

**UNIVERSIDADE FEDERAL DE MATO GROSSO
INSTITUTO DE FÍSICA
PROGRAMA DE PÓS-GRADUAÇÃO EM FÍSICA AMBIENTAL**

**ESTABELECIMENTO DE UM MODELO DE DETECÇÃO
DE INUNDAÇÃO NO PANTANAL NORTE A PARTIR DE
PRODUTOS DERIVADOS DE IMAGENS LANDSAT TM**

JÉSSICA DA SILVA LINHARES FREDERICO

Orientador: **Prof. Dr. PETER ZEILHOFER**

**Cuiabá, MT
Outubro de 2016**

**UNIVERSIDADE FEDERAL DE MATO GROSSO
INSTITUTO DE FÍSICA
PROGRAMA DE PÓS-GRADUAÇÃO EM FÍSICA AMBIENTAL**

**ESTABELECIMENTO DE UM MODELO DE DETECÇÃO
DE INUNDAÇÃO NO PANTANAL NORTE A PARTIR DE
PRODUTOS DERIVADOS DE IMAGENS LANDSAT TM**

JÉSSICA DA SILVA LINHARES FREDERICO

*Dissertação apresentada ao Programa de
Pós-Graduação em Física Ambiental da
Universidade Federal de Mato Grosso,
como parte dos requisitos para obtenção
do título de Mestre em Física Ambiental.*

Orientador: **Prof. Dr. PETER ZEILHOFER**

**Cuiabá, MT
Outubro de 2016**

Dados Internacionais de Catalogação na Fonte.

F852e Frederico, Jéssica da Silva Linhares.

Estabelecimento de um modelo de detecção de inundação no
Pantanal Norte a partir de produtos derivados de imagens
LANDSAT TM / Jéssica da Silva Linhares Frederico. -- 2016
40 f. : il. color. ; 30 cm.

Orientador: Peter Zeilhofer.

Dissertação (mestrado) - Universidade Federal de Mato Grosso,
Instituto de Física, Programa de Pós-Graduação em Física
Ambiental, Cuiabá, 2016.

Inclui bibliografia.

Ficha catalográfica elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).

Permitida a reprodução parcial ou total, desde que citada a fonte.

UNIVERSIDADE FEDERAL DE MATO GROSSO
INSTITUTO DE FÍSICA
Programa de Pós-Graduação em Física Ambiental

FOLHA DE APROVAÇÃO

TÍTULO: ESTABELECIMENTO DE UM MODELO DE DETECÇÃO DE
INUNDAÇÃO NO PANTANAL NORTE A PARTIR DE
PRODUTOS DERIVADOS DE IMAGENS LANDSAT TM

AUTORA: JÉSSICA DA SILVA LINHARES FREDERICO

Dissertação de Mestrado defendida e aprovada em 25 de outubro de 2016, pela
comissão julgadora:




Prof. Dr. Peter Zeilhofer
Orientador

Instituto de Ciências Humanas e Sociais - UFMT



Prof. Dr. Marcelo Sacardi Biudes
Examinador Interno

Instituto de Física - UFMT



Prof. Dr. Sérgio Wagner Gripp da Silveira
Examinador Externo

Instituto Nacional de Pesquisas Espaciais /INPE/Cuiabá

DEDICATÓRIA

À minha mãe Vera Lúcia da Silva Barros pelos sacrifícios realizados para possibilitar minha formação profissional e pessoal, e ao meu esposo Fábio Henrique Frederico pela compreensão, companheirismo e incentivos nos momentos de dificuldades.

AGRADECIMENTOS

Ao Prof. Dr. Peter Zeilhofer pela orientação, compreensão e paciência dedicados para realização deste trabalho.

Ao Prof. Dr. José de Souza Nogueira pelo excelente trabalho realizado enquanto coordenador do Programa de Pós-Graduação em Física Ambiental, mas, sobretudo pelo acolhimento, amizade, incentivos e conselhos dados ao longo de todo o curso.

