenças transmitidas por vectores. Este índice é calculado a partir de valores de reflectância das bandas referentes ao espectro do Vermelho e ao Infravermelho próximo, no caso do sensor utilizado neste trabalho, o sensor

Thematic Mapper (TM) a bordo do satélite LANDSAT – 5, estas bandas são correspondentes as bandas 3 e 4 respectivamente.

$$NDVI = \frac{IVP - V}{IVP + V}, \quad (\text{eq: 11})$$

Onde: IVP é a reflectância no espectro eletromagnético do canal infravermelho, V é a reflectância no espectro eletromagnético do canal vermelho.

O índice assume valores entre -1 e 1, sendo que a vegetação possui valores positivos e para corpos de água e áreas úmidas o NDVI tem uma resposta negativa.

Antes do cálculo do NDVI, é necessário que seja feita a transformação dos Números Digitais das bandas 3 e 4 da cena em valores de radiança e a posterior em valores de reflectância. Para transformação em valores de radiança espectral, pode se utilizar a equação matemática proposta por Chander *et al.* 2007:

$$L_i = L_{i,\min} + \left[\frac{(L_{i,\min} - L_{i,\max})}{255} \right] \times NC_i, \quad (\text{eq: 12})$$

Onde: L_i é a radiância espectral na banda i em Watts/(sq.meter* μm *ster), $L_{i,\max}$ e $L_{i,\min}$ são os valores de radiância máxima e mínima na banda i, respectivamente, NC_i é o nível de cinza na banda i.

Enquanto a radiância é um valor quantitativo medido pelos sensores, a transformação desses valores em valores de reflectância facilita de algum modo a comparação entre cenas diferentes de imagem. Essa transformação é feita de modo a remover as diferenças causadas pelo posicionamento do sol bem como a variação da quantidade de energia emitida pelo sol em cada banda. A reflectância pode ser descrita como sendo uma fracção da energia do sol que é emitida pela superfície e pode ser calculada usando a seguinte expressão:

$$R_\lambda = \frac{\pi * L_\lambda * d^2}{E_{sum,\lambda} * \sin(\theta_{SE})}, \quad (\text{eq: 13})$$

Onde: R_λ é o valor da reflectância, L_λ é o valor da radiância descrito anteriormente, d^2 é o quadrado da distância do sol em relação a terra (em unidades astronómicas), $E_{sum,\lambda}$ é a radiância específica emitida pelo sol em cada banda e θ_{SE} é o ângulo de elevação do sol. Abaixo segue a tabela referente à radiância específica emitida pelo sol para cada banda do TM segundo Chander *et al.* (2009).

Tabela 4: Valores de radiância específica emitida pelo sol (Chander *et al.*, 2009).

Banda	$E_{sum,\lambda}$ [Watts / (sq. meter * μm)]
1	1997
2	1812
3	1533
4	1039
5	230.8
7	84.9

Outros valores necessários para esta transformação são a distância do sol (d) e o ângulo de inclinação do sol (θ_{SE}), essas duas variáveis dependem do dia, mês e ano em que a imagem foi adquirida e variam em cada cena. A informação sobre o ângulo de inclinação pode ser encontrada no metadata da imagem como mostra a figura abaixo e a distância do sol pode ser determinada através da tabela Chander *et al.* associada a data de aquisição.

```

CPF_NAME = "L5CPF20080101_20080331.16"
END_GROUP = PRODUCT_METADATA
GROUP = IMAGE_ATTRIBUTES
  CLOUD_COVER = 0.00
  IMAGE_QUALITY = 9
  SUN_AZIMUTH = 77.78626207
  SUN_ELEVATION = 53.51652168
  GROUND_CONTROL_POINTS_MODEL = 146
  GEOMETRIC_RMSE_MODEL = 4.473
  GEOMETRIC_RMSE_MODEL_Y = 2.987
  GEOMETRIC_RMSE_MODEL_X = 3.330
  GROUND_CONTROL_POINTS_VERIFY = 902
  GEOMETRIC_RMSE_VERIFY = 0.259
  GEOMETRIC_RMSE_VERIFY_QUAD_UL = 0.182
  GEOMETRIC_RMSE_VERIFY_QUAD_UR = 0.224
  GEOMETRIC_RMSE_VERIFY_QUAD_LL = 0.310
  GEOMETRIC_RMSE_VERIFY_QUAD_LR = 0.000
END_GROUP = IMAGE_ATTRIBUTES
GROUP = MIN_MAX_RADIANCE
  RADIANCE_MAXIMUM_BAND_1 = 193.000
  RADIANCE_MINIMUM_BAND_1 = -1.520
  RADIANCE_MAXIMUM_BAND_2 = 365.000
  RADIANCE_MINIMUM_BAND_2 = -2.840
  RADIANCE_MAXIMUM_BAND_3 = 264.000
  RADIANCE_MINIMUM_BAND_3 = -1.170
  RADIANCE_MAXIMUM_BAND_4 = 221.000
  RADIANCE_MINIMUM_BAND_4 = -1.510
  RADIANCE_MAXIMUM_BAND_5 = 30.200
  RADIANCE_MINIMUM_BAND_5 = -0.370
  RADIANCE_MAXIMUM_BAND_6 = 15.303
  RADIANCE_MINIMUM_BAND_6 = 1.238
  RADIANCE_MAXIMUM_BAND_7 = 16.500
  RADIANCE_MINIMUM_BAND_7 = -0.150
END_GROUP = MIN_MAX_RADIANCE
GROUP = MIN_MAX_PIXEL_VALUE

```

Figura 9: Metadata da imagem Landsat TM utilizada no estudo.

É importante notar que os valores de reflectância deveriam ser positivos, mas, não obstante, durante o processo de conversão dos valores de Níveis de Cinza para valores de reflectância existe uma pequena probabilidade de aparecerem alguns valores de reflectância negativos, estes valores não são verdadeiros e devem ser transformados em zero usando a expressão abaixo na ferramenta Raster Calculation do ArcMap.

Reflectância_corrigida = CON ([reflectância]<0.0, 0.0, [reflectância]).

Uma vez transformados os valores dos Números digitais em valores de Radiância e Reflectância no topo da atmosfera já se pode calcular o índice NDVI e o resultado é apresentado na figura abaixo.

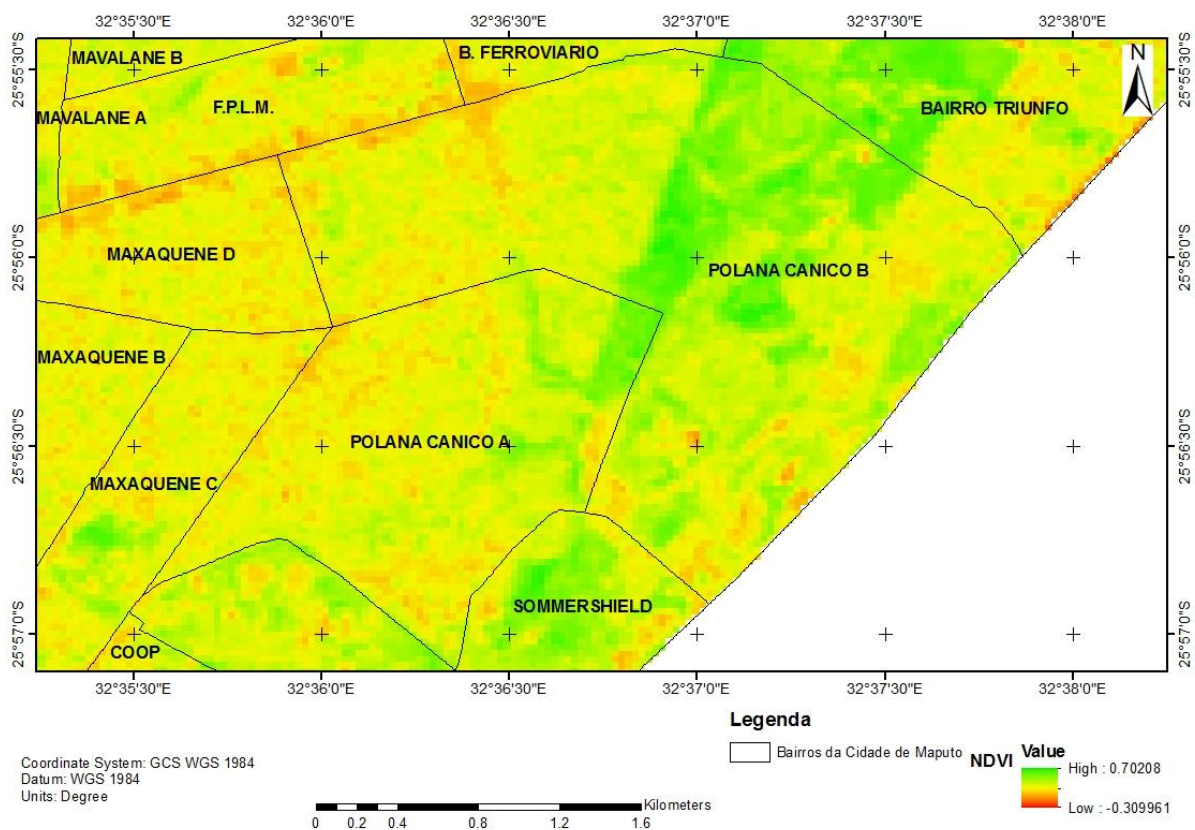


Figura 10: Mapa do índice de vegetação por diferença normalizada (Computada pelo autor).

