



UNIVERSIDADE FEDERAL DE MINAS GERAIS
INSTITUTO DE GEOCIÊNCIAS
DEPARTAMENTO DE CARTOGRAFIA

Lauro Magalhães Fráguas

**MODELAGEM DA DINÂMICA DO USO E COBERTURA DA TERRA
PARA MADRE DE DIOS, PERU**

**Belo Horizonte
2012**

Lauro Magalhães Fráguas

**MODELAGEM DA DINÂMICA DO USO E COBERTURA DA TERRA
PARA MADRE DE DIOS, PERU**

**Dissertação apresentada ao Programa de Pós
Graduação em Análise e Modelagem de
Sistemas Ambientais da Universidade Federal
de Minas Gerais como requisito para obtenção
do título de mestre em Análise e Modelagem
de Sistemas Ambientais.**

Orientador: Ricardo Alexandrino Garcia

**Belo Horizonte
2012**

APRESENTAÇÃO

Este trabalho foi elaborado como trabalho final do Mestrado do Programa de Pós-Graduação em Análise e Modelagem de Sistemas Ambientais. Optou-se por apresentar o trabalho em formato de artigo e por questões de padronização foram utilizadas as normas da Revista Brasileira de Cartografia. Algumas destas normas, tais como a organização do texto em colunas e o tamanho da fonte foram flexibilizadas para melhor apresentação e leitura do trabalho.

Afim de propiciar uma melhor visualização para análise, os mapas produzidos e apresentados no corpo do artigo estão presentes no Anexo C deste volume em um tamanho ampliado.

SUMÁRIO

LISTA DE FIGURAS	4
LISTA DE TABELAS	5
RESUMO	6
ABSTRACT	7
1- INTRODUÇÃO	8
2- OBJETIVOS	11
3- METODOLOGIA	11
3.1- Obtenção dos dados	11
3.2- Caracterização da Área de Estudo	11
3.3- Processamento Digital de Imagens	12
3.3.1- Correção Atmosférica	13
3.3.2- Classificação das Imagens	13
3.4- Modelagem da Dinâmica do Uso da Terra	14
4- RESULTADOS E DISCUSSÃO	17
4.1- Classificação das Imagens de Satélite	17
3.2- Modelagem da Dinâmica do Uso da Terra	18
5- CONSIDERAÇÕES FINAIS	24
6- REFERÊNCIAS	24
7- ANEXOS	29

LISTA DE FIGURAS

Figura 1: Mapa de situação de situação da área de estudo em Madre de Dios, Peru.	12
Figura 2: Fluxograma dos Processos do Land Change Modeler.	15
Figura 3: Mosaicos das imagens Landsat 5 TM classificadas para os anos de 2001, 2006 e 2011.	18
Figura 4: Mapa de potencial de transição de floresta para não-floresta.	20
Figura 5: Mapa de potencial de transição de não-floresta para floresta.	21
Figura 6: Mapa de simulação das mudanças de uso da terra para o ano de 2011.	22
Figura 7: Mapa de simulação das mudanças de uso da terra para o ano de 2020.	23

LISTA DE TABELAS

Tabela 1: Drivers utilizados no modelo.	16
Tabela 2: Área em metros quadrados de floresta e não floresta e desempenho médio da classificação para os anos de 2001, 2006 e 2011 em quilômetros quadrados.	17
Tabela 3: Coeficientes da equação obtida da regressão logística para cálculo do potencial de transição de floresta para não-floresta.	19
Tabela 4: Coeficientes da equação obtida da regressão logística para cálculo do potencial de transição de não-floresta para floresta.	20
Tabela 5: Comparativo entre a imagem de 2011 gerada pela classificação das imagens de satélite e a predição modelada em quilômetros quadrados.	22
Tabela 6: Índices kappa para comparação entre a imagem de 2011 gerada pela classificação das imagens de satélite e a predição modelada.	22

RESUMO

O Departamento de Madre de Dios está localizado na Amazônia peruana, e faz parte da região de tríplice fronteira MAP, juntamente com o Estado do Acre (Brasil) e o Departamento de Pando (Bolívia). Conhecida por sua grande biodiversidade e pelo fato de possuir 96% de sua extensão ainda coberta por floresta, a região vem sendo alvo de grandes investimentos em infra-estrutura, visando incentivar a ocupação da área, que realizada indiscriminadamente, pode ameaçar o equilíbrio ambiental da região.

A principal obra recente na região é a implementação da Rodovia Interoceânica Sul, ligando o Brasil à costa do oceano Pacífico. Sabe-se que estradas, bem como a hidrografia e demais vias de transporte são importantes agentes no processo de desmatamento. Neste contexto, objetivou-se neste trabalho modelar a mudança do uso da terra em torno do trecho da IOS que passa por Madre de Dios para o ano de 2020 por meio de um mosaico imagens Landsat 5 TM dos anos de 2001 e 2006 classificadas. Adotou-se uma área de influência de 50 km de raio da rodovia dentro do Departamento. Utilizou-se como variáveis de entrada para o modelo a declividade, áreas protegidas, áreas urbanas, concessões de mineração, concessões florestais, rodovia Interoceânica, estradas secundárias, lotes agrícolas, solos e vegetação. A partir de tais informações criou-se o modelo preditivo com duas transições: floresta para não-floresta e não-floresta para floresta.

Validou-se o modelo comparando sua predição para o ano de 2011 com outro mosaico de imagens Landsat 5 para o mesmo ano. O índice kappa obtido da comparação entre as duas imagens foi de 0,876. Optou-se por não aplicar um índice de calibração ao modelo, devido ao alto desempenho no teste comparativo. Em seguida aplicou-se novamente o modelo com o horizonte preditivo até o ano de 2020. Foram obtidos 4.599,76 Km² de áreas de não-floresta para o ano de 2020, o que equivale a um desmatamento de aproximadamente 1.480 Km² entre os anos de 2011 e 2020.

As principais áreas afetadas pelo desmatamento foram os arredores da capital Porto Maldonado, a fronteira do Brasil no extremo norte da área de estudo e ao sul da área de estudo.

PALAVRAS-CHAVE: Uso da Terra, Modelagem do Uso da Terra, desmatamento, Rodovia Interoceânica Sul, Madre de Dios.

ABSTRACT

The Department of Madre de Dios is located at the Peruvian Amazonia. It is well-known for its biodiversity and for being composed of 96% of forests. This same region has been the target of large investments in infrastructure so as to stimulate its occupation, which may affect the environment if done indiscriminately.

The roadwork done for the settling of the Interoceanica Sul Highway is the most important being done at present. The existence of roads is significant deforestation agents. The main goal of this research was to model the use of the land around the road crossing Madre de Dios for 2020 throughout the use of Landsat 5 images of the years 2001 and 2006. The catchment area was of 50 kilometers from the road inside the Department. The input variables used for the model were urban, protected, mining and forest areas, roads, sideways, land lots, soils and vegetation.

The model has been validated by comparing the previews made for the year 2011 with Landsat images for the same year. The kappa index obtained from this comparison was 0,876. We decided not to calibrate the model due to the high kappa index obtained. We then used the model for the year 2020. We obtained 4.599,76 Km² of non-forest areas for this year, which can be compared to a deforestation of about 1.480 km² between the years 2011 and 2020.

The most damaged areas were the outskirts of the capital, Porto Maldonado, the border with Brazil and the southern area.

KEYWORDS: Land Use, Land-Use Modeling, deforestation, Interoceanic Highway South, Madre de Dios.

1- INTRODUÇÃO

Na Amazônia Brasileira, observa-se o aumento contínuo do desmatamento desde 1991, com oscilações motivadas pelo aquecimento da economia (Fearnside, 2006). A política de ocupação da região amazônica pelo governo brasileiro historicamente se deu, e ainda ocorre através da abertura de grandes rodovias e estradas pelo interior da floresta, condenando as áreas em seu entorno ao desmatamento. Projetos rodoviários planejados, tais como a reconstrução das rodovias BR-163 (Cuiabá-Santarém) e a BR-319 (Manaus-Porto Velho), implicam na abertura de grandes áreas de floresta para a entrada de agentes de desmatamento. (Soares-Filho et al., 2004, 2005; Fearnside, 2006).

Na atual circunstância da economia peruana, a Amazônia é a principal frente de crescimento econômico, e percebe-se que o modelo de colonização adotado pelo lado brasileiro da floresta tem sido replicado pelos peruanos e é causa de preocupação para pesquisadores e órgãos governamentais ligados ao meio ambiente, e por este motivo, a exploração econômica e o desmatamento da Amazônia vêm se tornando uma questão ambiental cada vez mais discutida no âmbito internacional (Myers, 2004; Perz et al., 2005; 2008; Becker, 2006; Alvarez, 2001; Naughton-Treves, 2004; Soares-Filho et al., 2005; 2006; Oliveira et al., 2007; Nepstad et al., 2009; Laurence et al., 2001; Fearnside et al., 2000).

As pressões econômicas por uma intensificação do uso da terra levam a Amazônia peruana a sofrer desmatamento motivado principalmente pelo crescimento populacional e a expansão das fronteiras agrícolas (Perz et al., 2005; Chavez, 2009; Southworth et al., 2011). O Departamento de Madre de Dios se encontra contextualizado neste panorama. Apesar de ainda possuir 96% de sua cobertura de floresta, a implementação de grandes obras de infra-estrutura tendem a facilitar a exploração dos recursos naturais e promover o desenvolvimento econômico da região. A obra mais relevante neste processo é a Rodovia Interoceânica Sul (IOS), obra realizada com o aporte de mais de 890 milhões de dólares da Corporação Andina de Fomento e os governos brasileiro e peruano. A IOS é a primeira estrada a ligar o sistema brasileiro ao sistema rodoviário peruano, sendo que ela é atualmente o principal fator de desmatamento da região. A construção da estrada e a melhoria da infra-estrutura ao seu entorno criou condições de uma maior exploração econômica, o que alavancou o desmatamento da região, chegando a representar 23% do desmatamento na Amazônia Peruana em 2005 (Oliveira et al., 2007).

A concretização deste empreendimento acarretará em grandes mudanças sócio-econômicas e ecológicas na região que poderão ser observadas por meio das mudanças no uso e ocupação da terra. Outros empreendimentos de infra-estrutura, bem como a intensificação

da mineração e dos fluxos migratórios para região contribuem para a intensificação da mudança do uso da terra na região. Um estudo da Conservação Internacional (2005) indica que aproximadamente 6000 hectares de florestas são removidos de Madre de Deus anualmente e em grande parte são substituídas por paisagens agropecuárias ao longo da IOS e das estradas secundárias abertas a partir dela (Zambrano et al., 2010, Alvarez & Naughton-Treves, 2003).

Desta maneira, é cada vez mais necessária a implementação de uma política pública para o controle da expansão do desmatamento e atividades impactantes ao ecossistema. Tal necessidade é demonstrada por Oliveira et al. (2007) que identificaram a existência de extração madeireira em regiões vizinhas às áreas de concessão e a necessidade de monitoramento das atividades econômicas.

Neste contexto torna-se importante compreender a dinâmica da mudança do uso da terra na região. Tal conhecimento é desenvolvido através da complexa interação entre fatores físicos, biológicos, econômicos, políticos e sociais que delinham as transformações e mudanças de uso da terra (Veldkamp & Velburg, 2004). É também determinante na composição e na estrutura da paisagem (Turner et al., 2001). A compreensão integrada de fatores naturais e sociais nos processos de uso da terra é necessária para o entendimento das transformações na paisagem (Milne et al., 2009, Aspinall, & Hillp, 2003).

Dada a dinâmica espacial e temporal das forças biofísicas e sócio-econômicas que influenciam na cobertura vegetal e no uso da terra, compreender a complexa teia de interações entre padrão e processo é conceitualmente desafiador. Metodologicamente, os dados de cobertura do solo são mais frequentemente derivados de imagens de satélite, que fornecem uma representação da cobertura do solo em um ponto estático no tempo. A unidade de observação é o pixel, ou seja, um conjunto de diversos tipos de cobertura resumidos em uma quadrícula resultante, que não corresponde em uma maneira simples a unidades biofísicas, sociais, econômicas ou políticas de organização (Nagendra et al., 2004).

Neste contexto, para a previsão de possíveis conformações de uma paisagem futura considerando relações tão complexas dentro do sistema, torna-se fundamental a aplicação de Modelos de Dinâmica do Uso da Terra.