Ao Dr. Sérgio Wagner Gripp da Silveira pela amizade, compartilhamento de conhecimentos e todo o apoio dado à realização deste trabalho.

A minha mãe Vera Lúcia da Silva Barros e ao meu esposo Fábio Henrique Frederico por me incentivar e apoiar incondicionalmente em todos os meus projetos, sempre com muito carinho e compreensão que foram fundamentais para me sustentar aqui.

Aos membros da banca examinadora pelas importantes contribuições apresentadas que contribuíram significativamente para melhoria deste trabalho.

A todos os professores do Programa de Pós-Graduação em Física Ambiental pelos conhecimentos transmitidos.

Ao secretários Cesário e Soilce Carrilho por todo o trabalho feito para o bom andamento e funcionamento da pós-graduação

A todos os colegas do Programa de Pós-Graduação em Física Ambiental pela amizade e compartilhamento de conhecimentos, em especial a Danielle Nassarden, Dalila Mutzenberg, Igor Kuhnen, Pabline Batista, Lucas Peres Angelini e Ricardo Figueiredo.

Aos amigos, Claíza Bega Terra e Felipe Bega Terra pela amizade e momentos de descontração compartilhados, e sobretudo pelas inúmeras acolhidas em sua casa.

A Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela bolsa Demanda Social.

SUMÁRIO

LISTA DE FIGURAS.....	v
LISTA DE TABELAS.....	vii
LISTA DE ABREVIATURAS.....	viii
RESUMO.....	x
ABSTRACT.....	xi
1 INTRODUÇÃO.....	14
1.1 PROBLEMÁTICA	14
1.2 JUSTIFICATIVA	14
2 REVISÃO BIBLIOGRÁFICA	16
2.1 A INUNDAÇÃO NO PANTANAL	16
2.2 MONITORAMENTO DA INUNDAÇÃO COM LANDSAT TM.....	17
2.3 ÍNDICES ESPECTRAIS NO MONITORAMENTO DA INUNDAÇÃO.....	18
2.3.1 Índice da Vegetação por Diferença Normalizada (NDVI).....	18
2.3.2 Índice de Vegetação Realçado (EVI)	19
2.3.3 Índice de Vegetação Ajustado para o Solo (SAVI).....	20
2.3.4 Índice da Diferença Normalizada da Água (NDWI).....	21
2.3.5 Índice de Água da Superfície (LSWI).....	21
2.4 REGRESSÃO LOGÍSTICA	22
2.5 MÉTODOS DE SELEÇÃO DE VARIÁVEIS	24
2.5.1 P-valor	24
2.5.2 Fator de Inflação da Variância (VIF)	24
2.5.3 Stepwise.....	25
2.5.4 Critério de Informação de Akaike (AIC)	25
2.6 MEDIDAS DA QUALIDADE DE AJUSTE DO MODELO	26
2.6.1 Análise da Matriz de Confusão	26
2.6.2 Coeficiente Kappa	27
3 MATERIAL E MÉTODOS	29
3.1 ÁREA DE ESTUDO	29
3.2 MONITORAMENTO DE INUNDAÇÃO	30
3.3 IMAGENS ÍNDICES ESPECTRAIS	31

3.4	USO E COBERTURA DO SOLO.....	31
3.4.1	Formações Florestais – FF	32
3.4.2	Savana Florestada – SF (Cerradão).....	33
3.4.3	Savana Arborizada – SA (Cerrado).....	33
3.4.4	Vegetação com Influência Fluvial – VF.....	34
3.4.5	Alteração Antrópica – AA.....	34
3.5	PROCESSAMENTO E ANÁLISE DE IMAGENS DIGITAIS.....	35
3.6	AJUSTE DO MODELO DE REGRESSÃO LOGÍSTICA	35
3.7	Validação do Modelo	36
4	RESULTADOS E DISCUSSÃO	37
4.1	AJUSTE DO MODELO DE REGRESSÃO LOGÍSTICA PARA CLASSIFICAÇÃO DA INUNDAÇÃO	37
4.1.1	Modelo com informação espectral da área de entorno do pixel.....	40
4.2	DESEMPENHO DO MODELO DE CLASSIFICAÇÃO DA INUNDAÇÃO	41
5	CONCLUSÕES	46
	REFERÊNCIAS BIBLIOGRÁFICAS	47