4.1.2. Cálculo do Índice Tasseled Cap

A transformação tasseled cap foi concebida para o estudo de regiões agrícolas nos Estados Unidos da América e era originalmente aplicada a sensores MSS do Landsat (Crist e Cicone, 1984), esta transformação consiste basicamente em se obter novas bandas através de combinação linear das bandas originais. Desta forma a maioria das informações é disposta em

relação a novos eixos que estão relacionados diretamente a características físicas da cena. Crist e Cicone (1984) desenvolveram um estudo utilizando esta transformação para o sensor TM do Landsat, neste estudo os autores verificaram que nas seis bandas do TM há um novo componente além dos componentes brilho (brightness) e verde (greenness) já definidos pelo MSS, este novo componente corresponderia a humidade (wetness) e estaria relacionado ao conteúdo de humidade da vegetação e do solo, nitidamente vinculado a banda do infravermelho médio.

De forma resumida pode se dizer que o índice Tasseled Cap permite nos estimar o brilho, o verde das plantas e a humidade do solo e das plantas e essas três componentes podem ser calculados usando a expressão:

$$Tas.cap_i = (coef1 * banda1) + (coef2 * banda2) + (coef3 * banda3) + (coef4 * banda4) + (coef5 * banda5) + (coef7 * banda7), \quad (eq: 14)$$

Onde: $Tas.cap_i$ é o índice tasseled cap calculado para brilho, verde e humidade dependendo dos coeficientes usados. Segundo Huang *et al.* (2002) os coeficientes da equação para o cálculo da humidade são os que seguem na tabela abaixo.

Tabela 5: Coeficientes da equação para o cálculo da humidade (Huang *et al.*, 2002).

Índice	Banda 1	Banda 2	Banda 3	Banda 4	Banda 5	Banda 7
Brilho	0.3561	0.3972	0.3904	0.6966	0.2286	0.1596
Verde	-0.3344	-0.3544	-0.4556	0.6966	-0.0242	-0.2630
Humidade	0.2626	0.2141	0.0926	0.0656	-0.7629	-0.5388

É importante mencionar que para o cálculo do Tasseled Cap é necessário que os valores dos níveis de cinza sejam transformados em valores de reflectância, desta forma, o cálculo deste índice irá obedecer todos os parametros preconizados acima no cálculo do NDVI e o resultado obtido será um mapa temático composto por três bandas cada uma referente ao brilho, verde e humidade, segundo Chuvieco (1990) uma das vantagens desta transformação sobre a análise de componentes principais é no que diz respeito a sua interpretabilidade física, isto porque as componentes deduzidas a partir da Tasseled Cap se baseiam nas características das bandas espectrais em consideração. Este resultado é apresentado na figura abaixo.

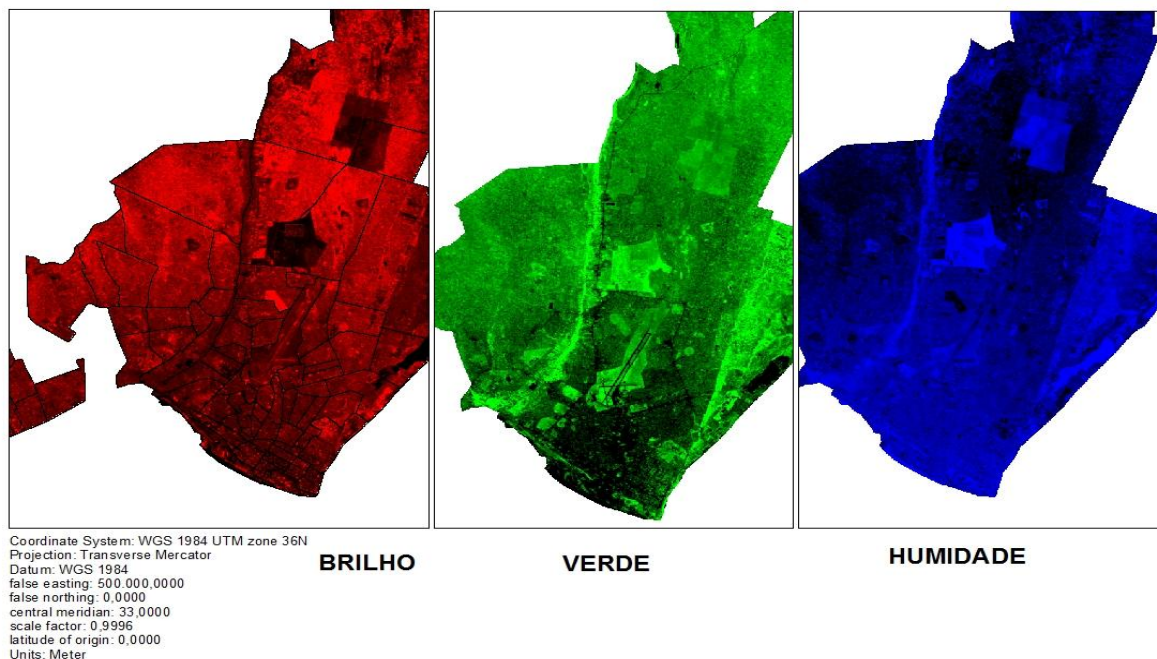


Figura 11: índice Tasseled Cap com as três componentes de Brilho, Verde e Humidade (Computada pelo autor).

4.1.3. Cálculo da Temperatura da Superfície

A temperatura é uma variável ambiental associada a transmissão e a ploriferação dos vectores transmissores de doenças visto que alguns desses vectores obedecem algumas condições de temperatura para completarem o seu ciclo de vida, ou seja, eles só conseguem reproduzir-se em certas temperaturas ambientais (Gemperli *et al.*, 2006). Os vectores transmissores da malária também não fogem a regra, segundo o modelo proposto por Haug *et al.* (2002) o intervalo ideal para a transmissão bem como da ploriferação do vector varia de $19.5^{\circ}\text{C} + \text{desvio padrão da temperatura anual}$, e quanto maior for a temperatura maior será a transmissão, chegando a atingir o seu pico nos 32°C e reduzindo em temperaturas mais elevadas.

Para o cálculo da temperatura na superfície usou-se a banda termal do sensor TM, mas antes mesmo de fazer o cálculo da temperatura foi necessário aplicar a correcção atmosférica e transformar os valores de níveis de cinza da imagem na banda 6 (termal) em valores de radiância usando os métodos descritos anteriormente.

Após obter a imagem com os valores de radiância transformou-se o resultado em valores de temperatura em graus kelvin usando a fórmula (Coelho, 2013):

$$T_{(\text{kelvin})} = K_2 / \ln\left(\frac{K_1 * E}{B_6 \text{Rad}} + 1\right), \text{ (eq: 15)}$$

Onde: $T_{(\text{kelvin})}$ é a temperatura na superfície em graus kelvin, K_1 e K_2 são constantes, E é a emissividade na banda termal (0.95) e B_6 é a radiância da banda 6. Abaixo está representada uma tabela das constantes “K” para os sensores TM e ETM+.

Tabela 6: valores das constantes K_1 e K_2 utilizadas para a conversão da temperatura em graus Kelvin (www.processamento.digital.br).