Modelos de uso da terra têm um papel importante em explorar possíveis desenvolvimentos futuros no sistema de uso. Com um modelo, o funcionamento do sistema pode ser explorado através de cenários e visualização de alternativas de uso que podem ser o

resultado de decisões políticas ou de seus desdobramentos na sociedade, conforme descrito nos cenários. A capacidade de exploração permite que os modelos estocásticos possam ser usados como ferramentas de comunicação e aprendizagem para os agentes envolvidos na gestão do uso da terra. Projeções podem ser usadas como um sistema de alerta para os efeitos de futuras mudanças de uso ou cobertura da terra e determinação de áreas prioritárias para aprofundamento da análise ou de intervenção política (Lambin & Geist, 2006; Aspinall & Hill, 2008).

Diversos são os trabalhos sobre modelos dinâmicos de uso e cobertura da terra. Soares-Filho (2005) realizou um trabalho de simples análise da cobertura vegetal por meio da identificação de três transições por imagens Landsat: desmatamento, regeneração e limpeza da regeneração. Apesar de ser um trabalho apenas de análise, os resultados apresentados podem ser usados como uma fase de identificação de parâmetros espaciais, etapa preliminar para a geração de um modelo de mudanças de uso e cobertura da terra.

Soares-Filho et al. (2004) também geraram um modelo simulando as mudanças de cobertura causadas pela pavimentação da rodovia Santarém-Cuiabá. Como parâmetro para o sistema, foi utilizada uma base de dados de SIG contendo mapas de solos, topografia, áreas protegidas e estradas; que por sua vez gerou uma base de probabilidades de transformações espaciais. A associação destas probabilidades com subsistemas relacionados às questões sócio-econômicas resultou em um modelo, onde foi possível simular diversos cenários, de acordo com possíveis quadros de dinâmica política, econômica e social.

Coelho (2009) simulou a dinâmica do uso da terra e cobertura vegetal para a região de Santarém, no Pará. A autora fez uso de classificação não-supervisionada de imagens de satélite para simular a expansão da agropecuária sobre a floresta.

Assim, tendo em vista o atual panorama para a região de Madre de Deus, acredita-se que uma modelagem da dinâmica do uso da terra venha contribuir para o planejamento do uso da terra e auxiliar na determinação das áreas mais sensíveis às mudanças.

2- OBJETIVOS

O objetivo geral deste trabalho é gerar um modelo de dinâmica do uso da terra para o Departamento de Madre de Dios, Peru com um horizonte preditivo para o ano de 2020.

Os objetivos específicos são:

- Quantificar o Uso e Ocupação da Terra para a Região de Madre de Dios para os anos de 2001, 2006 e 2011 por meio de imagens Landsat 5 TM;
- verificar quais são os principais fatores responsáveis pelas mudanças de cobertura para a área de estudo;
- validar o modelo por meio da comparação da predição das mudanças para 2011 e as imagens classificadas para o mesmo ano.
- Obter uma projeção da situação de uso e ocupação em 2020.

3- METODOLOGIA

3.1- Obtenção dos dados

Nesta pesquisa os trabalhos foram realizados em uma etapa de campo e outra de escritório. Em campo, percorreu-se toda extensão da Rodovia, a fim de obter posições geográficas de pontos com o sistema GPS e seus respectivos usos da terra durante os meses de novembro e dezembro de 2010. Além disso, foram realizadas visitas a órgãos públicos tais como INRENA (Instituto Nacional de Recursos Naturales), Dirección Regional de Agricultura, SENASA (Servicio Nacional de Sanidad Agraria), ACCA (Asociación para la Conservación de la Cuenca Amazónica), ProNaturaleza (Fundación Peruana para la Conservación de la Naturaleza) e COFOPRI (Organismo de Formalización de la Propiedad Informal) a fim de obter dados secundários que pudessem contribuir na execução do trabalho.

3.2- Caracterização da Área de Estudo

Madre de Dios é o terceiro maior Departamento do Peru e está localizado totalmente na Floresta Amazônica. Possui uma área de 85.300 km² e faz fronteira com o Brasil ao norte, com a Bolívia a leste, com o departamento de Cusco a oeste e com os departamentos de Cusco e Puno ao sul. Segundo o censo de 2007, sua população é de 109.555 habitantes e sua capital é Porto Maldonado. As principais atividades econômicas são a agropecuária, extrativismo madeireiro, extrativismo vegetal não madeireiro (castanha, buriti, etc) e a mineração. A maioria da população e das atividades econômicas ocorrem próximas a

rodovia Interoceânica, seja propriamente em suas margens, seja às margens de estradas secundárias.

A área de estudo para este trabalho engloba toda a extensão da Interoceânica Sul dentro do Departamento de Madre de Dios contabilizando 403 km de um extremo a outro. Delimitou-se uma área de trabalho de 50 quilômetros de raio da IOS dentro do Departamento. Excluiu-se o extremo sul desta área, visto a intensa presença de nuvens devido ao início da Cordilheira dos Andes, inviabilizando o processamento das imagens Landsat (Figura 1).

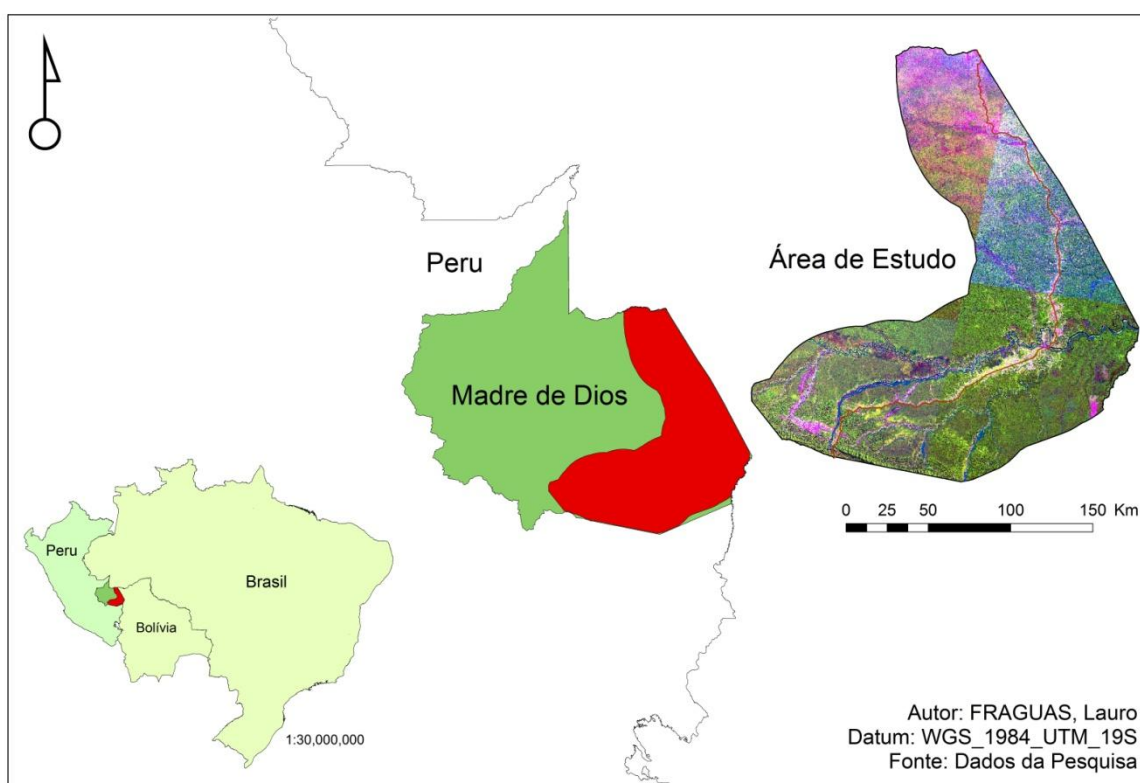


Figura 1: Mapa de situação de situação da área de estudo em Madre de Dios, Peru

3.3- Processamento Digital de Imagens

Utilizou-se um recorte das cenas de órbita/ponto 02/68, 02/69, 03/68 e 03/69 para cobrir toda a área de estudo para os anos de 2001, 2006 e 2011. Os recortes foram mosaicados somente após o processo de classificação devido às diferenças espectrais presentes mesmo após o processo de correção atmosférica.

As imagens foram georeferenciadas por meio das posições geográficas dos pontos GPS obtidos em campo, bem como pelos polígonos de hidrografia e estradas obtidas no banco de dados do sistema de informações geográficas fornecido pela ONG ACCA.

3.3.1- Correção Atmosférica

As imagens obtidas por sensores remotos são produtos da interação da radiação solar com a atmosfera e a superfície-alvo, sendo que o sinal proveniente da atmosfera pode ser considerado um ruído que interfere na obtenção de informações para a região de interesse.

A radiação interage com a atmosfera causando absorção ou espalhamento, sendo que o espalhamento pode ser também produto de múltiplas interações. A determinação de cada componente na relação entre radiação solar e efeito atmosférico consiste na solução da equação de transferência radiativa do modelo de correção atmosférica, e o grau de contribuição de cada componente vai depender das condições atmosféricas locais, das coordenadas geográficas do alvo, além da data e do horário da obtenção da imagem (Antunes et al., 2003).

Assim, optou-se por utilizar a metodologia 6S (Second Simulation of The Satellite Signal in The Solar Spectrum) (Vermont et al., 1997) em uma versão adaptada por Antunes et al. (2003). Dentro do 6S, trabalhou-se com o modelo atmosférico tropical em conjunto com o modelo de aerossóis continental, utilizando os dados referentes às condições ambientais de cada imagem de satélite como input para a correção atmosférica.

3.3.2- Classificação das Imagens

A classificação automática de imagens multiespectrais permite a extração rápida de informação e definição dos padrões de ocupação da terra. Visa a categorização da cobertura da terra distinguindo as composições de diferentes materiais superficiais. A classificação supervisionada é baseada num conjunto de amostras utilizadas para treinamento do classificador. Tais amostras para treinamento são obtidas por meio das informações de uso obtidas pela obtenção de posições geográficas pelo GPS e pela interpretação visual do comportamento espectral pelo usuário.

Para realizar a classificação, utilizou-se as bandas 1 a 5 das imagens Landsat 5, após receberem a correção atmosférica. O *software* utilizado foi o Spring 5.1.8 e foi aplicado o classificador de Máxima Verosimilhança (MAXVER), que é o mais utilizado em imagens de sensoriamento remoto (Shiba et al., 2005).

A regra de decisão utilizada pelo classificador pode ser definida como:

$$x \in w_i \Leftrightarrow -\ln|\Sigma_i| - (x - m_i)^t \Sigma_i^{-1}(x - m_i) = \max_j \left(-\ln|\Sigma_j| - (x - m_j)^t \Sigma_j^{-1}(x - m_j) \right) \quad (1)$$

Onde:

Σ_i e m_i são respectivamente, a matriz de covariância e o vetor média da classe i , obtidas através das amostras de treinamento.

Aplicou-se um limiar de decisão de 100%, devido ao grande número de amostras coletadas para cada uma das cenas e pela pequena quantidade de classes obtida com os comportamentos espectrais muito diferentes entre si. As classes obtidas foram: água, floresta e não-floresta. Em seguida, confeccionou-se o mosaico das quatro cenas Landsat classificadas para cada um dos anos.

3.4- Modelagem da Dinâmica do Uso da Terra

Para modelar a dinâmica do uso da terra, utilizou-se a plataforma Land Change Modeler (LCM). LCM é uma plataforma de análise e previsão das mudanças de cobertura da terra que também incorpora ferramentas que lhe permitem analisar, medir e projetar os impactos sobre o habitat e a biodiversidade. O LCM inclui um conjunto de ferramentas que abordam análise da mudança, gestão de recursos e avaliação de habitat, mantendo um fluxo de trabalho simples e automatizado.

Foi utilizado o software IDRISI, versão Taiga (Eastman 2006), que consiste num SIG (Sistema de Informações Geográficas) contendo vários módulos de análise da informação espacial, dentre eles o LCM. O primeiro passo consiste na análise de mudanças de uso da terra a partir dos dois mapas de paisagens de diferentes datas, sendo gerado para visualização um balanço de perdas e ganhos entre as classes. É também nesse primeiro passo que o software calcula a taxa de transição com base em cadeias de Markov, apresentando a matriz para visualização e edição, caso necessário.

O segundo passo consiste na modelagem dos potenciais de transição, gerando um zoneamento indicando as probabilidades de mudança de uso. No caso de modelos com mais de uma transição, o LCM permite subdividi-los ou agrupá-los em sub-modelos, desde que os mesmos determinantes espaciais estejam influenciando as transições de cada grupo. Nesta etapa, o software utiliza os mapas de determinantes para gerar os potenciais com base em regressão logística ou redes neurais (MLP – Multi-Layer Perceptron), a partir de amostras dos mapas cujo tamanho é ajustável pelo usuário.