LISTA DE FIGURAS

FIGURA 1 - Localização da área de estudo. Sítio de Amostragem de Longa Duração (SALD) Pirizal (amarelo) e Transecto na Reserva Particular do Patrimônio Natural Sesc Pantanal (vermelho).	29
FIGURA 2 - Classificação de uso e cobertura do solo na área de estudo.	32
FIGURA 3 - Exemplo de Formações Florestais (FF).....	33
FIGURA 4 - Exemplo de Savana Florestada.....	33
FIGURA 5 - Exemplo de Savana Arboriza (SA).	33
FIGURA 6 - Exemplo de Vegetação com influência Fluvial (VF).	34
FIGURA 7 - Exemplo de Alteração Antrópica (AA).	34
FIGURA 8 - Mapas de inundação preditos pelo modelo de regressão logística (Modelo II) considerando as variáveis selecionadas pelo método <i>Stepwise</i> sendo elas LSWI (<i>Land Surface Water Index</i>) e EVI (<i>Enhanced Vegetation Index</i>) e a variável categórica com a classificação da cobertura do solo, denominada LAND.	42

LISTA DE TABELAS

TABELA 1 - Estrutura da matriz de confusão para validação do modelo.	26
TABELA 2 - Datas do monitoramento da inundação em campo e das imagens LANDSAT5-TM utilizadas nesta pesquisa.	30
TABELA 3 - Resultado do ajuste do modelo de regressão logística a partir dos índices espectrais EVI (<i>Enhanced Vegetation Index</i>), NDWI (<i>Normalized Difference Water Index</i>), NDVI (<i>Normalized Difference Vegetation Index</i>), LSWI (<i>Land Surface Water Index</i>), SAVI (<i>Soil Adjusted Vegetation Index</i>), e a variável categórica com a classificação da cobertura do solo, denominada LAND - Modelo I.	37
TABELA 4 - Fator de inflação da variância (VIF), para determinação de multicolinearidade entre as variáveis independentes EVI (<i>Enhanced Vegetation Index</i>), NDWI (<i>Normalized Difference Water Index</i>), NDVI (<i>Normalized Difference Vegetation Index</i>), LSWI (<i>Land Surface Water Index</i>), SAVI (<i>Soil Adjusted Vegetation Index</i>), e a variável categórica com a classificação da cobertura do solo, denominada LAND.	38
TABELA 5 - Resultado do ajuste do modelo de regressão logística considerando as variáveis selecionadas pelo método <i>Stepwise</i> , sendo elas LSWI (<i>Land Surface Water Index</i>), EVI (<i>Enhanced Vegetation Index</i>) e a variável categórica com a classificação da cobertura do solo, denominada LAND - Modelo II.	39
TABELA 6 - Fator de inflação da variância (VIF), para avaliação de multicolinearidade entre as variáveis independentes LSWI (<i>Land Surface Water Index</i>), EVI (<i>Enhanced Vegetation Index</i>) e a variável categórica com a classificação da cobertura do solo, denominada LAND.	39
TABELA 7 - Resultado do ajuste do modelo de regressão logística considerando apenas as variáveis LSWI (<i>Land Surface Water Index</i>) e EVI (<i>Enhanced Vegetation Index</i>) - Modelo III.	40
TABELA 8 - Comparação do AIC (Critério de Informação de Akaike) entre os modelos ajustados com a informação espectral pontual (Modelo II) e os modelos ajustados com informação espectral extraída dos buffers de 30, 60 e 90 metros.	41
TABELA 9 - Validação do modelo de regressão logística aplicado aos mapas de inundação individualmente.	43
TABELA 10 – Acurácia, coeficiente Kappa e taxas de falsos positivos (TFP) e falsos negativos (TFN) das imagens geradas pelo modelo de classificação para 26/03/2007;	