Constantes	Landsat TM	Landsat ETM+
K1	607.76	666.09
K2	1260.56	1282.71

Após obter a imagem com os valores em graus kelvin estes são transformados em valores da temperatura na superfície em graus centígrados usando a transformação:

$$\text{Temperatura } ^\circ\text{C} = \text{Temperatura } ^\circ\text{K} - 273.15, \text{ (eq: 16)}$$

As duas transformações descritas acima são possíveis de efectuar usando a ferramenta “Band Math” no Envi software. Os resultados desta etapa são apresentados na figura abaixo.

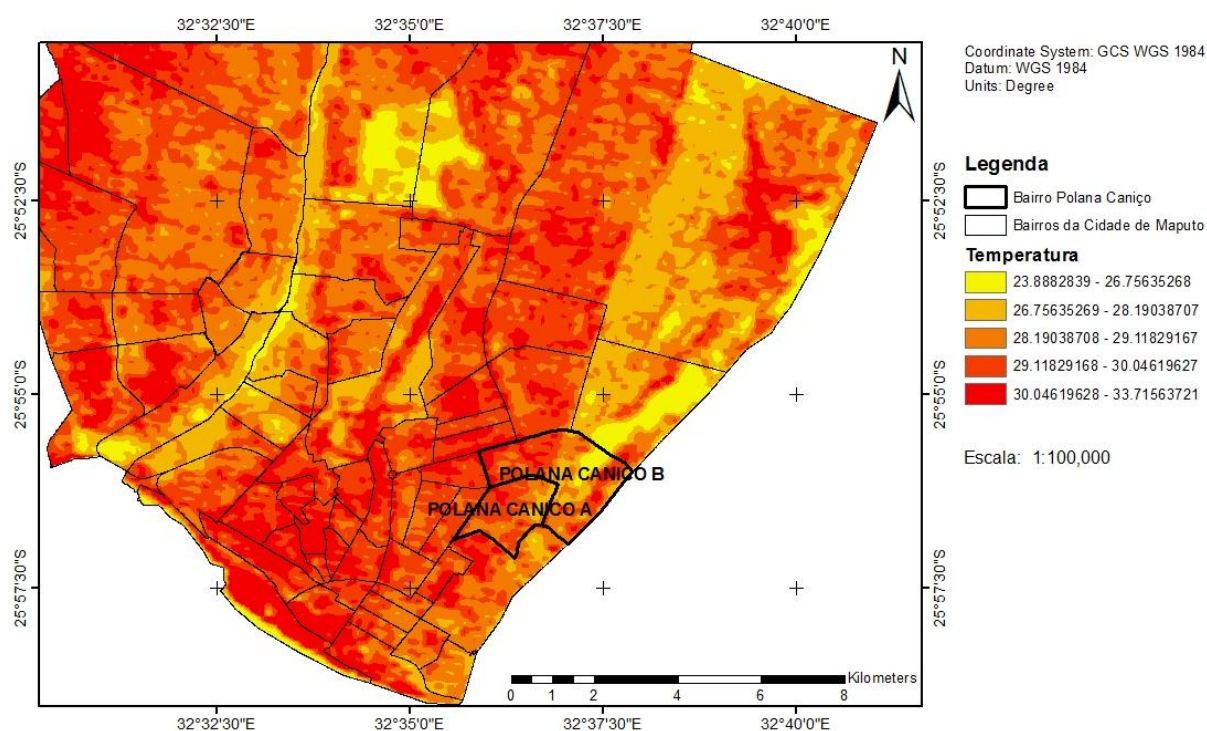


Figura 12: Temperatura da superfície da área de estudo (Computada pelo autor).

4.1.4. Regressão Logística e Análise

A regressão logística vem sendo utilizada nas mais diversas áreas da ciência. Este método estuda a relação entre uma variável resposta e uma ou mais variáveis independentes e possui uma estrutura apropriada para analisar o comportamento de uma variável dependente categórica (Penha, 2002).

Em regressão logística, a variável dependente é discreta, tal qual o uso e ocupação do solo, por exemplo. Se a variável dependente é dicotômica, o valor de Y toma apenas dois valores 1 (presença) e 0 (ausência). Ao estimarmos mudanças na cobertura florestal, por exemplo, Y=1 representaria eventos nos quais a floresta se modificou, enquanto que Y=0 representaria eventos nos quais as florestas permanecem de mesma forma no período em questão (Eastman, 1997).

Neste caso concreto, Y=1 representa áreas onde houve confirmação de casos de malária e Y=0 representa áreas onde não houve malária.

No caso de três variáveis independentes, a regressão logística é definida da seguinte forma:

$$\text{logit}(p) = a + b_1 \cdot x_1 + b_2 \cdot x_2 + b_3 \cdot x_3, \quad (\text{eq: 17})$$

Onde, $\text{logit}(p) = \ln(p/(1-p))$, p é a variável dependente, a probabilidade de que um determinado evento tenha ocorrido; x1, x2, e x3 são variáveis independentes; b1, b2 e b3 são coeficientes das variáveis independentes. O intercepto (a) representa o valor da equação quando os valores dos coeficientes das variáveis independentes forem iguais à zero. E o parâmetro coeficientes indica a mudança em $\text{logit}(p)$ para um incremento de uma unidade na variável independente correspondente. A transformação logística de dados dicotômicos garante que a variável dependente da regressão seja contínua, e que a nova variável (a probabilidade de ocorrência de um determinado fenômeno) seja irrestrita, sem fronteiras. Além do mais, a transformação também garante que as estimativas de probabilidade sejam contínuas variando entre 0 e 1 (Eastman, 1997).

4.1.4.1. Parâmetros necessários para realização da Regressão Logística

Em IDRISI o módulo LOGITREG produz regressão logística e estimativas a partir de imagens ou arquivos de dados. LOGTREG demanda que se indique o tipo de regressão a ser produzido,

entre imagens ou arquivos de dados. A variável dependente deve ser uma imagem cujo formato é real binário, demonstrando probabilidades que oscilam entre 0 e 1. Já as imagens independentes devem estar em formato real. A imagem mascara, quando utilizada, deve estar em formato byte-binário com 1 em todas as células que deverão compor a regressão e 0 nos demais locais (Eastman, 2003).

É também necessário estabelecer um nível de confiança que oscila entre 0 e 1 (a medida em que eventos futuros corresponderão à imagem indicada). Outra tarefa importante é definir o tamanho da amostra para o cálculo de probabilidade (número inteiro) a partir dos quais serão calculadas probabilidades associadas a todos os pontos (Eastman, 2003).

Segundo Eastman (2003), para a realização da análise da regressão, ou seja, para determinar a relação logística usa-se o módulo LOGITREG do IDRISI, este módulo utiliza para o efeito, o método dos mínimos quadrados com introdução de pesos que segue os seguintes procedimentos:

1) Determina a equação de regressão através da fórmula: $L_i = \text{logit}(p_i) = \ln(p_i / (1 - p_i))$, (eq: 18)

Onde p_i é a probabilidade para a observação i ;

2). Introduz os pesos para cada observação, para variáveis dependentes e independentes usando a equação:

$$W_i = \sqrt{N_i * p_i * (1 - p_i)}, \quad (\text{eq: 19})$$

Onde, W_i é o peso para cada observação i , N_i é o tamanho da amostra a partir da qual a probabilidade para cada observação foi calculada;

(3). Aplica-se o método dos quadrados mínimos à seguinte equação linear:

$$W_i * L_i = \sum (W_i * b_k * X_{ik}), \quad (\text{eq: 20})$$

Onde, k é o número de variáveis independentes, X_{ik} é o valor da variável k para cada observação i , b_k é o coeficiente para a variável k

(4). Para estimar a probabilidade p_i a partir do L_i predito para cada observação i :

$$P_i = \exp(L_i) / (1 + \exp(L_i)), \quad (\text{eq: 21}).$$

4.1.4.2. Coeficientes e constantes

O coeficiente da regressão logística indica o quanto aumenta a probabilidade de ocorrência de um evento para o aumento de uma unidade na variável independente. O coeficiente pode ser positivo ou negativo. No caso de um coeficiente positivo, quanto maior for seu valor, maior será o poder preditivo da variável independente sobre a probabilidade de ocorrência de um evento. No entanto, a probabilidade de 0 a 1 é resultado de uma função não linear da probabilidade de ocorrência de um evento (Ventocinque *et al.*, 2007).