Num terceiro passo, é feita a alocação espacial das mudanças previstas. No LCM a alocação pode ser realizada pelo método *hard* ou *soft prediction*. O primeiro utiliza um algoritmo de alocação multi-critério (Eastman et al 1995), enquanto que o segundo baseia-se na caracterização de cada pixel quando à máxima probabilidade de transição a ele

associadas. Um pixel é mais vulnerável quanto mais transições estiverem a ele associadas, agregando maior probabilidade de que ele venha a sofrer mudança (Eastman 2006). Na figura 2 é apresentado o fluxograma referente ao processo de modelagem na plataforma LCM.

Foram utilizadas as imagens classificadas de 2001 e 2006 como inputs do modelo, juntamente com o modelo de elevação (SRTM) e a o raster referente à Interoceanica. Adicionou-se os drivers da tabela 1 como variáveis do modelo.

Foram empregados os sub-modelos de transição de floresta para não-floresta e de não-floresta para floresta para gerar os mapas de potencial de transição. Para isto aplicou-se a regressão logística em uma amostra de 10% do total de pixels das imagens, por ser o método de cálculo de transição que apresentou o resultado mais próximo das mudanças observadas para transições na Amazônia em estudo de Ruhoff et al. (2010). As variáveis aplicadas na regressão logística para as duas transições estão listadas na tabela 1. Os dados cartográficos adaptados para serem utilizados no modelo foram obtidos na etapa de trabalho de campo por meio da ACCA (2010).

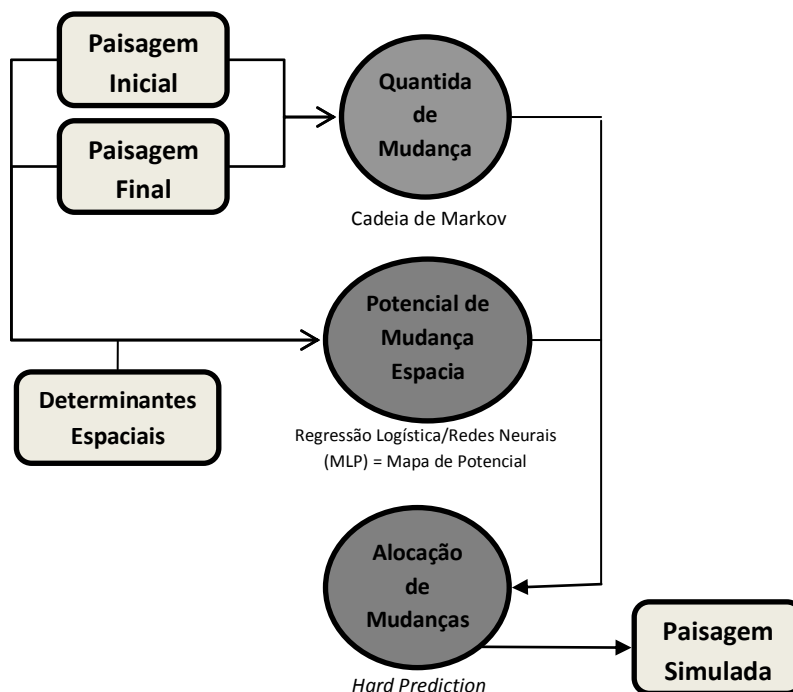


Figura 2: Fluxograma dos Processos do Land Change Modeler.

Tabela 1: Drivers utilizados no modelo.

Drivers utilizados
Áreas Protegidas
Áreas Urbanas
Concessões de Mineração
Concessões Florestais
Função de Distância a Concessões de Mineração
Função de Distância a Concessões Florestais
Função de Distância a Estradas
Função de Distância à hidrografia
Função de Distância a Lotes Agrícolas
Hidrografia
Lotes Agrícolas
Solos
Vegetação

Com os mapas de potencial de transição criados, aplica-se a alocação especial das mudanças através de *hard prediction* para o ano de 2011. O desempenho do modelo foi avaliado através de diferentes índices de estatística Kappa, calculados no *Map Comparison Kit* (MCK) entre o mapa de uso da terra gerado e o mosaico de imagens classificadas do mesmo ano.

O *Map Comparison Kit* (MCK) é um software utilizado para a comparação estatística de mapas raster. O programa permite aos usuários obter uma boa compreensão das diferenças entre pares de mapas, tais como a extensão total das diferenças, sua distribuição espacial e natureza.

Neste estudo utilizaram-se os índices Kappa (K) e Kappa diferenciado entre acertos quantitativos (K_histo) (Visser, 2004) e de localização espacial (K_location) (Pontius 2002), calculados pixel-a-pixel (*crisp method*) de acordo com as equações (2) a (4). Utilizou-se

$$K = \frac{P(A) - P(E)}{1 - P(E)} \quad (2)$$

Onde:

P(A) é a porcentagem de pixels corretos em relação ao total

P(E) é a porcentagem de acertos esperados por aleatoriedade

$$K_{\text{location}} = \frac{P(A) - P(E)}{P(\text{max}) - P(E)} \quad (3)$$

Onde:

P(A) é a porcentagem de pixels corretos em relação ao total

P(E) é a porcentagem de acertos esperados por aleatoriedade

P(max) é a máxima porcentagem de acertos possíveis dado o total de pixels da classe

$$K_{\text{histo}} = \frac{P(\text{max}) - P(E)}{1 - P(E)} \quad (4)$$

Onde:

P(E) é a porcentagem de acertos esperados por aleatoriedade

P(max) é a máxima porcentagem de acertos possíveis dado o total de pixels da classe

Não houve a necessidade de calibrar o modelo, visto que o índice kappa obteve resultados altos, conforme será discutido posteriormente. Portanto, em seguida aplicou-se o modelo para prever as mudanças de uso da terra para o ano de 2020.

4- RESULTADOS E DISCUSSÃO

4.1- Classificação das Imagens de Satélite

Ao analisar a série histórica de imagens classificadas, percebeu-se a diminuição das áreas de floresta e o aumento das áreas de não-floresta (Tabela 2), conforme a tendência já esperada. O desempenho médio em todas as cenas dos mosaicos de cada um dos anos apresentou resultado satisfatório para inferir que a tendência observada corresponde a realidade da época da obtenção de cada uma das imagens.

Tabela 2: Área em metros quadrados de floresta e não floresta e desempenho médio da classificação para os anos de 2001, 2006 e 2011 em quilômetros quadrados.

Ano	Área de Floresta	Área de Não-Floresta	Desempenho Geral Médio
2001	26295	2463	98,84%
2006	25985	2749	99,87%
2011	25715	3119	99,97%

Os mapas gerados na classificação estão presentes na Figura 3.

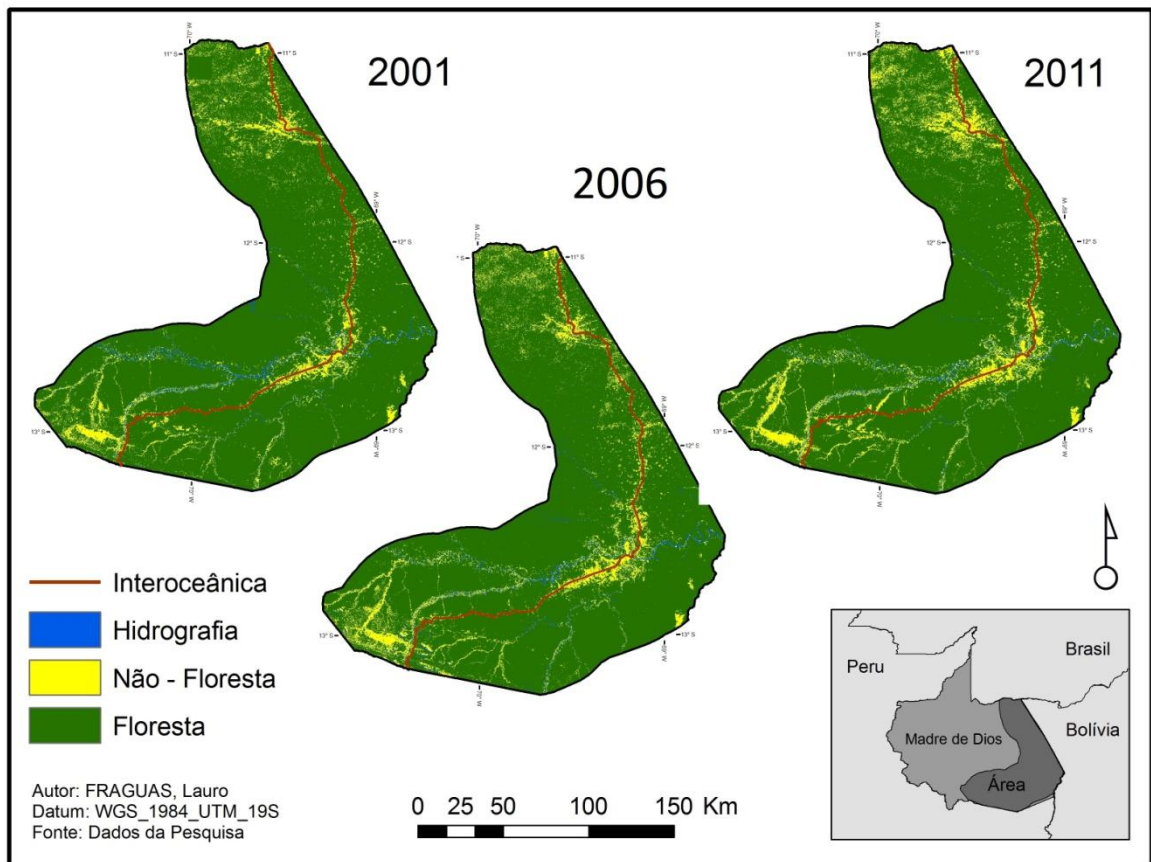


Figura 3: Mosaicos das imagens Landsat 5 TM classificadas para os anos de 2001, 2006 e 2011.

3.2- Modelagem da Dinâmica do Uso da Terra

A regressão logística para determinar o mapa de potencial de transição de floresta para não-floresta é apresentado na Tabela 3. Por meio da equação de regressão gerada por esses coeficientes aplicada em cada pixel, é gerado o mapa de potencial de transição (Figura 4).

Tabela 3: Coeficientes da equação obtida da regressão logística para cálculo do potencial de transição de floresta para não-floresta.

Variáveis	Coeficiente
Intercepto	-2,87544664
Presença Áreas Protegidas Integrais	0,00002261
Presença Áreas Protegidas Uso Sustentável	-0,0000478
Distância à Rodovia Interoceânica	-0,00001188
Distância às Estradas Secundárias	-0,0000459
Distância às Estradas Terciárias	-0,00002928
Distância às Estradas Ribeirinhas	0,00000573
Distância ao Rio Madre de Dios	0,00003209
Distância a Rios Secundários	-0,00002869
Distância a Concessões Florestais	0,00000101
Presença de Concessões Florestais	0,00103585
Distância a Concessões de Mineração	0,00000378
Presença de Concessões de Mineração	-0,00345903
Presença da Rodovia Interoceânica	1,35181728
Distância dos Lotes Agrícolas	-0,00000547
Presença dos Lotes Agrícolas	0,81084687
Classes de Solos	0,05274745
Presença da Rodovia Interoceânica	-0,00238027
Tipo de Vegetação	0,04125292
Presença de Área Urbana	0,2496963

Analisando os dados gerados, percebe-se a maior influência das variáveis correspondentes à Interoceânica, aos lotes agrícolas e às áreas urbanas no desmatamento na área de estudo. As áreas mais sensíveis a esta transição são o extremo norte, próximo ao Brasil, em volta da cidade de Iñampari, onde há uma série de concessões florestais; arredores da cidade de Ibéria e da capital Porto Maldonado; outra região de destaque é o extremo sul da área de estudo, próximo a Mazuco, região com intensa atividade de extrativismo de ouro e pecuária bovina. Os valores negativos indicam uma relação inversa entre a presença do driver e o desmatamento. No caso dos drivers de distância negativos, quanto mais distante do elemento, menor é a possibilidade da transição de floresta para não-floresta.