13/05/2007 e 14/06/2007, e os valores globais, obtidos a partir de uma análise de desempenho geral (independente da data).....	44
--	----

LISTA DE ABREVIATURAS

AIC	Critério de Informação de Akaike
EUA	United States of America
EVI	Enhanced Vegetation Index
LANDSAT	Land Remote Sensing Satellite
LSRD	LSDS Science Research and Development
LSWI	Land Surface Water Index
MODIS	Moderate Resolution Imaging Spectroradiometer
MSS	Multispectral Scanner System
NDMI	Normalized Difference Moisture Index
NDVI	Normalized Difference Vegetation Index
NDWI	Normalized Difference Water Index
RL	Regressão Logística
SAVI	Soil Adjusted Vegetation Index
SIG	Sistema de Informação Geográfica
SR	Sensoriamento Remoto
TM	Thematic Mapper
USGS	United States Geological Survey
WWF	World Wildlife Fund

RESUMO

FREDERICO, J. S. L. **Estabelecimento de um modelo de detecção de inundação no Pantanal Norte a partir de produtos derivados de imagens LANDSAT TM**. Cuiabá, 2016, 40 f. Dissertação (Mestrado em Física Ambiental) - Instituto de Física, Universidade Federal de Mato Grosso.

Os ciclos de seca e inundação determinam a dinâmica dos processos ecológicos no Pantanal. Dessa forma, a identificação de áreas inundadas e não inundadas é fundamental para o entendimento das ligações entre os diferentes tipos de compartimentos formados pelas variações no nível d'água, bem como para avaliação dos padrões de biodiversidade e o manejo adequado das atividades desenvolvidas no ecossistema. Assim, o presente trabalho teve como objetivo o estabelecimento de um modelo de detecção da inundação no Pantanal Norte, a partir de produtos derivados de imagens LANDSAT TM. Utilizando o método de regressão logística, empregou-se como variável dependente dicotômica a condição de inundação medida *in situ* (2007) e, como variáveis independentes índices espectrais de vegetação e umidade (NDVI, EVI, SAVI, NDWI, LSWI) e uma classificação de cobertura do solo derivados de imagens LANDSAT TM. Na seleção das variáveis independentes para compor o modelo, a combinação dos índices espectrais EVI e LSWI e a classificação de cobertura do solo, foi a que resultou no melhor ajuste do modelo, que apresentou acurácia geral de 84,97% e um índice Kappa de 0,691. A qualidade do modelo variou de acordo com os períodos do ciclo de inundação, com melhor desempenho nos períodos de cheia e vazante. O modelo também apresentou uma tendência de superclassificação da área inundada em regiões de vegetação com influência fluvial. De forma geral, a classificação de inundação no Pantanal Norte a partir de produtos derivados de imagens LANDSAT TM apresentou desempenho satisfatório, sendo uma importante alternativa para o monitoramento da inundação em áreas úmidas, que apresentam acesso limitado em boa parte do ano.

Palavras-chave: Sensoriamento Remoto, Regressão logística, índices espectrais, áreas inundáveis.

ABSTRACT

FREDERICO, J. S. L. **Establishment of a model for inundation detection in the Northern Pantanal products derived from LANDSAT TM imagery.** Cuiabá, 2016, 40 f. Dissertação (Master in Environmental Physic) - Environmental Physic) - Institute of Physic, Federal University of Mato Grosso.