Foi aplicado o módulo LOGITREG do idrissi para o cálculo dos coeficientes das três variáveis em estudo e os resultados são representados na equação abaixo, onde os resultados mostraram que a humidade tem maior valor preditivo e com um índice positivo significando que quanto maior for a humidade maior será a probabilidade de ocorrência. Por sua vez o NDVI com um coeficiente aproximado de 0.081485 também contribui de certa forma para a prevalência do fenómeno em estudo e com um índice positivo entre 0 e 1 indicando uma correlação não linear, ou seja, dentro do intervalo dos valores desta variável, existe um certo intervalo em que a sua correlação com a malária seja linear. Já para o caso da temperatura o coeficiente também se encontra no intervalo entre 0 e 1 indica uma correlação não linear entre a variável dependente e a variável temperatura, não significando com isso a não contribuição desta variável para a ocorrência da malária.

$$\text{logit}(\text{Malaria}) = -12.7598 + 0.081485 * \text{NDVI} + 2.800355 * \text{humidade} + 0.384548 * \text{temperatura},$$

(eq: 22)

4.1.4.3. Criação do Mapa de probabilidade de ocorrência através dos resultados da Regressão Logística

A espacialização da regressão dá como resultado um mapa temático com as probabilidades de ocorrência do fenómeno em causa. Esta foi feita no Envi software através do módulo *Band math* introduzindo a expressão:

$$\frac{1}{1 + e^{-(12.7598 + 0.081485 * B1 + 2.800355 * B2 + 0.384548 * B3)}}, \quad (\text{eq: 23})$$

onde *B1*, *B2* e *B3* correspondem ao NDVI, Humidade e Temperatura respectivamente. Foi gravada a imagem no formato padrão do Arcgis e classificada em intervalos de probabilidade. O resultado esta representado na figura abaixo.

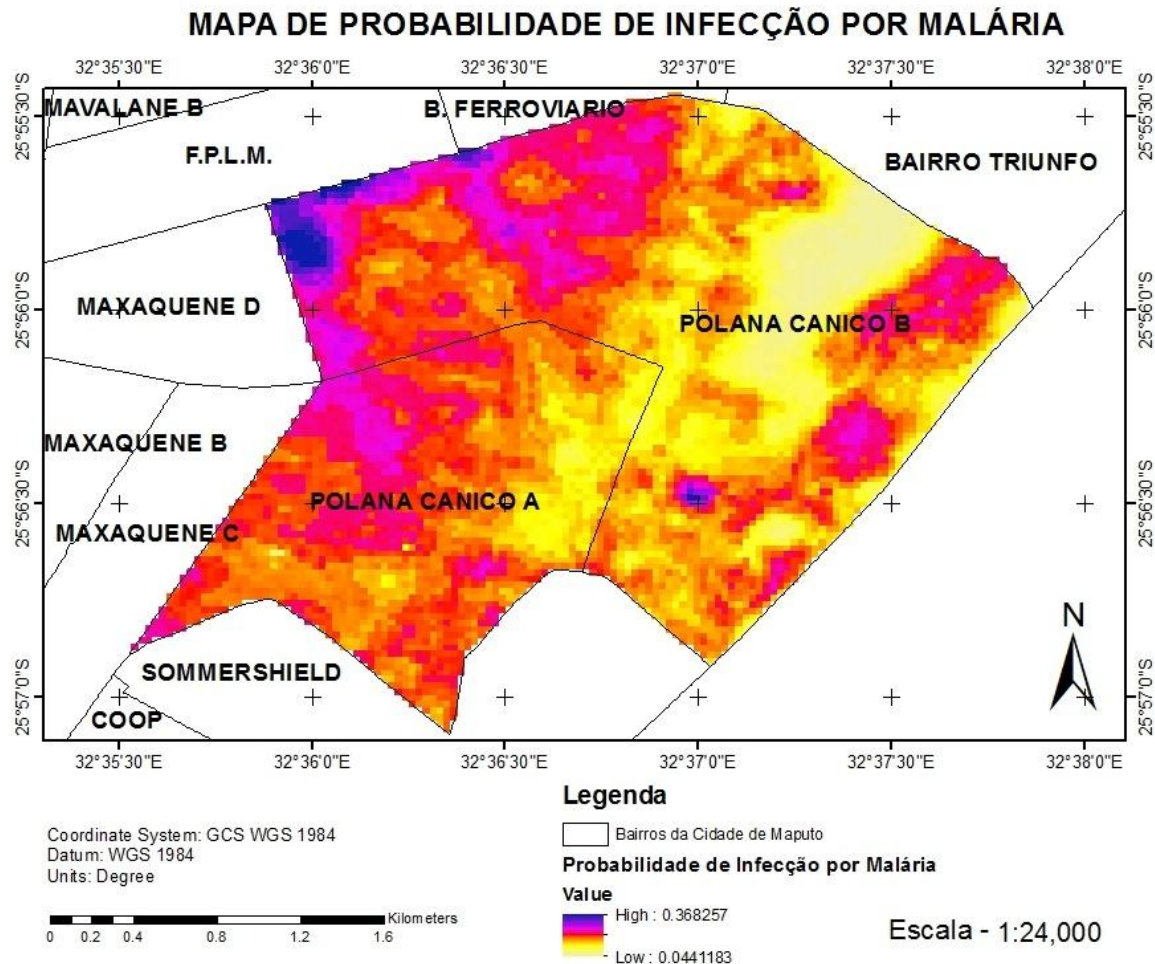


Figura 13: Imagem de probabilidade de ocorrência da malária no bairro Polana Caniço (Computada pelo autor).

4.1.4.4. Razão de chances (odds ratio)

A razão de chances permite conhecer quais chances um evento tem de acontecer se, sob as mesmas condições, ele não acontecer. Ou seja, razão de chances é uma medida de associação e expressa a aproximação do quanto é mais provável (ou improvável) para o resultado estar presente entre aqueles com $x = 1$ do que entre aqueles com $x = 0$. Por exemplo, se y denota a presença ou ausência de uma determinada espécie e x denota se a área tem ou não tem floresta, o Odds = 2 indica que a presença daquela espécie é duas vezes mais esperada em áreas com floresta do que em áreas sem floresta. Ou seja, a presença de floresta é muito importante para aumentar a chance de ocorrência daquela espécie. A razão de chances de resposta é dada por

$p/(1-p)$ onde p é a probabilidade de resposta, e a razão de chances é o fator multiplicativo de mudança de estado de y quando a variável independente aumenta uma unidade (Hosmer e Lemeshow, 1989).

Neste caso temos um valor ajustado da razão de chances de 4.612 indicando que as áreas sem confirmação de malária sob as mesmas condições ambientais, ou seja, com mesmo NDVI, temperatura e humidade das áreas com confirmação de malária tem 4 vezes chances de existir malária.

Adjusted Odds Ratio = 4.0612

True Positive = 87.6471%

False Positive = 7.1983%

4.2. Validação do modelo

Uma vez definido o modelo, é necessário testar a sua validade. Em regressão logística há uma série de gráficos, testes de ajuste, e outras medidas para assegurar a validade do modelo. Estas estatísticas permitem identificar as variáveis que não se ajustam bem, ou que têm forte influência sobre a estimativa dos parâmetros. Uma das formas mais comuns de se avaliar o modelo como um todo, é por meio da estatística de Likelihood-Ratio. Esta estatística testa a hipótese de que todos os coeficientes, menos a constante, são iguais a 0. A significância da estatística de Likelihood-Ratio (LR) é testada utilizando a distribuição do X^2 com os graus de liberdade iguais ao número de variáveis independentes no modelo, não incluindo a constante. O teste de Likelihood-Ratio, ou teste G, é calculado utilizando o valor da estatística de log likelihood do modelo saturado e do insaturado. Tipicamente, o modelo saturado contém o conjunto de variáveis analisadas e o modelo insaturado omite um subconjunto selecionado, embora outras restrições sejam possíveis (Venticinque *et al.*, 2007).

A estatística do teste é duas vezes a diferença do Likelihood-Ratio do modelo saturado para o insaturado e é testada com a distribuição do X^2 , sendo o grau de liberdade igual ao número de restrições impostas. Se um modelo contém uma constante, podemos calcular um teste de Likelihood-Ratio da hipótese nula em que todos os coeficientes, exceto a constante, são iguais a zero.