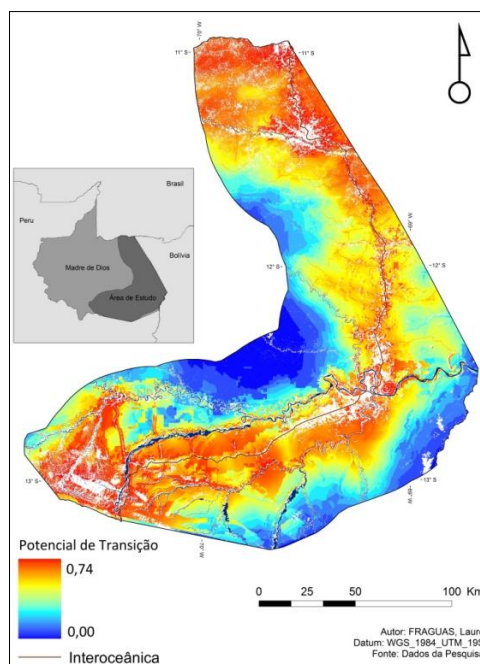


Figura 4: Mapa de potencial de transição de floresta para não-floresta.

De modo semelhante à transição anterior, o potencial de mudança de áreas de não-floresta para floresta é representado pela equação obtida pela regressão logística descrita na tabela 4. O mapa de potencial de transição pode ser visualizado na Figura 5.

Tabela 4: Coeficientes da equação obtida da regressão logística para cálculo do potencial de transição de não-floresta para floresta.

Variáveis	Coefficiente
Intercepto	-0,41861496
Presença Áreas Protegidas Integrais	-0,00000284
Presença Áreas Protegidas Uso Sustentável	0,00001678
Distância à Rodovia Interoceânica	0,00002231
Distância às Estradas Secundárias	-0,000014
Distância às Estradas Terciárias	0,00003169
Distância às Estradas Ribeirinhas	-0,00003268
Distância ao Rio Madre de Dios	0,00001737
Distância a Rios Secundários	0,00002171
Distância a Concessões Florestais	0,00001688
Presença de Concessões Florestais	-0,00251457
Distância a Concessões de Mineração	-0,0000208
Presença de Concessões de Mineração	0,00145126
Presença da Rodovia Interoceânica	-0,69704908
Distância dos Lotes Agrícolas	0,00000785
Presença dos Lotes Agrícolas	-0,5792292
Classes de Solos	0,03174386
Presença da Rodovia Interoceânica	0,00244304
Tipo de Vegetação	-0,03219034
Presença de Área Urbana	-1,56976473

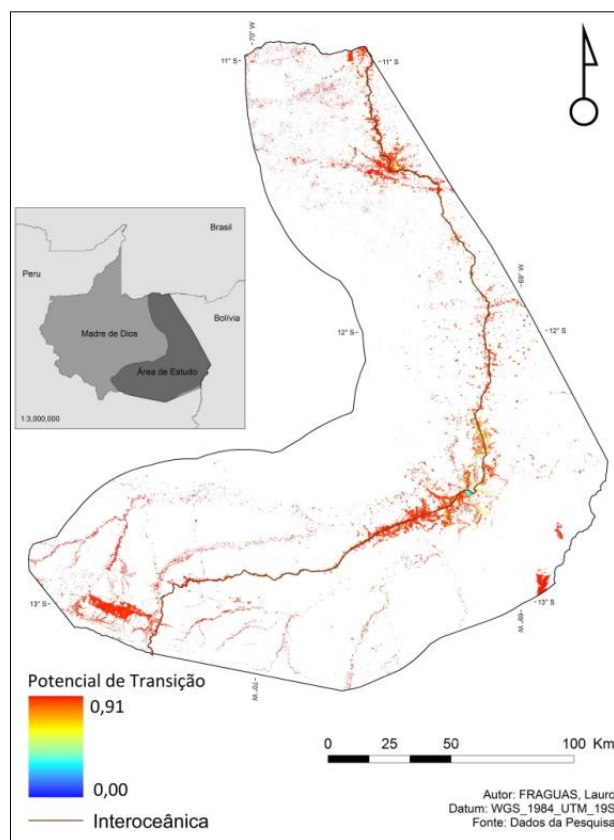


Figura 5: Mapa de potencial de transição de não-floresta para floresta.

Os fatores que mais influenciam nesta transição, que pode ser interpretada como a capacidade de regeneração da floresta são as funções inversas das distancias das áreas urbanas, da Interoceânica e dos lotes agrícolas, ou seja, as áreas de não-floresta distante desses elementos possuem uma probabilidade maior de se regenerar do que as que estão contidas contidas ou mais próximas delas. Desta maneira, nota-se pelo mapa (Figura 5) que as regiões mais afastadas da rodovia, principalmente ao norte são as que possuem maior potencial de transição. As regiões próximas das estradas, centros urbanos e lotes agrícolas possuem potencial de transição próximo de nulo.

Posteriormente à confecção dos dois sub-modelos, é possível realizar a predição de mudanças. Para validar o modelo, aplica-se o modelo para o ano de 2011. Assim, obtém-se o mapa de predição para o ano de 2011 (Figura 6), que possui áreas de floresta e não-floresta muito próximas das obtidas pela classificação das imagens de 2011 (Tabela 5).

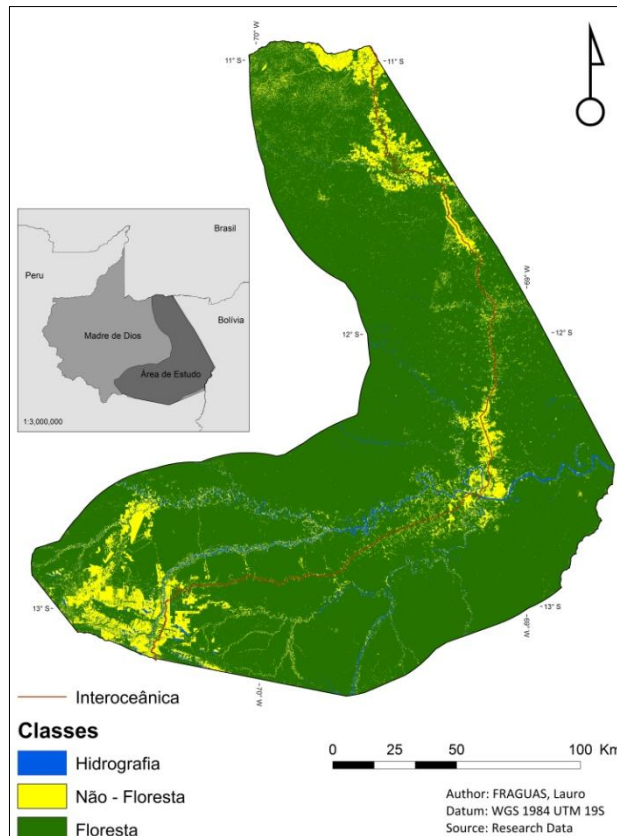


Figura 6: Mapa de simulação das mudanças de uso da terra para o ano de 2011.

Tabela 5: Comparativo entre a imagem de 2011 gerada pela classificação das imagens de satélite e a predição modelada em quilômetros quadrados.

Imagem	Área de Floresta	Área de Não-Floresta
2011 Classificada	25715	3119
2011 Predita	25878	3056

A validação ocorreu por meio dos índices fuzzy kappa calculados por meio do software MCK obtiveram os seguintes resultados

Tabela 6: Índices kappa para comparação entre a imagem de 2011 gerada pela classificação das imagens de satélite e a predição modelada.

Kappa	Klocation	Khisto
0,876	0,889	0,985

Devido ao alto valor do índice kappa, conclui-se que as duas imagens são muito semelhantes no quantitativo de cada uma das classes e apresentam o mesmo padrão de distribuição das áreas desmatadas, não sendo necessário aplicar um fator de correção para calibrar o modelo. No entanto a imagem classificada possui uma maior distribuição de não-floresta, alcançando distâncias maiores dos fatores que aumentam o potencial de

desmatamento. Na imagem predita, observa-se uma concentração muito mais intensa do desmatamento próximo aos fatores que potencializam o crescimento das áreas de não-floresta.

Assim, aplica-se o mesmo modelo, desta vez com o horizonte preditivo até o ano de 2020 (Figura 7). Observa-se que o desmatamento manteve os mesmo padrões observados anteriormente, sendo que a área de floresta equivale a 24.134,66 Km² e a área de não-floresta é de 4.599,76 Km². No entanto o sub-modelo de transição de regeneração está superdimensionado a longo prazo, visto que algumas áreas da rodovia e regiões de centros urbanos consolidados foram transformadas em regiões de floresta.

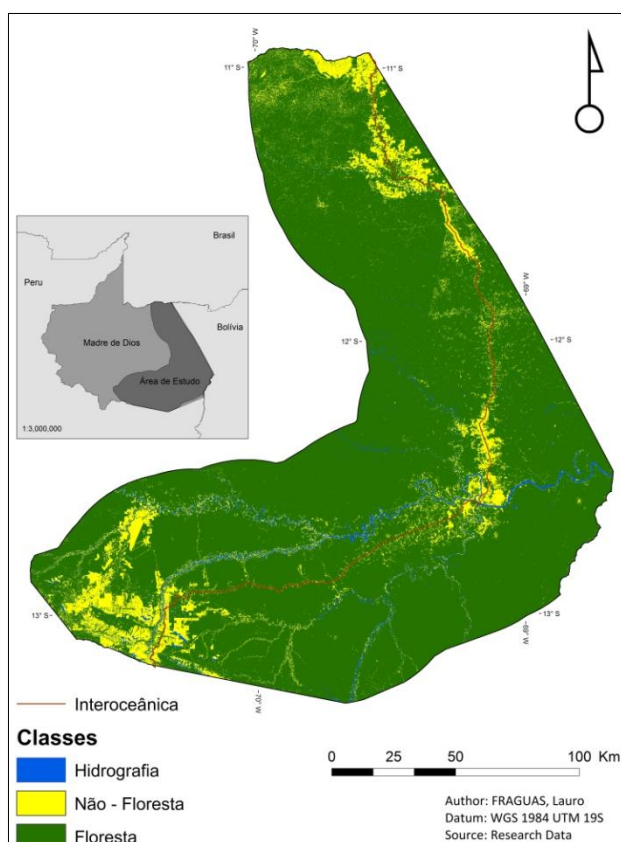


Figura 7: Mapa de simulação das mudanças de uso da terra para o ano de 2020.

O desmatamento do ano de 2020 em relação ao observado em 2011 foi de 1480,76 km² quadrados. O que representa uma taxa considerável, visto que o horizonte preditivo é de apenas 9 anos, em uma área de influência limitada a 50 quilômetros de distância da rodovia dentro dos domínios de Madre de Dios.

Ressalta-se também que o modelo foi confeccionado por meio do cálculo das taxas de mudança entre os anos de 2001 e 2006, que apresentaram excelentes valores para predizer o uso da terra para o ano de 2011. No entanto, a possibilidade de aumento das taxas de mudança pelo aquecimento econômico associado ao superdimensionamento das taxas de

regeneração podem ocasionar uma taxa líquida de desmatamento subestimada ao modelar o uso da terra para o ano de 2020.

5- CONSIDERAÇÕES FINAIS

As classificações automáticas supervisionadas apresentaram bons resultados, com desempenho médio superior a 98%, o que proporcionou imagens com quantificação de áreas de floresta e não-floresta confiáveis para a aplicação no modelo e validação das predições.

Os modelos de dinâmica do uso da terra são s ferramentas úteis para auxiliar nas decisões políticas, econômicas e ambientais para uma região. O Departamento de Madre de Dios vem sofrendo com o aumento da pressão do uso econômico da floresta e este modelo apresentado pode auxiliar os órgãos competentes nestas decisões. Apesar das limitações do modelo já discutidas, ele possui resultados relevantes ao ser validado por comparação com o uso da terra atual. Para aperfeiçoamento do modelo confeccionado, sugere-se, em sua próxima versão, a inserção de variáveis sócio-econômicas, visando prever possíveis avanços nas taxas de transição devido a contextos que não podem ser explicados simplesmente por variáveis físicas. Também é sugerido verificar se a inserção de variáveis econômicas podem resolver a regeneração superestimada a longo prazo ou se será necessária a escolha de outras variáveis para este sub-modelo.

Pela predição realizada para o ano de 2020, as regiões fronteiriças com o Brasil, os arredores da capital Puerto Maldonado e a região de concessões minerais ao sul merecem atenção especial dos poderes públicos, visto o crescimento acelerado do desmatamento, que chega a extrapolar em muito a influência da distância das estradas como fator de desmatamento em relação às demais áreas da região estudada.

6- REFERÊNCIAS

ACCA, **Base de Dados Catográficos**. Lima, Peru, 2010.

ALVAREZ, N., **Deforestation in the southeastern Peruvian Amazon: Linking remote sensing analysis to local views of landscape change**. Unpublished Master's Thesis, University of Wisconsin, Madison, 2001.