A fórmula da estatística G usada para testar o modelo é a seguinte:

$$G = 2*[LL(N)-LL(0)], \quad (\text{eq: 24})$$

Onde: $LL(N)$ = log likelihood do modelo saturado (todas as variáveis inclusas);

$LL(0)$ = log likelihood do modelo insaturado (somente a constante inclusa).

Quando fazemos essa subtração, estamos olhando, simplesmente, o quanto as variáveis estão causando mudanças nas probabilidades de ocorrência de um evento e se essas mudanças são maiores que esperadas ao acaso. Para o caso do fenómeno em estudo, se formularmos a hipótese de que a humidade não tem influência na predição da malária, procede-se da seguinte maneira:

Presença de malária = CONSTANTE + ndvi + temperatura + humidade (saturado);

Presença de malária = CONSTANTE + ndvi + temperatura (insaturado).

Agora podemos entender a variação que é explicada pela humidade, entendendo quanto perdemos de poder de explicação ao removermos essa variável do modelo. Para todas as variáveis essa operação pode ser realizada da seguinte forma:

Efeito da humidade = $G(\text{insaturado}) - G(\text{saturado})$, com 3 – 2 graus de liberdade;

Efeito da temperatura = $G(\text{insaturado}) - G(\text{saturado})$, com 3 – 2 graus de liberdade;

Efeito da Ndzi = $G(\text{insaturado}) - G(\text{saturado})$, com 3 – 2 graus de liberdade.

4.2.1. Testes Estatísticos de ajuste do Modelo às Observações

4.2.1.1. Rho2 de McFadden

Rho2 de McFadden é uma transformação da estatística de LR para imitar um R2 da regressão linear. Seus valores estão sempre entre 0 e 1 e, quanto mais alto, melhor é o ajuste do modelo aos resultados. Entretanto, o Rho2 de McFadden tende a ser muito mais baixo que R2. Porém, baixos valores não implicam, necessariamente, um ajuste pobre. Valores entre 0,2 e 0,4 são considerados satisfatórios (Hensher & Johnson, 1981).

McFadden / 0.2185

Magelkerke / 0.0244

4.2.1.2. Método R2 (ROC)

O módulo ROC do inglês *Relative Operating Characteristic* é um excelente método para avaliar a validade de um modelo que prevê o local da ocorrência de uma determinada classe, comparando uma imagem que descreve a aptidão, probabilidade da classe de ocorrência, isto é, a imagem de entrada e uma imagem booleana mostrando onde realmente existe essa classe, ou seja, a imagem de referência (Venticinque, 2007).

Neste trabalho utilizamos o ROC para comparar uma imagem de probabilidade modelada para ocorrência da malária contra uma imagem de ocorrência real da malária no bairro da polana caniço.

O módulo ROC oferece uma análise estatística que permite avaliar quão bem concentrada está a categoria de interesse nos locais de relativamente alta aptidão para a ocorrência desta categoria, e desta forma permite-nos avaliar a concordância entre o par de mapas no que diz respeito a localização das células em uma categoria. Assim, a análise ROC é útil para casos em que o investigador quer avaliar quão bem o mapa de aptidão retrata a localização de uma determinada classe ou categoria, mas não tem uma estimativa da quantidade da categoria em estudo (Venticinque, 2007).

O resultado desta operação é um arquivo de texto informando o valor ROC, bem como as coordenadas dos pontos da curva ROC que são usadas para calcular o valor do ROC. Um valor de ROC igual a 1 indica que existe uma concordância espacial perfeita entre o mapa de classe e o mapa de aptidão enquanto um valor ROC de 0,5 é entendido como um resultado esperado ao acaso (Eastman, 2003).

4.2.1.2.1. Requisitos para realização do ROC

A Imagem de entrada deve estar no formato binário real que mostra uma variável quantitativa contínua, em que valores mais altos indicam uma maior probabilidade de que a classe de interesse está presente. A imagem de referência mostra uma variável booleana da ocorrência real da classe de interesse. Nesta imagem, o valor de 1 indica a classe de interesse está presente, e 0 indica que a classe de interesse está ausente (Eastman, 2003).

4.2.1.2.2. Resultados da operação ROC

ROC é uma estatística resumo derivada de várias tabelas de contingência dois-a-dois com base numa comparação da imagem simulada e a imagem de referência. Cada tabela corresponde a um limite diferente no mapa de aptidão.

O resultado é constituído do valor ROC e o dos valores dos verdadeiros positivos e valores de falsos positivos para cada limite que constituem a curva a partir da qual o ROC é calculado. O valor do verdadeiro positivo é derivado de $A / (A + C)$, enquanto o valor de falso positivo é derivado de $B / (B + D)$, onde A, B, C, D são contagem de *pixels* na tabela de contingência para cada limiar. Veja o Anexo 1. Segundo Eastman (2001), os valores de N (n), P (p), P (n), N (p) dependem apenas do mapa de referência. As equações para os três componentes relacionados são: $\text{PerfectChance} = N(n)$, $\text{PerfectQuantity} = N(p) - N(n)$, $P = \text{perfeito}(p) - N(p)$. Os valores de M (m), N (m), P (m), H (p), e H (n) podem ser usados para examinar a concordância entre dois mapas categóricos. Portanto, eles são diferentes para cada limiar por comparar o mapa de referência com o mapa de entrada que foi reclassificado como estando acima ou abaixo do limiar. Estes sete pontos, [N (n), N (m), H (m), P (m), P (p), H (n) e H (p)] dão origem a todas as outras estatísticas na parte inferior da saída ROC, especificamente: Kno, Klocation, Kquantity, Kstandard, CorrectChance, CorrectQuantity, CorrectLocation, ErrorLocation e ErrorQuantity. A figura abaixo mostra o gráfico ROC do estudo de ocorrência de malária no bairro da polana caniço. Um ponto para cada limite que é desenhado com valores de sensibilidade no eixo vertical e valores de especificidade no eixo horizontal.




Figura 14: Curva ROC do modelo em estudo, desenhada no Microsoft excel 2012 (Computada pelo autor).

A estatística de ROC representa a área sob a curva que liga os pontos. IDRISI utiliza a regra trapezoidal de cálculo integral para calcular a área, em que x_i é a taxa de falsos positivos de limiar i , y_i é a taxa de verdadeiros positivos para limiar i , e $n + 1$ é o número de limiares (veja a equação abaixo).

$$AreaUnderCurve = \sum_{i=1}^n [x_{i+1} - x_i] \times [y_i + (y_{i+1} - y_i)/2], \quad (eq: \quad 25)$$

A linha diagonal a preto deriva de uma imagem de entrada em que as localizações dos valores de imagem foram distribuídos aleatoriamente, ou seja, o resultado é esperado acaso (ROC = 0,50). A outra linha (Curva) deriva do modelo aplicado neste trabalho (ROC = 0,798).

4.2.1.2.3. Criação do Mapa de Risco de transmissão da malária

Para a criação do mapa de risco de infecção por malária utilizou-se a metodologia de Zhou *et al.* 2014 que preconiza que todas as áreas com uma probabilidade inferior que a prevalência média real tem um baixo risco de infecção por malária e todas as áreas com a probabilidade superior a prevalência real da doença tem um risco alto.

Considerando uma prevalência média de 9.7% (IIM, 2007), esta abordagem permitiu-nos gerar quatro padrões de risco de infecção por malária, sendo o risco BAIXO aquele cuja probabilidade esta abaixo dos 9% e um padrão ALTO – MODERADO, aquele em que a probabilidade esta ligeiramente acima dos 9%, um padrão ALTO aquele em que as áreas estão acima dos 9% bem como suas regiões circunvizinhas e um padrão MUITO ALTO aquele em que a prevalência está muito acima dos 9% e são circundadas pelas zonas de risco alto.

Estes resultados mostraram uma distribuição de 15% da área do bairro da Polana Caniço tem Baixo risco de ser infectado pela malária, 42% com um risco Alto-moderado, 40% com Alto risco e 3% com o padrão Muito alto está numa área considerada critica para a transmissão da malária. O bairro da Polana Caniço B apresenta a maior porção de área com o padrão de infecção baixo com cerca de 20% do total da área desta secção por sua vez o bairro da Polana Caniço A apresenta a maior porção de área com o padrão Alto-moderado e Alto com cerca de 44 e 49% respectivamente o que torna este bairro mais propenso a transmissão de malária relativamente ao bairro da polana caniço B. Não obstante as porções de área mais críticas para a transmissão estão colizados no bairro da polana caniço B em que cerca de 4% da área desta

secção do bairro tem o padrão de transmissão Muito-Alto. O mapa abaixo mostra a distribuição espacial dos padrões de risco de infecção por malária no bairro da Polana Caniço.