ALVAREZ, N., & NAUGHTON-TREVES, L., **Linking national agrarian policy to deforestation in the Peruvian Amazon: A case study of Tambopata,1986–1997**. *Ambio*, 23, 269–274, 2003.

ANTUNES, M. A. H. ; FREIRE, R. M. B. ; BOTELHO, A. S. ; TONIOLLI, L. H. . Correções Atmosféricas de Imagens de Satélites Utilizando o Modelo 6S. In: XXI Congresso Brasileiro de Cartografia, 2003, Belo Horizonte. **Anais do XXI Congresso Brasileiro de Cartografia**, 2003.

ASPINALL, J.R., HILL M. J., **Land Use Change: Science, Policy and Management**. CRC Press, Boca Raton, 2003, 185p.

BECKER, B. K. **Amazônia - Geopolítica na Virada do III Milênio**. Rio de Janeiro: Editora Garamond, 2006. v. 1. 172 p.

CHAVEZ, A., **Public policy and spatial variation in land use and cover in the southeastern Peruvian Amazon**. Ph.D. Dissertation, University of Florida, Gainesville, 2009.

COELHO, A. S., **Modelagem de Dinâmica do Uso da Terra e Cobertura Vegetal na Região de Santarém, Oeste Pará**. Universidade Federal do Pará. Dissertação de Mestrado, 2009.

CONSERVAÇÃO INTERNACIONAL DO BRASIL. (Dados de cobertura da terra classificados em Imagens Landsat Enhanced Thematic Mapper Plus (ETM+). In: [http://www.conservation.org.br/..](http://www.conservation.org.br/)

EASTMAN, J.R. IDRISI Andes: **Guide to GIS and Image Processing**. Worcester: ClarkLabs. 2006. 327 p.

EASTMAN, J. R., W. JIN, P. A. K. KYEM, J. TOLEDANO. Raster Procedures for Multi-Criteria/Multi-Objective Decisions. **Photogrammetric Engineering and Remote Sensing**. 1995. 61(5), 539-547

FEARNSIDE, P. M., LASHOF, D. A., & MOURA-COSTA, P. **Accounting for time in mitigating global warming through land-use change and forestry**. *Mitigation and Adaptation Strategies for Global Change*, 5(3), 239–270, 2000.

FEARNSIDE, P. M., Desmatamento na Amazônia: dinâmica, impactos e controle. **Acta Amazonica**. 36(3): 395 – 400, 2006.

LAMBIN, E.F., GEIST,H.J., **Land-Use and Land-Cover Change. Local Processes and Global Impacts, Global Change**, The IGBP Series. Springer, 2006.

LAURENCE, W.F.; COCHRANE, M.A.; BERGEN, S.; FEARNSTIDE, P.M.; DELAMONICA, P.; BARBER, C.; D'ANGELO, S.; FERNANDES, T. 2001, **The future of the Brazilian Amazon: Development trends and deforestation**. *Science*, 291, 438–439

MILNE, E., ASPINALL, R.J, VELDKAMP, T.A. Integrated modelling of natural and social systems in land change science. **Landscape Ecology** 24:1145–1147, 2009.

MYERS, N., Tropical deforestation: rates and patterns. In: Brown, K., Pearce, D.W. (Eds.), **The Causes of Tropical Deforestation**. University College London Press, London, UK, pp. 27±40, 2004.

NAGENDRA, H.; MUNROE, D.K., SOUTHWORTH, J., From pattern to process: landscape fragmentation and the analysis of land use/land cover change. **Agriculture, Ecosystems and Environment** 101: 111–115, 2004.

NAUGHTON-TREVES, L., **Deforestation and carbon emissions at tropical frontiers: A case study from the Peruvian Amazon**. *World Development* 32, 173–190, 2004.

NEPSTAD, D., SOARES-FILHO, B., MERRY, F., LIMA, A., MOUTINHO, P., CARTER, J., BOWMAN, M., CATTANEO, A., RODRIGUES, H., SCHWARTZMAN, S., MCGRATH, D., STICKLER, C., LUBOWSKI, R., PIRIS-CABEZAS, P., RIVERO, S., ALENCAR, A., ALMEIDA, O., STELLA, O., **The end of deforestation in the Brazilian Amazon**. *Science* 326, 1350–1351, 2009.

OLIVEIRA, P. J. C., ASNER, G. P., KNAPP, D. E. ALMEYDA, A., GILDEMEISTER, R. G., KEENE, S., RAYBIN, R. F., SMITH, R. C. Land-Use Allocation Protects the Peruvian Amazon. **Science** 317: 1233 -1255, 2007.

PERZ, S. G.; ARAMBURÚ, C.; BREMNER, J., Population, land use and deforestation in the pan Amazon basin: a comparison of Brazil, Bolivia, Colombia, Ecuador, Peru and Venezuela. **Environment, Development and Sustainability**, v. 7, n. 1, p. 23-49, 2005.

PERZ, S., BRILHANTE, S., BROWN, F., CALDAS, M., IKEDA, S., MENDOZA, E., OVERDEST, C., REIS, V., REYES, J. F., ROJAS, D., SCHIMINK, M., SOUZA, C., WALKER, R., Road building, land use and climate change: prospects for environmental governance in the Amazon. **Trans. R. Soc. B** 363: 1889–1895, 2008.

PONTIUS Jr., R.G. Statistical Methods to Partition Effects of Quantity and Location During Comparison of Categorical Maps at Multiple Resolutions. **Photogrammetric Engineering & Remote Sensing**. October 2002. 1041-1039 p.

RUHOFF, A. L., CRUZ, I. F., COLLISCHONN, W. . Modelos de simulação dinâmica do desmatamento na Amazônia. **Caminhos de Geografia (UFU)**, v. 11, p. 258-268, 2010.

SHIBA, M. H., SANTOS, R.L., QUINTANILHA, J. A., KIM, H. Y., Classificação de Imagens de Sensoriamento Remoto pela Aprendizagem por Árvore de Decisão: Uma Avaliação de Desempenho. **Anais XII Simpósio Brasileiro de Sensoriamento Remoto**, Goiania, Brasil, 2005.

SOARES-FILHO B. et al., Simulating the response of land-cover changes to road paving and governance along a major Amazon highway: the Santarém-Cuiabá corridor. **Global change biology**. n. 10:745–764, 2004.

SOARES-FILHO, B. S., NEPSTAD, D., CURRAN, L., et al, **Cenários de desmatamento para Amazônia**. Estudos Avançados, São Paulo, v. 19, n. 54, p. 138-152, 2005.

SOARES-FILHO, B.S., NEPSTAD, D.C., CURRAN, L.M., CERQUEIRA, G.C., GARCIA, R.A., RAMOS, C.A., VOLL, E., MCDONALD, A., LEFEBVRE, P., SCHLESINGER, P., **Modelling conservation in the Amazon basin**. Nature 440, 520–523, 2006.

SOARES-FILHO, B.S.; NEPSTAD, D.C.; CURRAN, L.; CERQUEIRA, G.; GARCIA, R.A.; RAMOS, C.A.; LEFEBVRE, P.; SCHLESINGER, P.; VOLL, E.; MCGRATH, D., Cenários de desmatamento para Amazônia. **Estudos Avançados** 19(54): 138-152, 2005.

SOUTHWORTH J., MARSIK M., QIU Y., PERZ S., CUMMING G., STEVENS F., ROCHA K., DUCHELLE A., BARNES G. Roads as Drivers of Change: Trajectories across the Tri-National Frontier in MAP, the Southwestern Amazon. **Remote Sensing**. 3(5):1047-1066, 2011.

TURNER, M.G., GARDNER, R.H., O'NEILL, R.V., **Landscape Ecology in theory and practice: pattern and process**. Springer Science, New York, 2001, 404p.

VELDKAMP, T.A., VERBURG, P.H., Modelling land use change and environmental impact. **Journal of Environmental Management** 72: 1–3, 2004.

VERMONT, E.F.; D. TANRÉ, J. L. DEUZÉ, M. HERMAN, J.-J. MORCRETE, Second Simulation of the Satellite Signal in the Solar Spectrum, 6S: An overview. **IEEE Transactions on Geoscience and Remote Sensing**. Vol. 35. N. 3, pp 675– 686, 1997.

VISSER, H. (Ed). **The MAP COMPARISON KIT: methods, software and applications**. RIVM report 550002005/2004. Bilthoven: RIVM. 2004. 127 p.

ZAMBRANO, A.M.; BROADBENT, E.N.; SCHMINK, M.; PERZ, S.G.; ASNER, G.P.
Deforestation drivers in southwest Amazonia: Comparing smallholder farmers in Inapari,
Peru and Assis Brasil, **Brazil. Conserv. Soc.**, 8, 157–170, 2008.

7- ANEXOS

ANEXO A – Output da Regressão Logística do Sub-Modelo de Transição de Floresta para Não-Floresta Realizada pelo Sotware IDRISI

Logistic Regression Results:

Regression Equation :

$$\begin{aligned} \text{logit(LCM_Train_flore_to_desma)} = & -2.8754 + 0.000023*\text{areas_protegidas_integ} - \\ & 0.000048*\text{areas_protegidas_usust} - 0.000012*\text{dist_estradas_intero} - 0.000046* \\ & *\text{dist_estradas_sec} - 0.000029*\text{dist_estradas_terc} + 0.000006*\text{dist_estradas_hidro} + \\ & 0.000032*\text{hidrografia_madre} - 0.000029*\text{hidrografia_outros} + 0.000001*\text{conc_florestais} + \\ & 0.001036*\text{conc_florestais_nodist} + 0.000004*\text{conc_mineracao} - \\ & 0.003459*\text{conc_mineracao_nodist} + 0.351817*\text{interoceantica_nodist} - 0.000005*\text{lotas} + \\ & 0.810847*\text{lotas_nodsit} + 0.052747*\text{solos} - 0.002380*\text{todas_estradas} + 0.041253*\text{vegetacao} \\ & + 0.249696*\text{urbano} \end{aligned}$$

Individual Regression Coefficient

Variables	Coefficient
Intercept	-2,87544664
areas_protegidas_integ	0,00002261
areas_protegidas_usust	-0,00004780
dist_estradas_intero	-0,00001188
dist_estradas_sec	-0,00004590
dist_estradas_terc	-0,00002928
dist_estradas_hidro	0,00000573
hidrografia_madr	0,00003209
hidrografia_outros	-0,00002869
conc_florestais	0,00000101
conc_florestais_nodist	0,00103585
conc_mineracao	0,00000378
conc_mineracao_nodist	-0,00345903
interoceantica_nodist	1,35181728
lotas	-0,00000547
lotas_nodsit	0,81084687
solos	0,05274745
todas_estradas	-0,00238027
vegetacao	0,04125292
urbano	0,24969630

Regression Statistics :

Number of total observations = 1813043
 Number of 0s in study area = 1726553
 Number of 1s in study area = 86490
 Percentage of 0s in study area = 95,2296
 Percentage of 1s in study area = 4,7704

Number of auto-sampled observations = 174261
 Number of 0s in sampled area = 165846
 Number of 1s in sampled area = 8415
 Percentage of 0s in sampled area = 95,1710
 Percentage of 1s in sampled area = 4,8290

-2logL0 = 67420,8995
 -2log(likelihood) = 58944,4013
 Pseudo R_square = 0,1257
 Goodness of Fit = 171086,2077
 ChiSquare(19) = 8476,4982

Means and Standard Deviations

	Mean	Standard Deviation
areas_protegidas_integ	63159,827334	57466,941076
areas_protegidas_usust	50437,475218	53374,807490
dist_estradas_intero	23424,684244	14110,841306
dist_estradas_sec	9571,416978	9637,353416
dist_estradas_terc	12877,863171	10424,826431
dist_estradas_hidro	81220,504978	40627,114725
hidrografia_madre	49398,817842	44965,309362
hidrografia_outros	11558,452184	10220,043872
conc_florestais	38015,077011	35858,168147
conc_florestais_nodist	212,871457	94,476912
conc_mineracao	14906,924412	15266,308794
conc_mineracao_nodist	214,662828	92,836436
interoceantica_nodist	0,000494	0,022210
lotes	11168,332404	10061,926099
lotes_nodsit	0,048198	0,214185
solos	5,268838	3,335277
todas_estradas	252,016688	27,296420
vegetacao	11,586827	5,154783
urbano	0,000132	0,011488
LCM_Train_flore_to_desma	0,048290	0,214378

Classification of cases & odds ratio

Observed	Fitted_0	Fitted_1	Percent Correct
0	165823	23	99.9861
1	8395	20	0.2377

Odds Ratio = 17.1762

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 = 0.1542

Classification of cases & odds ratio by using the new threshold

Observed	Fitted_0	Fitted_1	Percent Correct
0	159222	6624	96.0059
1	6624	1791	21.2834

Adjusted Odds Ratio = 6.4992

True Positive = 98.8411%

False Positive = 3.9941%

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

ROC = 0.7805

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

ANEXO B — Output da Regressão Logística do Sub-Modelo de Transição de Não-Floresta para Floresta Realizada pelo Software IDRISI

Logistic Regression Results:

Regression Equation :

$$\begin{aligned} \text{logit(LCM_Train_flore_to_desma)} = & -0.4186 - 0.000003*\text{areas_protegidas} + \\ & 0.000017*\text{areas_protegidas_usust} + 0.000022*\text{dist_estradas_intero} - 0.000014* \\ & *\text{dist_estradas_sec} + 0.000032*\text{dist_estradas_terc} - 0.000033*\text{dist_estradas_hidro} + \\ & 0.000017*\text{hidrografia_madre} + 0.000022*\text{hidrografia_outros} + 0.001451*\text{conc_florestais} - \\ & 0.002515*\text{conc_florestais_nodist} - 0.000021*\text{conc_mineracao} + \\ & 0.001451*\text{conc_mineracao_nodist} - 0.697049*\text{interoceantica_nodist} + 0.000008*\text{lotas} + - \\ & 0.579229*\text{lotas_nodsit} + 0.031744*\text{solos} + 0.002443*\text{todas_estradas} - 0.032190*\text{vegetacao} \\ & - 1.569765*\text{urbano} \end{aligned}$$

Individual Regression Coefficient

Variables	Coefficient
Intercept	-0,41861496
areas_protegidas_integ	-0,00000284
areas_protegidas_usust	0,00001678
dist_estradas_intero	0,00002231
dist_estradas_sec	-0,00001400
dist_estradas_terc	0,00003169
dist_estradas_hidro	-0,00003268
hidrografia_madr	0,00001737
hidrografia_outros	0,00002171
conc_florestais	0,00001688
conc_florestais_nodist	-0,00251457
conc_mineracao	-0,00002080
conc_mineracao_nodist	0,00145126
interoceantica_nodist	-0,69704908
lotas	0,00000785
lotas_nodsit	-0,57922920
solos	0,03174386
todas_estradas	0,00244304
vegetacao	-0,03219034
urbano	-1,56976473

Regression Statistics :

Number of total observations = 165829
 Number of 0s in study area = 95870
 Number of 1s in study area = 69959
 Percentage of 0s in study area = 57,8126
 Percentage of 1s in study area = 42,1874

Number of auto-sampled observations = 15997
 Number of 0s in sampled area = 9388
 Number of 1s in sampled area = 6609
 Percentage of 0s in sampled area = 58,6860
 Percentage of 1s in sampled area = 41,3140

-2logL0 = 21691,3248
 -2log(likelihood) = 18474,9432
 Pseudo R_square = 0,1483
 Goodness of Fit = 16091,5074
 ChiSquare(19) = 3216,3816

Means and Standard Deviations

	Mean	Standard Deviation
areas_protegidas_integ	77425,526411	68297,938477
areas_protegidas_usust	63531,108770	64749,591003
dist_estradas_intero	15317,401825	14766,026868
dist_estradas_sec	5166,290930	7836,720620
dist_estradas_terc	8701,496718	8800,585226
dist_estradas_hidro	89316,187410	41146,492941
hidrografia_madre	63533,505532	55448,681771
hidrografia_outros	7857,539039	8802,609956
conc_florestais	29047,618991	34356,644912
conc_florestais_nodist	203,206039	102,341128
conc_mineracao	13199,629931	17460,258985
conc_mineracao_nodist	190,297243	110,674384
interoceantica_nodist	0,019379	0,137856
lotes	6256,195537	9057,794657
lotes_nodist	0,202788	0,402088
solos	5,769644	3,606939
todas_estradas	240,072826	59,643434
vegetacao	13,120273	5,685100
urbano	0,005501	0,073967
LCM_Train_flore_to_desma	0,413140	0,492413

Classification of cases & odds ratio

Observed	Fitted_0	Fitted_1	Percent Correct
----------	----------	----------	-----------------

0	7410	1978	78.9305
1	2802	3807	57.6033

Odds Ratio = 5.0899

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 = 0.4606

Classification of cases & odds ratio by using the new threshold

Observed	Fitted_0	Fitted_1	Percent Correct
----------	----------	----------	-----------------