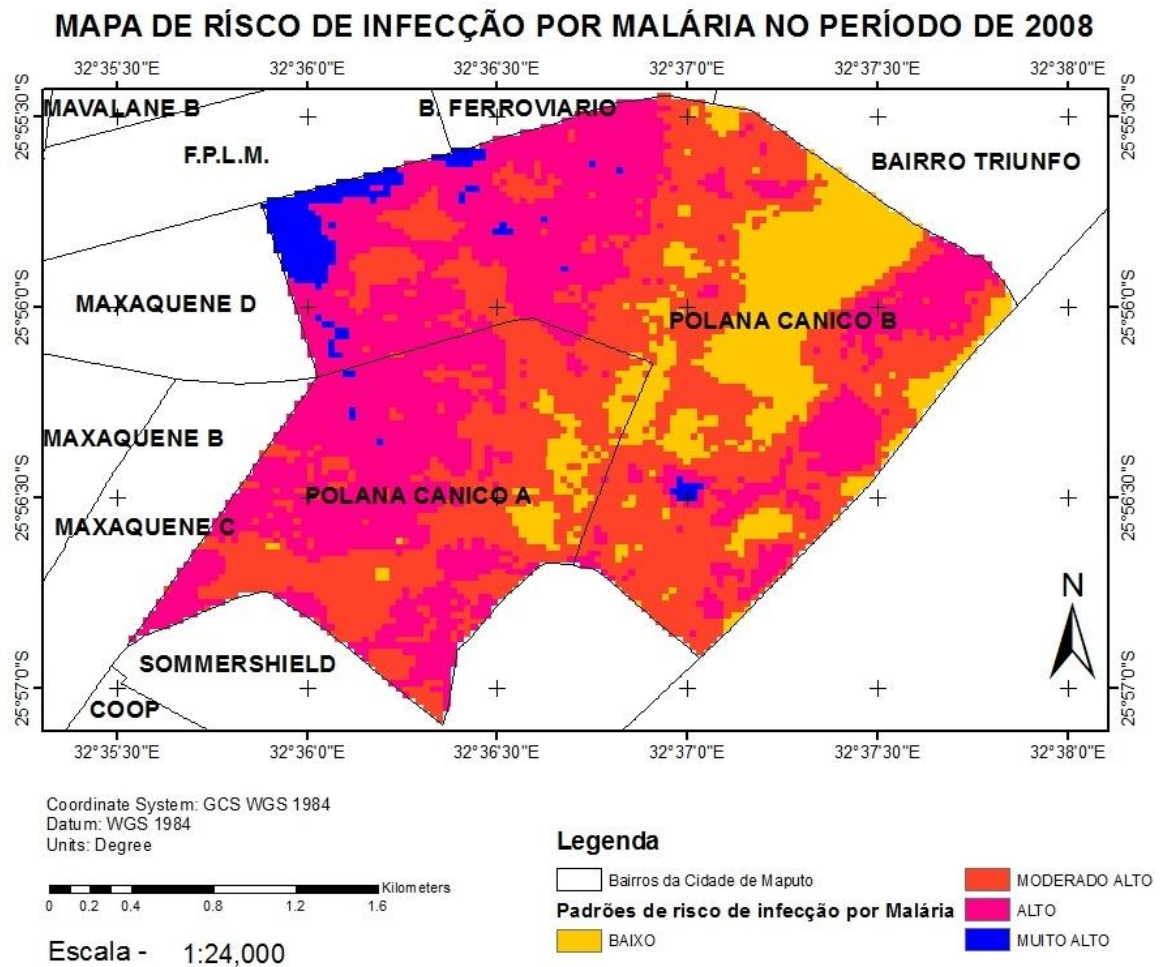


Figura 15: Mapa da distribuição espacial dos padrões de risco de infecção por malária (Computada pelo autor).

CAPITULO V

5. CONCLUSÕES

5.1.Discução e Resultados

Para a sobrevivência e a circulação de transmissores primários da malária, especialmente do *Anopheles gambiae*, são ambientes propícios a existência de coleções de água, uma temperatura da superfície favorável variando dos 24°C aos 32°C, uma humidade relativa elevada e vários outros factores que propiciam a intensidade deste fenómeno e viabilizam a permanência de reservatórios de *Plasmodium*.

Neste estudo, foram realizadas análises espaciais mais detalhadas, o que facilitou a identificação dos diversos factores implicados na transmissão da malária numa das zonas peri-urbanas do município de Maputo. Foram identificados e utilizados 3 factores chave para a predição da ocorrência da malária, através dos quais foi possível gerar uma equação com os pesos de cada uma das variáveis na predição da ocorrência da malária e esta equação por sua vez foi transformada em imagem de probabilidades permitindo estimar a probabilidade de ocorrência da malária no bairro da Polana Caniço, para além de que, possibilitou descobrir onde a transmissão era mais acentuada entre os dois bairros da Polana Caniço A e Polana Caniço B.

Foram utilizados alguns métodos de processamento digital de imagens tais como a correção geométrica, correção atmosférica usando o método *Dark Object Subtraction* e combinada com o método de correção radiométrica *Cross Calibration* e demonstraram ser métodos eficientes para trabalhos de precisão. A correção atmosférica na banda 6 (termal) permitiu-nos calcular a temperatura da superfície da área de estudo e que foi a posterior usada para a criação do modelo juntamente com as imagens dos índices de humidade e de vegetação que também foram obtidos através de imagens que sofreram essas correções.

A análise de regressão logística indicou haver uma associação entre a ocorrência da malária e as variáveis usadas no modelo, e para o efeito este método usou uma imagem dependente e dicotómica “ocorrência de malária” com valores de 1 a representarem áreas com ocorrência de malária e zero para áreas de ausência de malária e o resultado desta operação foi de:

$$\text{logit}P(P(X)/1-P(X)) = -12.7598 + 0.081485 * NDVI + 2.800355 * \text{humidade} + 0.384548 * \text{temperatura}, \quad (\text{eq: 26})$$

de salientar que para a criação da imagem de probabilidades considera-se a equação:

$$P(X) = \frac{1}{1 + e^{-(12.7598 + 0.081485 \cdot NDVI + 2.800355 \cdot humidade + 0.384548 \cdot temperatura)}}, \quad (\text{eq: 27})$$

Que produz uma imagem de probabilidades de ocorrência da malária.

O risco de transmissão da malária que constitui, as áreas em habitação e com probabilidade de ocorrência de malária, para o caso do bairro da polana caniço em que a maior parte da porção da terra é habitável não irá diferir muito da imagem de probabilidade de ocorrência de malária, ou então irá constituir a intercessão entre a imagem de probabilidade de ocorrência do fenómeno e uma imagem de distribuição da população da área de estudo.

A mesma metodologia usada neste trabalho foi previamente usada por William (1994), Lambin (2003), Mendes (2011) e vários outros pesquisadores e demonstrou que a imagem TM é eficiente para mapear a vegetação com o objectivo de discriminar mudanças de cobertura vegetal, uso da terra e ocorrência de espécies e fenómenos da terra.

Para a validação do modelo foi considerado o modelo R2 (ROC) que retornou um valor de 0.798 mostrando um bom ajuste das observações efectuadas. Estes resultados revelaram que o bairro da Polana caniço A está mais propenso a transmissão da malária com cerca de 93% do total da sua área em comparação com o bairro da Polana Caniço B com apenas 80% do total de sua área de cobertura.

5.2. Conclusão

Foram obtidos bons resultados com a utilização de imagens orbitais do satélite TM LANDSAT5 para mapear as variações do NDVI, Temperatura de superfície e o índice de humidade Tassellad Cap, sendo estes dados importantes, pois a malária está relacionada com as alterações ambientais e factores climáticos. A maior distribuição do padrão Muito-alto da malária na região da polana caniço B pode estar relacionada com a ocupação desordenada da terra, e condições ambientais relacionadas à presença de charcos de água vegetação aquática, esgotos ao ar livre, que podem ser observados neste bairro, e variáveis como a temperatura e precipitação que criam condições adequadas para a ploriferação do *Anophelis Gambiae*.