0	6986	2402	74.4141
1	2402	4207	63.6556

Adjusted Odds Ratio = 5.0940

True Positive = 99.5033%

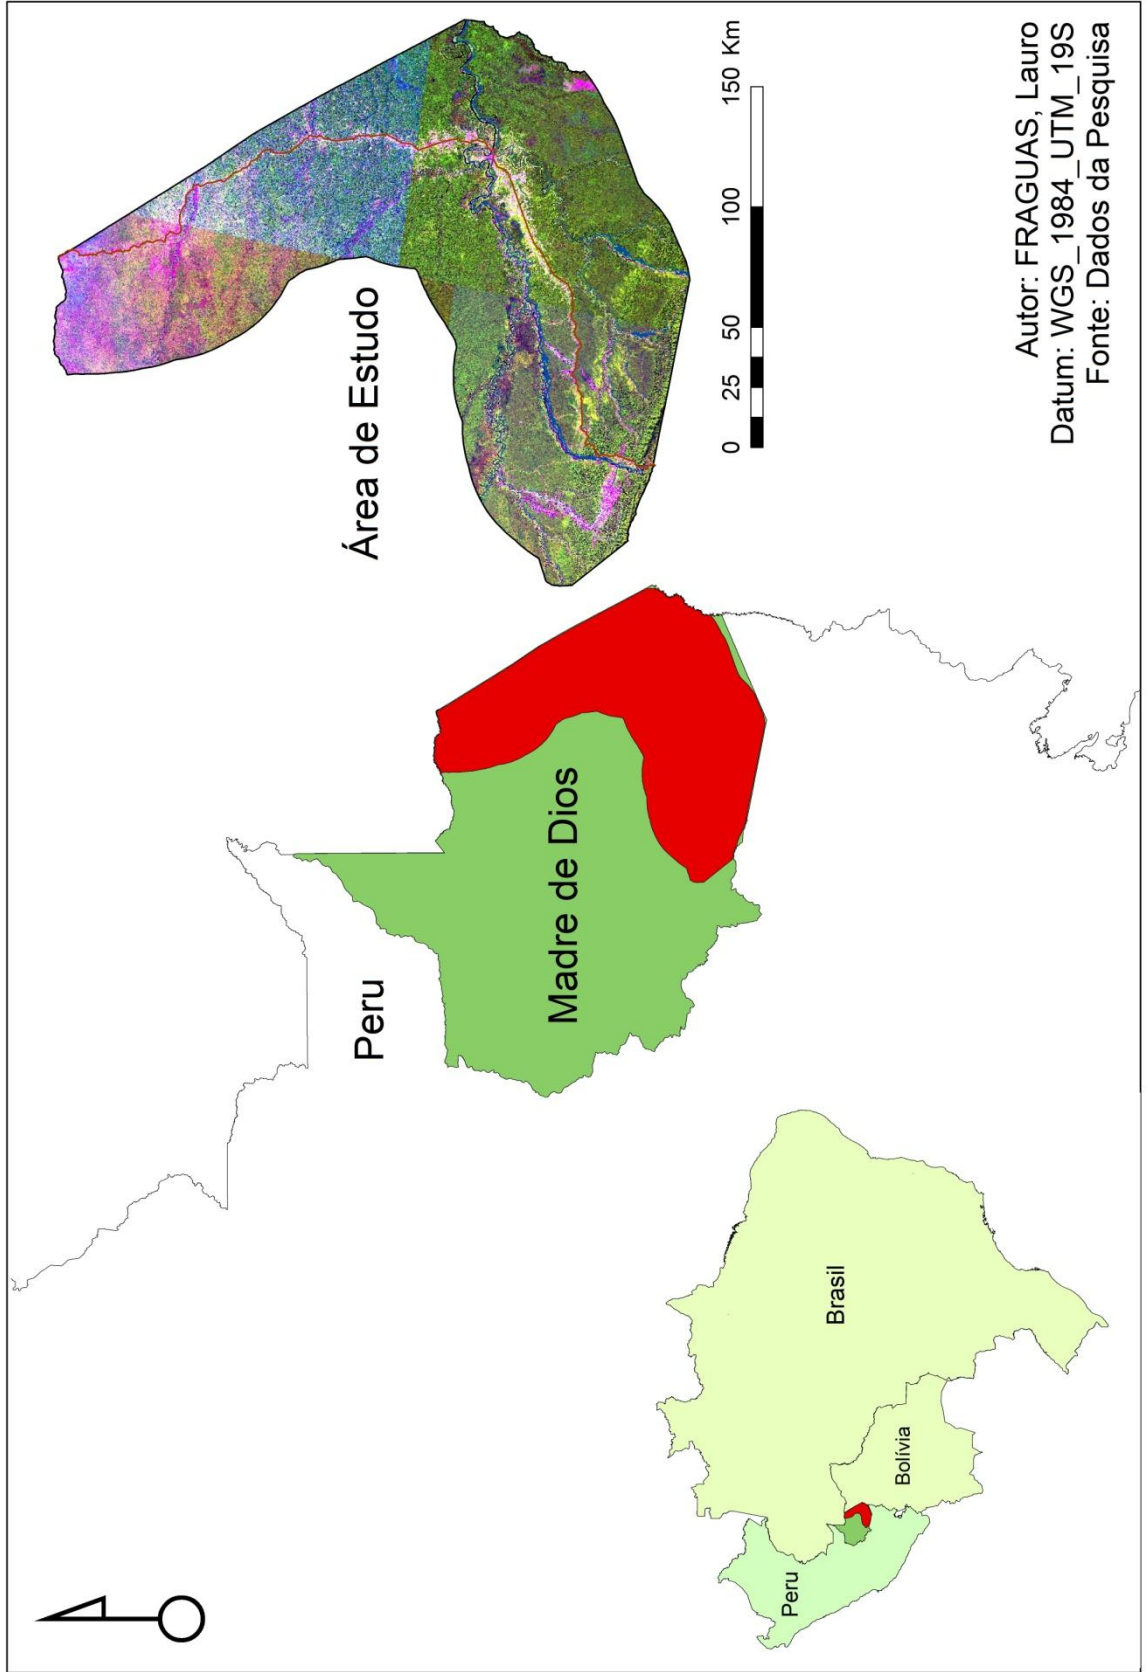
False Positive = 25.5859%

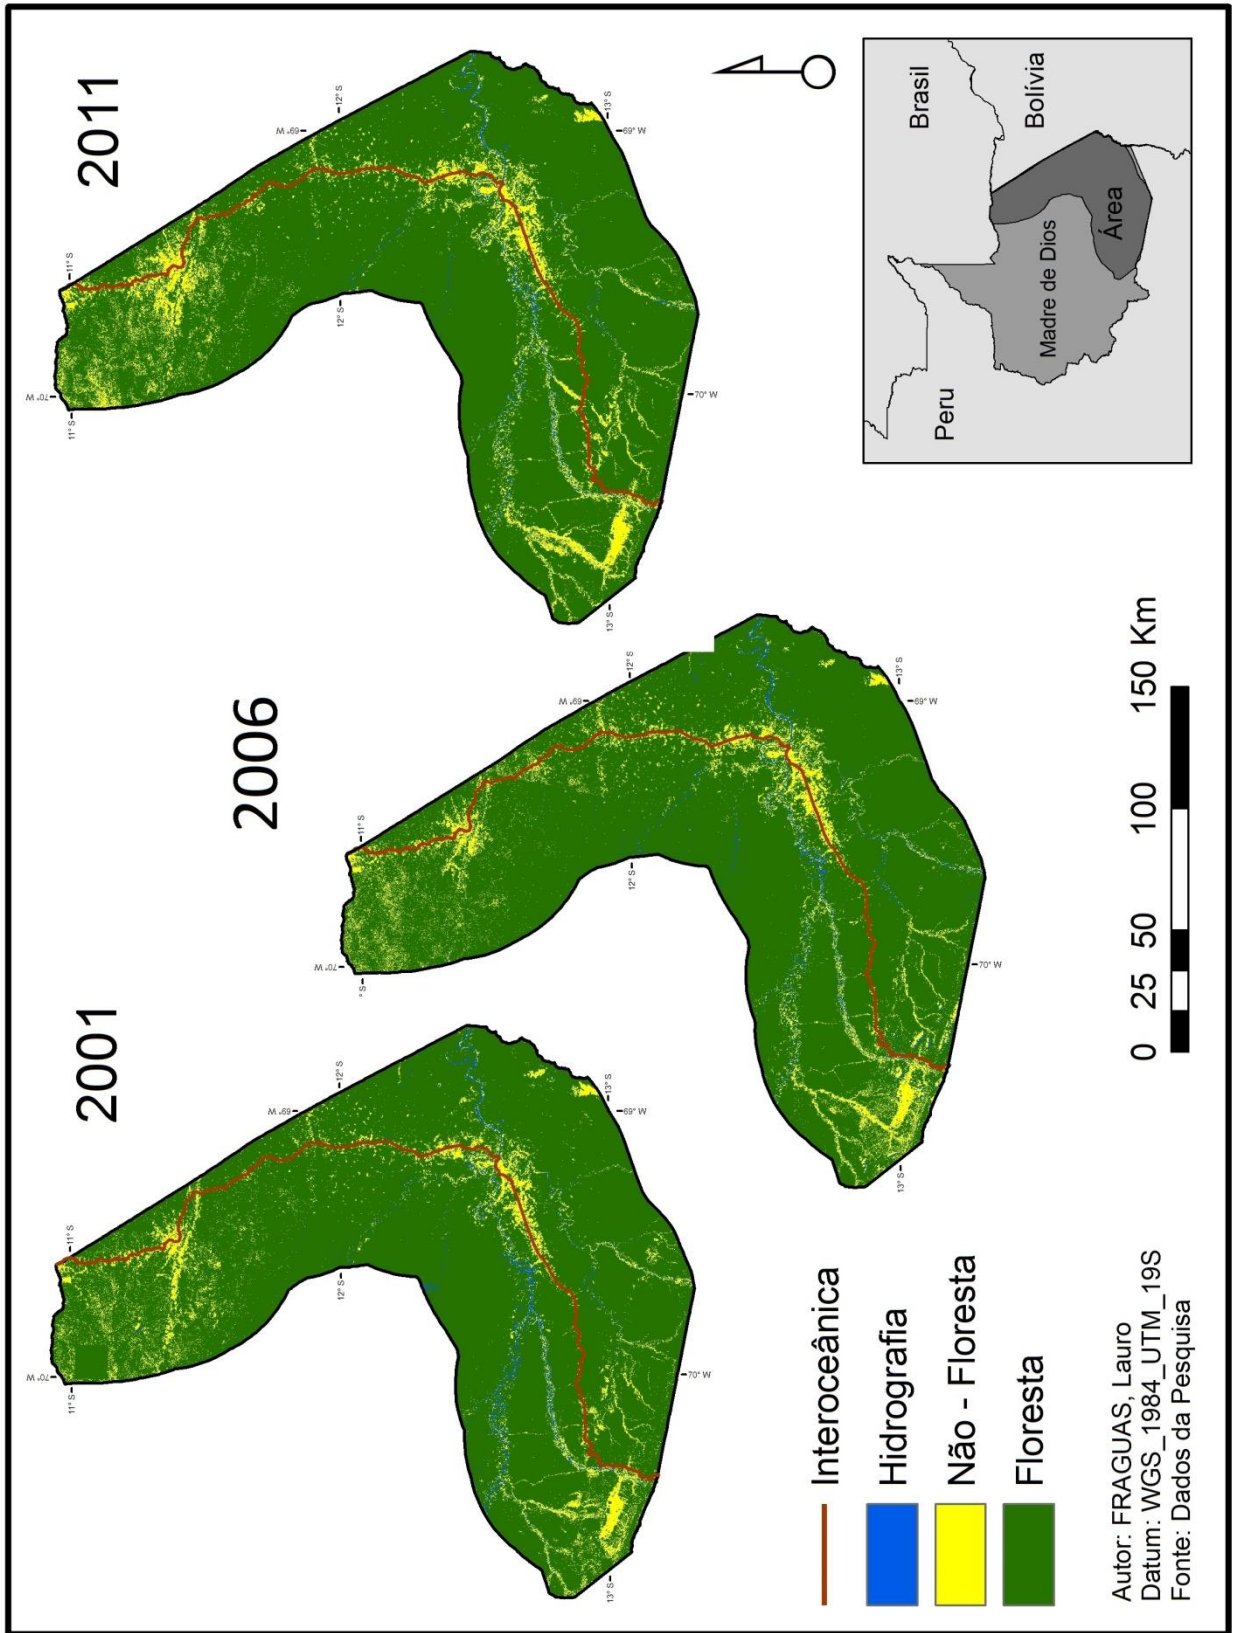
(2) ROC* Result with 100 thresholds (Sample-based computation when applicable):

ROC = 0.7549

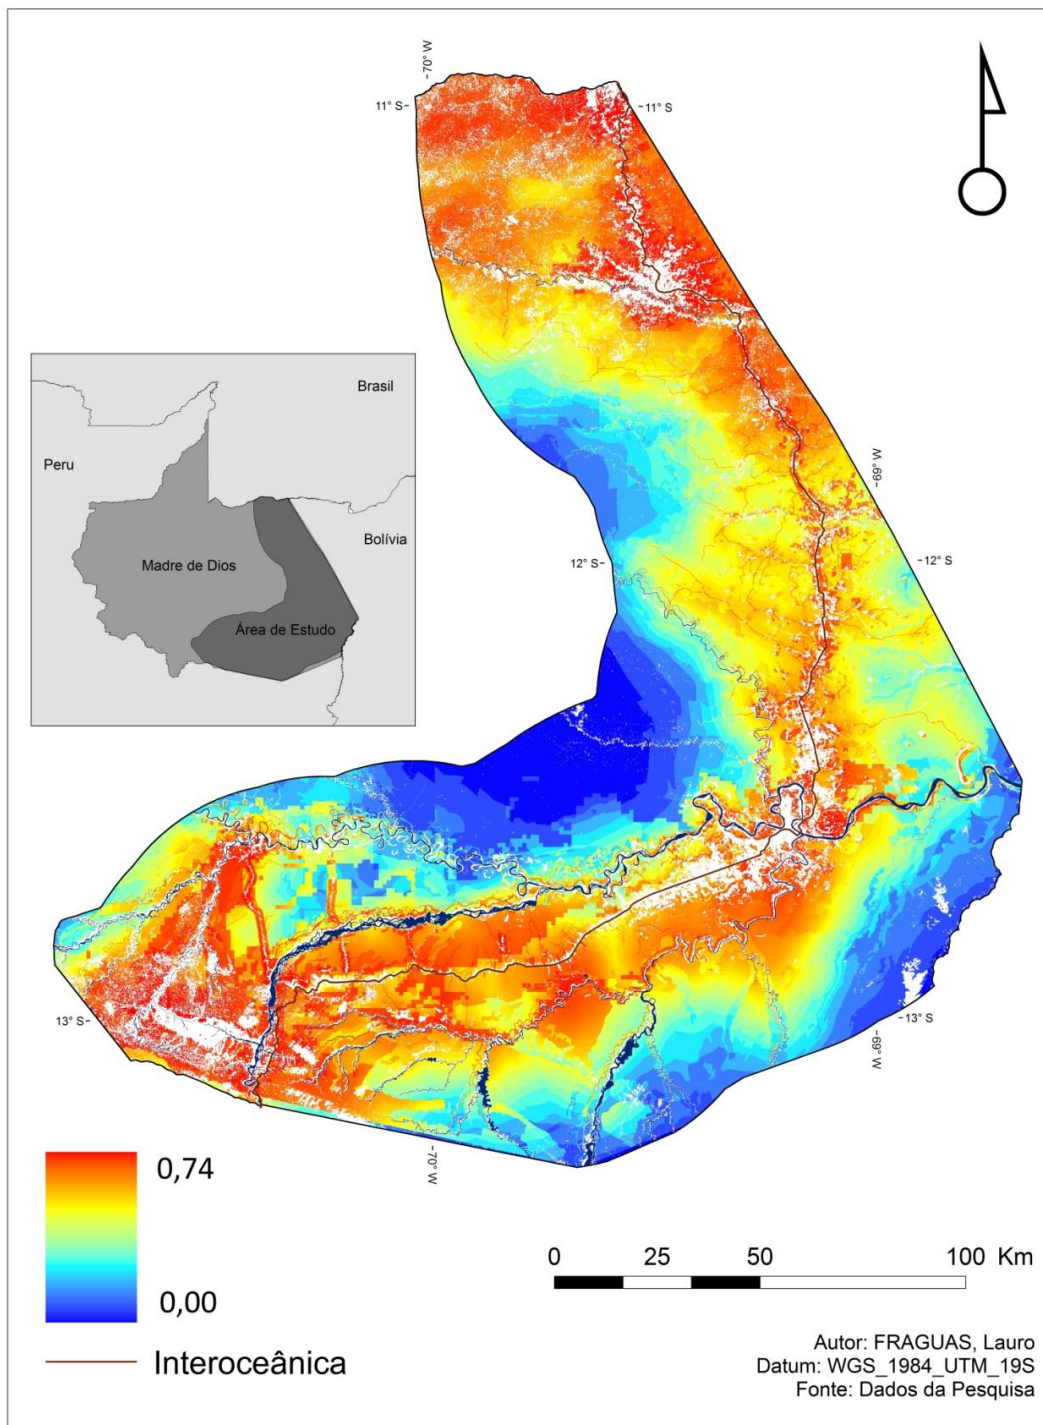
* ROC=1 indicates a perfect fit; and ROC=0.5 indicates a random fit.

Mapa de Localização - Madre de Dios - Peru

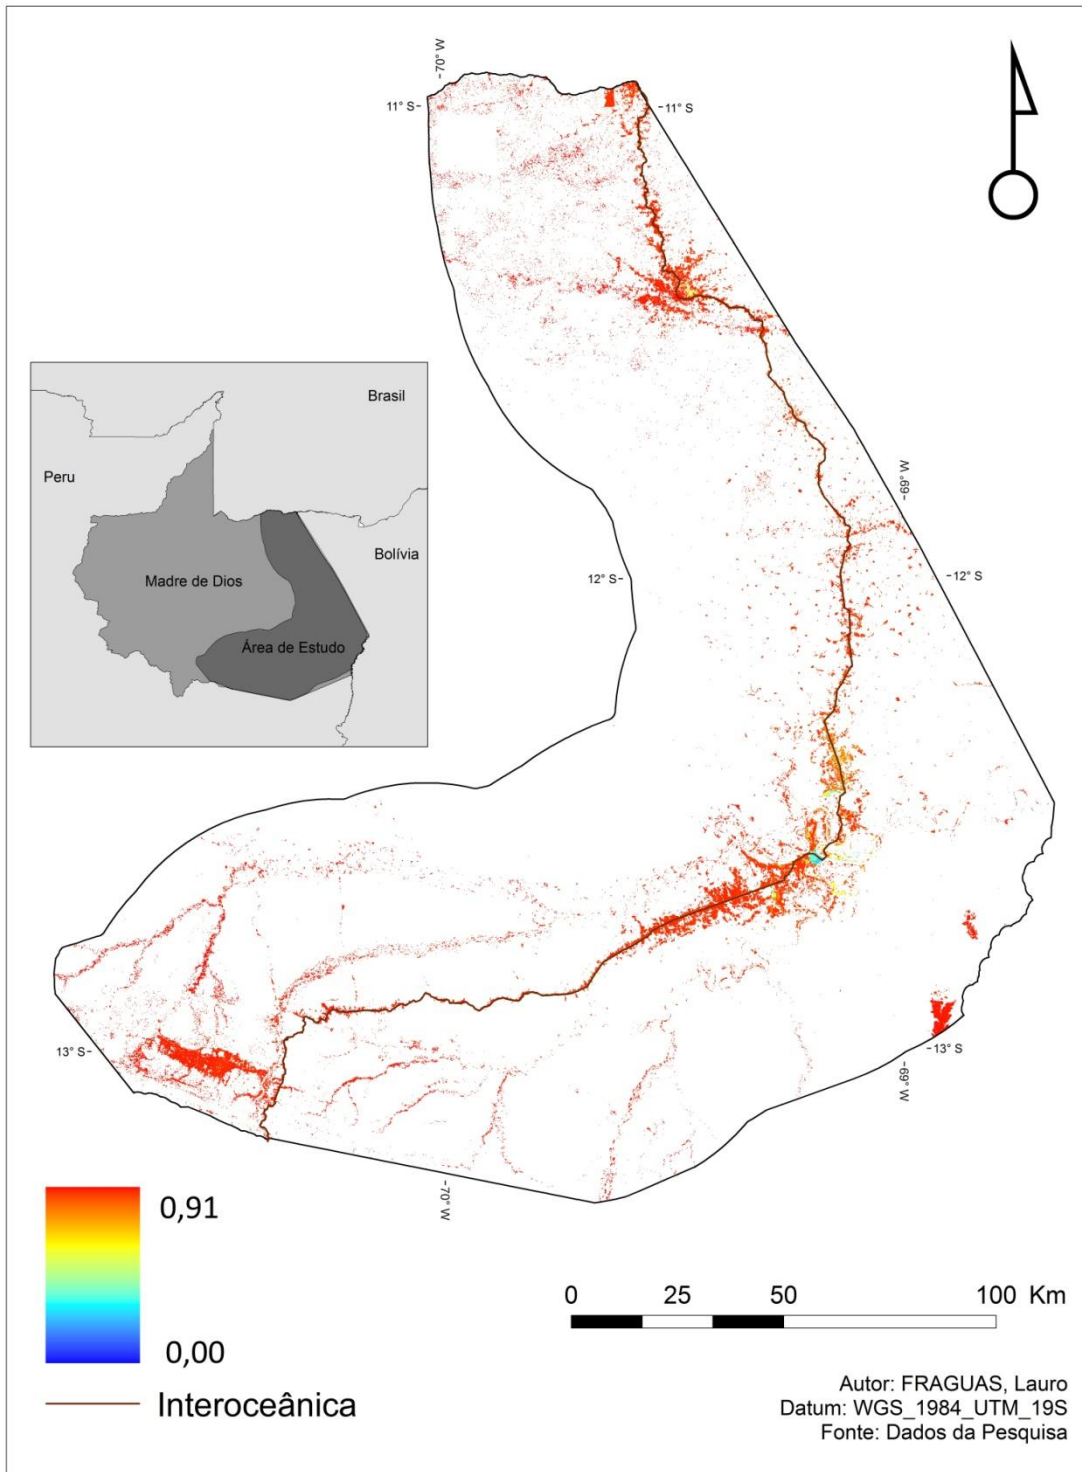




Mapa Pontencial de Transição Floresta para Não - Floresta Madre de Dios - Peru

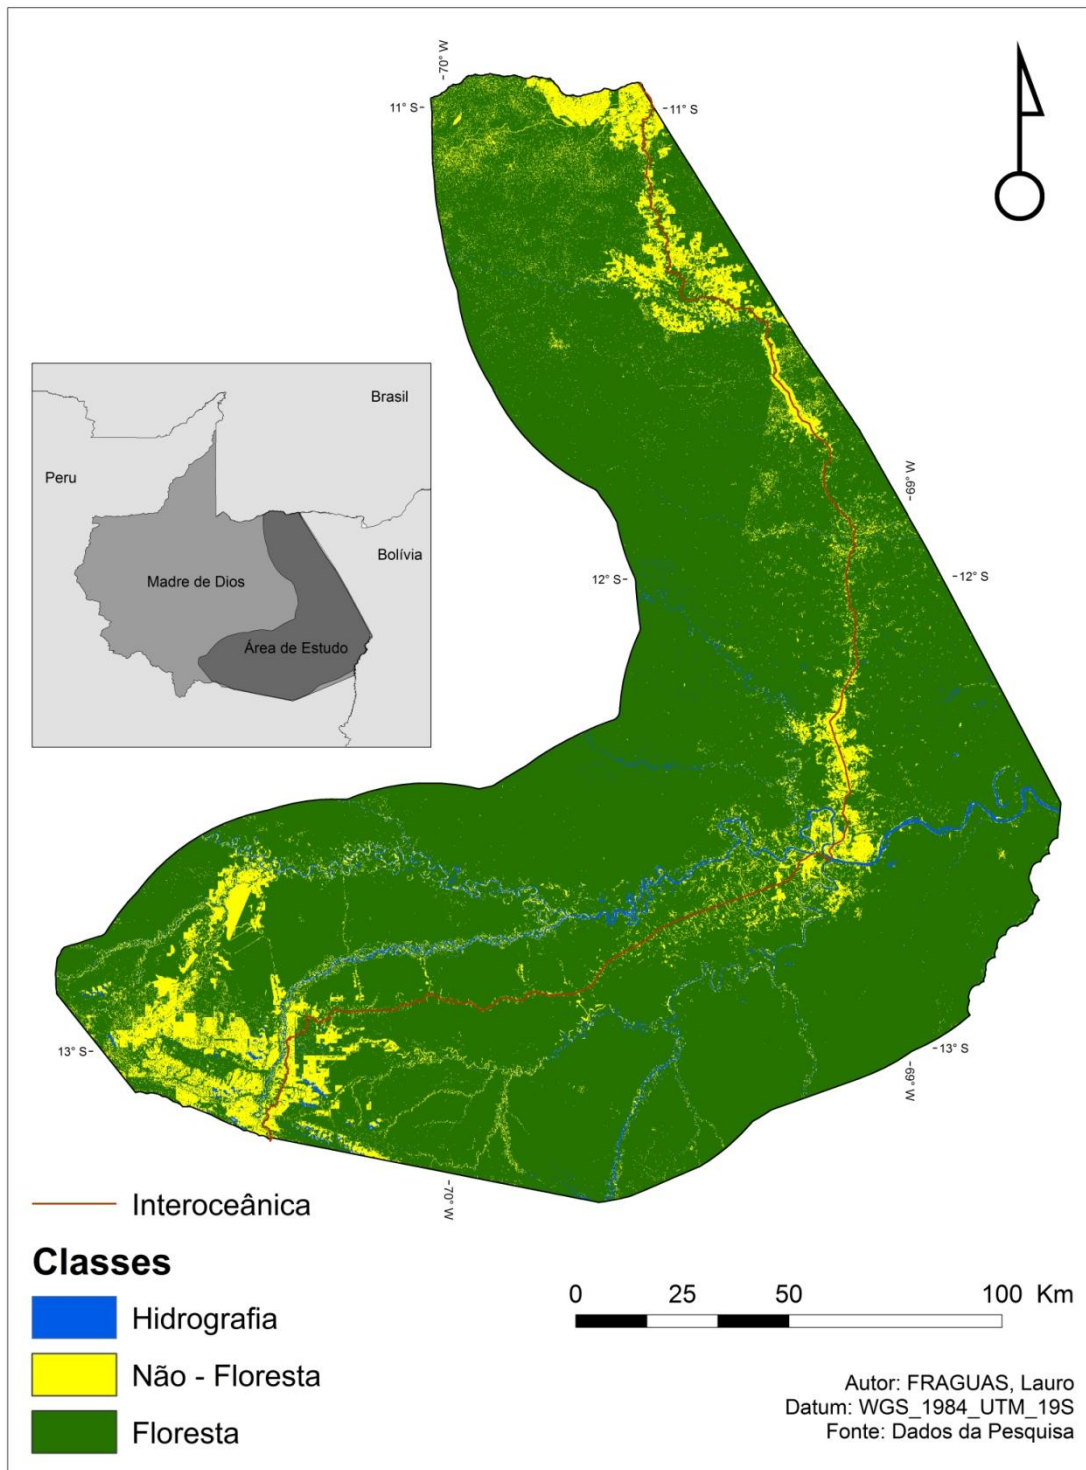


Mapa Pontencial de Transição Não - Floresta para Floresta Madre de Dios - Peru



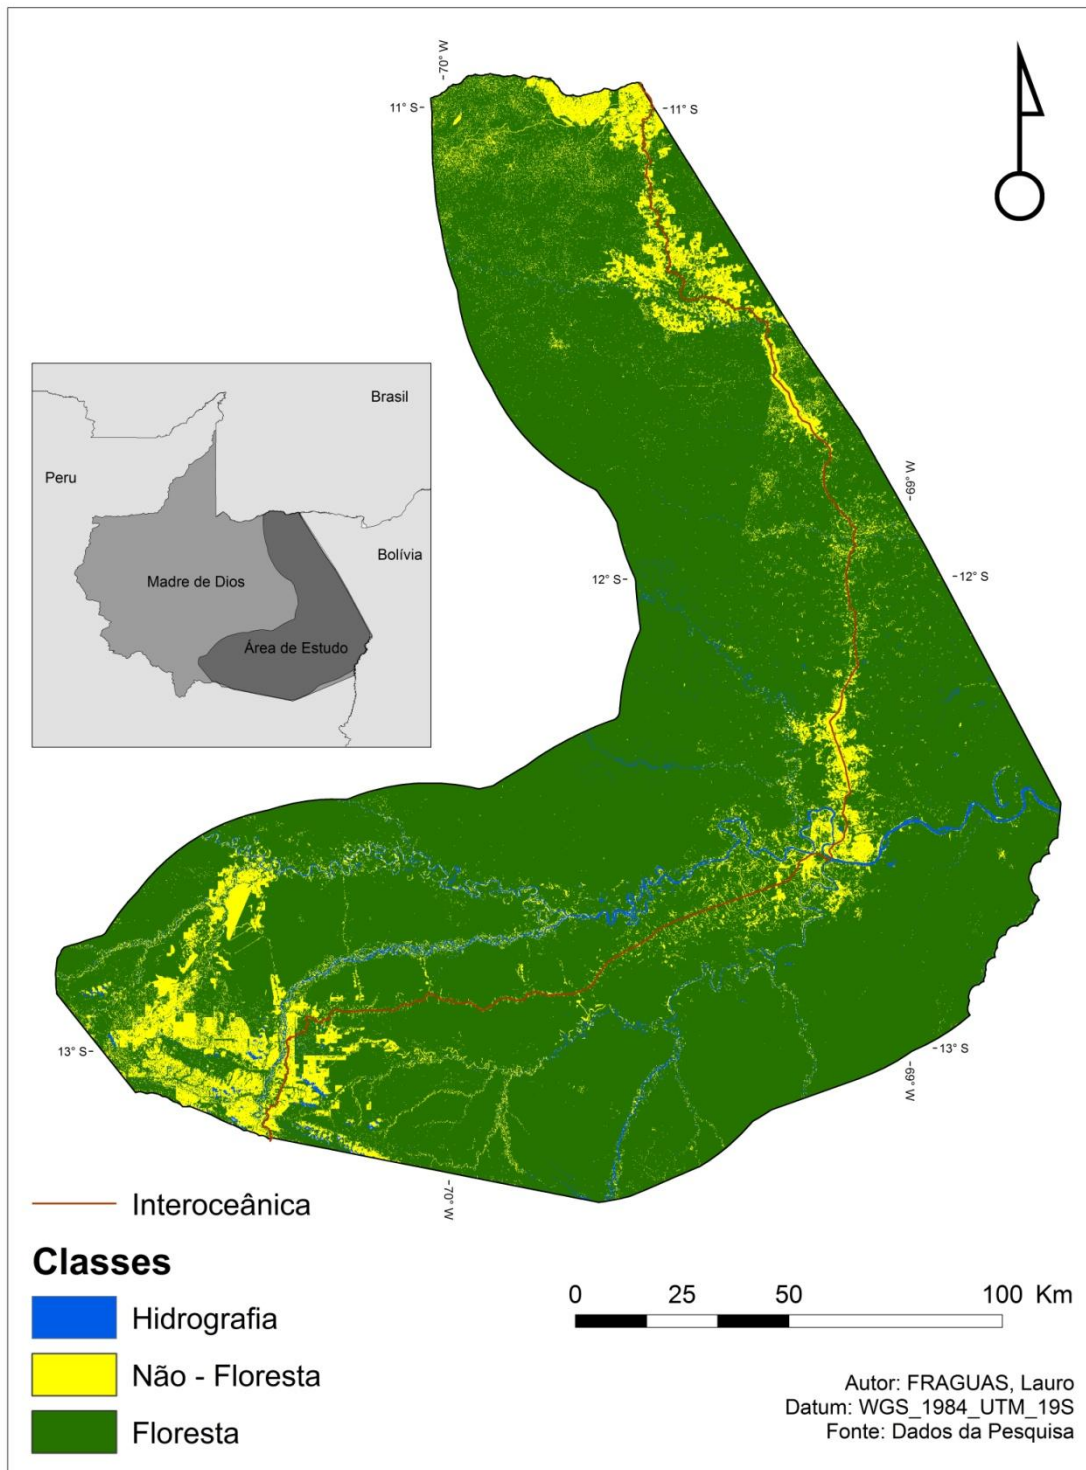
Mapa Predito - 2011

Madre de Dios - Peru



Mapa Simulado - 2011

Madre de Dios - Peru



Mapa Simulado - 2020

Madre de Dios - Peru