As imagens de satélite e SIG através deste modelo, permitiram criar mapas de destribuição espacial da probabilidade de se adquirir malária. Esses mapas foram criados apenas com a imagem de fevereiro de 2008, por sinal a única desponivel do TM-Landsat5 para a época chuvosa naquele ano, era desejavel que se utilizesse imagens dos meses no final da época chuvosa ou então em toda a estação de chuvas para nos permitir uma comparação dos resultados obtidos. Outro factor importante observado é que os bairros mais próximos da área de estudo também apresantam características não muito destintas das características da área de estudo, o que nos leva a crer que o modelo aqui desenvolvido pederá servir também para os bairros em causa, havendo uma necessidade de se desenvolver um modelo semelhante para se fazer uma análise comparativa dos resultados.

Bibliografia

- Alföldi, T.T. (1996). **Introdução às imagens digitais e técnicas de análise digital**. Canada Centre for Remote Sensing Natural Resources.
- Arcanjo, A.R. (2004). **Estudo da aplicabilidade dos testes imunocromatográficos como diagnóstico da malária na Atenção Básica de Saúde no município de Manaus**. Tese de Licenciatura. 90pp. Manaus. Universidade Estadual do Amazonas, Fundação de Medicina Tropical do Amazonas.
- Caloz, R. et Collet, C., 2001, Précis de télédétection, Volume 3 : Traitements numériques d'images de télédétection, Chapitre 5, Presse de l'Université du Québec, Ste Foy, Québec, Canada, pp. 76-105.
- Câmara G., Davis C., Monteiro A.M.V (2001), Introdução à Ciência da Geoinformação, INPE, p: 345.
- CENTERS FOR DISEASE CONTROL AND PREVENTION (2000). **Disease information**: rift valley fever. Disponível em:
<http://www.cdc.gov/ncidod/dvrd/spb/mnpages/dispages/rvt.htm>.
- Chander, G., B.L. Markham e D. L. Helder. (2009). Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI sensors. **Remote Sensing of Environment**, 113: 893-903.
- Crist, E.P. e R. C. Cicone. (1984). A physically-based transformation of Thematic Mapper data – the TM Tasseled Cap. *IEEE Trans.* **On Geosciences and Remote Sensing**, 22: 256-263.
- Divino F. (2005). **Conceitos Básicos de Sensoriamento Remoto**, Setembro de 2005.
- Eastman, J.R. (1997). Idrisi for Windows, Introduction. Worcester-MA, Graduate School of Geography, Clark University. Users's Guide version 2.0 . 245 pp.
- Eastman, J.R. (2003). **Idrisi Kilimanjaro Guide to GIS and Image Processing**. Worcester-MA, Graduate School of Geography, Clark University. 328 pp.
- Environment for Visualizing Images (ENVI). 2009. User's Guide:**Atmospheric Correction Module**: QUAC and FLAASH. ESRI.
- Envi (2012), **Guia do Envi em Português**, SulSoft Serviços de Processamento de Dados Ltda, 33 pp.
- Ferreira, N.C. (2006) **Apostila de Sistema de Informações Geográficas**. 133 pp. Goiânia, Centro Federal de Educação Tecnológica de Goiás.

- Goodchild, M.F. (2009). Geographic information systems and science: today and tomorrow. University of California, Santa Barbara, **Procedia Earth and Planetary Science**. 1: 1037–1043.
- Hassan Ouaidrari and Eric F. Vermote (1999), **Operational Atmospheric Correction of Landsat TM Data**, REMOTE SENS. ENVIRON. 70:4–15
- Hassan Ouaidrari and Eric F. Vermote (1999), **Operational Atmospheric Correction of Landsat TM Data**, REMOTE SENS. ENVIRON. 70:4–15.
- Hosmer, D.W. e S. Lemeshow. (1989). **Applied logistic regression**. John Wiley & Sons, Inc., New York. Hensher, D. & L.W. Johnson. 1981. Applied discrete choice modelling. Croom Helm, London.
- Huang, C., B. Wylie., L. Yang., C. Homer, e G. Zylstra. (2002). Derivation of a tasseled cap transformation based on Landsat 7 at-satellite reflectance. **International Journal of Remote Sensing**, 23, 1741-1748.
- INE (2011), Inquérito Demográfico e de Saúde, Relatório preliminar, p: 38.
- INGC. (2009). Study on the impact of climate change on disaster risk in Mozambique. **Climate Change Report**. Maputo.
- Jeffares & Green (Pty) Ltd. (2010). Estudo de Viabilidade, Avaliação de Impacto Ambiental e Social, Projecto Executivo e Supervisão do Projecto de Reabilitação da Barragem de Nacala. **Relatório de Avaliação de impacto na Saúde**. 145pp.
- Kasper, D.L et al (2006). Harrison Medicina Interna, 16ª edição, Rio de Janeiro: Mc Graw - Hill: 1279 - 1293
- Leeuw, A. J. de, Veugen, L. M. M., and Stokkom, H. T. C. van (1988). Geometric correction of remotely-sensed imagery using ground control points and orthogonal polynomials. **International Journal of Remote Sensing**, 9, 1751-1759 pp.
- Longlay, P.A, M.F. Goodchild, D.J. Maguire e David W. Rhind (2005), **Manual of Geographic Information Systems**. 2nd edition, John Wiley & Sons Publishers.
- Martens, W.J.M. et al. (1995). Potential impact of global climate change on malaria risk. **Environmental Health Perspectives, Research Triangle Park**, 103 (5): 458 – 464.
- Mascarenhas, N.A., F.R.D. Velasco (1989). *Processamento digital de imagens*. **Buenos Aires Kapelusz**. 2.

- Mohsin M. S. e A. Vergara (2012). Mudanças climáticas e saúde pública, Uma reflexão com enfoque para Moçambique. **Revista Científica da UEM**, Série Ciências Biomédicas e Saúde Pública, 1 (0): 39-52.
- Murakami, T., S. Ogawa., N. Ishitsuka., K. Kumagai., G. Saito (2001) Crop discrimination with multitemporal SPOT/HRV data in the Saga Plains. Japan. **International Journal of Remote Sensing**. 22 (7): 1335-1348.
- OMS (2009), procedimentos padronizados para a vigilância e manejo Integrado de vectores de doenças, 30 pp.
- Okamoto, A. (1988). Orientation Theory of CCD Line-Scanner Images. **International Archives of Photogrammetry and Remote Sensin**. Kyoto, Japan, 27 (3): 609- 617 pp.
- Paolini, L., F. Grings., J.A. Sobrino., J.C. Jimenezmun., e H. Karszenbaum. (2006). Radiometric correction effects in Landsat multi-date/multi-sensor change detection studies. **International Journal of Remote Sensing**. 27 (4): 685–704.
- Penha, R.N. (2002). Um estudo sobre regressão logística binária. Disponível em: <http://www.iem.efei.br/dpr/td/producao2002/PDF/Renata.PDF>
- Programa Nacional de Controlo da Malária (2007), Inquerito Nacional sobre Indicadores de Malária em Moçambique, 1ª edição, 115 pp.
- Rall Back Malaria. (2008). **the Global Malaria Action Plan**: for a malaria free-world. 274 pp. RBM publishers.
- Rejmankova, E. (1995). Predictions of adult Anopheles albimanus densities in villages based on distances to remotely sensed larval habitats. **American Journal of Tropical Medicine Hygiene**, Baltimore, 53 (5): 482-488.
- Richter R. e Schläpfer. (2014). **Atmospheric/ Topographic Correction for Satellite Imagery – 2/3**. User Guide, 8.3.1.
- Sanches, I.D. Sanches, R.G. Andrade, C.F. Quartaroli e C.A.G. Rodrigues (2011). Análise comparativa de três métodos de correção atmosférica de imagens Landsat 5 – TM para obtenção de reflectância de superfície e NDVI. **Anais XV Simpósio Brasileiro de Sensoriamento Remoto – SBSR**. Brasil, Curitiba, INPE. 7564 pp.
- Shri, J.N.M. (2000). Remote Sensing a Visionary tool in Malaria Epidemiology. Indian Council of Medical Research, New Delhi. **ICRM Bulletin**, 30 (11): 11 – 23.
- Silveira, A.C. e D.F. Rezende. (2001). **Avaliação da estratégia global de controlo integrado da malária no Brasil**. Brasília-DF: Organização Pan-Americana da Saúde.

- Simmons, J. S. (1943). Keys to the Anopheline Mosquitoes of the World With Notes on Their Distribution, Biology and Relation to Malaria. **The American Entomological Society**: The Academy of Natural Sciences Philadelphia.
- Song, C., C.E. Woodcock., K.C Seto., M.P. Lenney e S.A. Macomber (2001). Classification and Change Detection Using Landsat TM Data: When and How to Correct Atmospheric Effects. **Remote Sensing of the Environment**, 75: 230-244.
- SUCEN. (2000). **Noções básicas sobre malária**. Disponível em: <http://www.sucen.sp.gov.br>.
- Terrazas, W.C.M. (2005). **Análise Epidemiológica da Distribuição Espacial da Malária no município de Manaus - um enfoque em nível local**. Dissertação de Mestrado. 107 pp. Fundação Oswaldo Cruz, ENSP.
- Toutin, T. (2003). Geometric Processing of Remote Sensing Images: Models, Algorithms and Methods. **Natural Resources Canada Centre for Remote Sensing**. M.A. Wulder and S. E. Franklin Editors, Kluwer Academic Publishers.
- Vasconcelos, C. H. (2004). **Aplicação de Sensoriamento Remoto e Geoprocessamento para analisar a distribuição da Malária na região do reservatório de Tucuruí – PA**. Tese de Doutorado. 188pp. São Paulo, Universidade de São Carlos.
- Vasconcelos, C. H. e E.M.L. de Moraes Novo (2005). Uso de sensoriamento remoto e sistema de informação geográfica para o estudo da distribuição da malária no município de Jacundá-PA. **Anais XII Simpósio Brasileiro de Sensoriamento Remoto**, Goiânia, Brasil, INPE: 2421-2427.
- Venticinque, E.M., J.S. Carneiro., M.P. Moreira. e L. Ferreira. (2007). O uso de regressão logística para espacialização de probabilidades. Megadiversidade, 3 (1-2).
- Vogelmann, J.E., D. Helder., R. Morfitt., M.J. Choate., J.W. Merchant e H. Bulley (2001). Effects of Landsat 5 Thematic Mapper and Landsat 7 Enhanced Thematic Mapper Plus radiometric and geometric calibrations and corrections on landscape characterization. **Remote Sensing of Environment**, 78: 55–70.
- Who (2000), **Handbook on geographic information systems and digital mapping**, Series F, (79), 205 pp.
- Who (2005), **the world health report**, disponível em <http://www.who.int/whr/2005/en/>

- Who (2008), Mosquitoes of the genus Anopheles in countries of the WHO European Region having faced a recent resurgence of malaria, **Regional research project 2003–2007**, 2008 pp.
- World Health Organization (2012), World malaria report, 288 pp.
- Yang, X. (2001). Piece-wise Linear Rational Function Approximation in Digital Photogrammetry. **Proceedings of the ASPRS Annual Conference**. St Louis, Missouri, USA.

ANEXO 1: Resultados da operação ROC

| Result of ROC**
=====

ROC = 0.798

The following section list detailed statistics for each threshold.

With each threshold, the following 2x2 contingency table is calculated

Simulated by threshold	Reality (reference image)	
	1	0
1	A(number of cells)	B(number of cells)
0	C	D
For the given reference image:	A+C=6285	B+D=68715

No.	Exp. Thrhlds(%)	Act. Thrhlds(%)	Act. raw cuts	A	True posi.(%)	B	False posi.(%)
1	0.0000	0.0000	0.0000	0	0.0000	0	0.0000
2	20.0000	20.0013	0.1687	3177	50.5489	11824	17.2073
3	40.0000	40.0013	0.1334	5418	86.2053	24583	35.7753
4	60.0000	60.0013	0.0000	6272	99.7932	38729	56.3618
5	80.0000	80.0013	0.0000	6285	100.0000	53716	78.1722
6	100.0000	100.0000	0.0000	6285	100.0000	68715	100.0000

** For the given reference image, the following seven statistics are the same for all thresholds. The unit of each statistic is the proportion correct attributable to a combination of information of location and quantity.

No info of location and no info of quantity: N(n) = 0.5000
Perfect info of location and perfect info of quantity: P(p) = 1.0000
Perfect info of location and no info of quantity: P(n) = 0.5838
No info of location and perfect info of quantity: N(p) = 0.8464
No info of location and no info of quantity: PerfectChance = 0.5000
No info of location and perfect info of quantity: PerfectQuantity = 0.3464
Perfect info of location given no info of quantity: PerfectLocation = 0.1536

No.	M(m)	N(m)	P(m)	M(p)	M(n)
1	0.9162	0.9162	0.9162	0.8464	0.5000
2	0.8009	0.7497	0.8838	0.9051	0.5320
3	0.6607	0.5832	0.6838	0.9647	0.5645
4	0.4834	0.4167	0.4838	0.9992	0.5834
5	0.2838	0.2503	0.2838	1.0000	0.5838
6	0.0838	0.0838	0.0838	0.8464	0.5000

No.	Kno	Klocation	Kquantity	Kstandard
1	0.832	0.000	1.201	0.000
2	0.602	0.382	0.721	0.205
3	0.321	0.770	0.240	0.186
4	-0.033	0.995	-0.240	0.114
5	-0.432	1.000	-0.721	0.045
6	-0.832	0.000	-1.201	0.000

No.	CorrectChance	CorrectQuantity	CorrectLocation	ErrorLocation	ErrorQuantity
1	0.500	0.416	0.000	0.000	0.084
2	0.500	0.250	0.051	0.083	0.116
3	0.500	0.083	0.077	0.023	0.316
4	0.417	0.000	0.067	0.000	0.516
5	0.250	0.000	0.034	0.000	0.716
6	0.084	0.000	0.000	0.000	0.916

** : A ranked image (Tmp\$Rank_PREDICTION) based on the input image was created in the working directory. In addition, a percentile map(Tmp\$percentile_PREDICTION) based on the threshold bands user specified was also created in the working directory.

ANEXO 2: Resultados da Regressão Logística

Logistic Regression Results:

Regression Equation :

$$\text{logit(Malaria)} = -12.7598 + 0.081485 \cdot \text{NDVI} + 2.800355 \cdot \text{humidade} + 0.384548 \cdot \text{temperatura}$$

Individual Regression Coefficient

Variables	Coefficient
Intercept	-12.75975694
NDVI	0.08148489
humidade	2.80035475
temperatura	0.38454829

Regression Statistics :

Number of total observations = 75000
 Number of 0s in study area = 68715
 Number of 1s in study area = 6285
 Percentage of 0s in study area = 91.6200
 Percentage of 1s in study area = 8.3800
 Number of auto-sampled observations = 7193
 Number of 0s in sampled area = 6571
 Number of 1s in sampled area = 622
 Percentage of 0s in sampled area = 91.3527
 Percentage of 1s in sampled area = 8.6473

-2logL0 = 4233.8096
 -2log(likelihood) = 3400.3798
 Pseudo R_square = 0.1969
 Goodness of Fit = 351831.0335
 ChiSquare(3) = 833.4298

	Mean	Standard Deviation
NDVI	0.162807	0.172045
humidade	-0.034780	0.043506
temperatura	16.195226	14.454193
Malaria	0.086473	0.281081

Classification of cases & odds ratio

Observed	Fitted_0	Fitted_1	Percent Correct
0	6571	0	100.0000
1	622	0	0.0000

Odds Ratio = Not Applicable

Reclassification of cases & ROC (Sample-based computation when applicable):

- (1) Select a new threshold value such that, after reclassification, the number of fitted 1s matches the number of observed 1s in the dependent variable
 New cutting threshold = 0.1921

Classification of cases & odds ratio by using the new threshold

Observed	Fitted_0	Fitted_1	Percent Correct
0	6098	473	92.8017
1	473	149	23.9550

Adjusted Odds Ratio = 4.0612; True Positive = 87.6471%

False Positive = 7.1983%

- (2) ROC* Result with 100 thresholds (Sample-based computation when applicable):

ROC = 0.8031

* ROC=1 indicates a perfect fit; and ROC=0.5 indicates a random fit.

ANEXO 3: Mapa de Risco de transmissão por malária

MAPA DE RISCO DE INFECÇÃO POR MALÁRIA NO PERÍODO DE 2008