Drought and flood cycles determine the dynamics of ecological processes in the Pantanal. Therefore, the identification of flooded and non-flooded areas is critical for understanding spatial linkages between landscape compartments at different water levels, as well as for evaluating biodiversity patterns and appropriately managing the activities developed within the ecosystem. This study is mainly aimed at establishing a flood mapping model in the Northern Pantanal system from products derived from Landsat TM images. Using the logistic regression method, the flood conditions measured in situ (2007) were used as a dichotomous variable and spectral vegetation and humidity indices (NDVI, EVI, SAVI, NDWI, LSWI), as well as the land cover classification derived from LANDSAT TM images, were used as independent variables. In the selection of independent variables to compose the model, the combination of the EVI and LSWI indices and the land cover classification resulted in the best model fit, which showed an overall accuracy of 84.97% and a Kappa index of 0.691. The model performance varied according to the flood cycle period, with best performance during rising and receding waters. The model also presented a tendency of super classification of the flooded area in regions with dense riverine vegetation. Overall, the flooding classification in the Northern Pantanal from products derived from LANDSAT TM images presented a satisfactory mapping performance and can therefore be considered an important alternative for flood monitoring in large tropical floodplains, which have limited access during most of the year.

Keywords: Remote Sensing, Logistic regression, spectral indices, floodplains.

1 INTRODUÇÃO

1.1 PROBLEMÁTICA

O monitoramento da inundação tem sido objeto de estudo de diversas pesquisas em áreas úmidas ao redor do mundo, uma vez que as condições de inundação determinam a dinâmica dos processos ecológicos nesses ecossistemas.

Como maior zona úmida do mundo, o Pantanal constitui-se em um bioma complexo que abriga uma diversidade de fauna e flora, distribuídas de forma sazonal em função das alterações anuais e interanuais da inundação. As diferenças locais no regime hidrológico, provocam variações no nível d'água, gerando um mosaico paisagístico de áreas inundadas e não inundadas.

Além de determinar os processos ecológicos, as condições de inundação influenciam fortemente o desenvolvimento da economia, baseada na pecuária, pesca e turismo. Dessa forma, a identificação de áreas inundadas e não inundadas é fundamental para o entendimento das ligações entre os diferentes tipos de compartimentos formados pelas variações no nível d'água, avaliação dos padrões de biodiversidade e o manejo adequado das atividades desenvolvidas no ecossistema.

Entretanto, devido à sua notada extensão, cerca de 140.000 km² em território brasileiro e ao acesso limitado em determinados períodos do ano, o monitoramento da inundação *in loco* é bastante dificultado, sendo portanto associado às técnicas de Sensoriamento Remoto (SR) que possibilitam a obtenção de estimativas de inundação a partir de modelos de classificação de áreas inundadas e não inundadas.

1.2 JUSTIFICATIVA

Técnicas de Sensoriamento Remoto (SR) têm sido amplamente empregadas no monitoramento de regiões sujeitas a processos sazonais de inundação visto que atuam como um importante complemento para obtenção de informações de regiões com pouca disponibilidade de dados *in situ*.

Há uma grande variedade de produtos de SR frequentemente empregados nos estudos de inundação. Nesse contexto, destacam-se os produtos LANDSAT TM que

apresentam resolução temporal de 16 dias e elevada resolução espacial (30 metros), proporcionando um bom nível de detalhamento para distinção de áreas inundadas e não inundadas.

Assim, o presente trabalho teve como objetivo estabelecer um modelo de detecção da inundação no Pantanal Norte a partir de produtos derivados de imagens LANDSAT TM. Desse modo, foram definidos os seguintes objetivos específicos:

- i) identificar quais índices espectrais contribuem significativamente para o melhor ajuste do modelo de classificação;
- ii) Validar o desempenho do modelo da classificação para monitoramento da inundação.

2 REVISÃO BIBLIOGRÁFICA

2.1 A INUNDAÇÃO NO PANTANAL

As Zonas úmidas são definidas através de um tratado intergovernamental (Convenção de Ramsar - 1975) como áreas prioritárias para conservação biológica devido a alta complexidade ecológica e sua importância internacional para manutenção da biodiversidade (PIEDEDE et al., 2012). O Brasil possui 12 zonas úmidas brasileiras reconhecidas como sítios Ramsar, dentre elas o Parque Nacional do Pantanal Mato-Grossense, inserido na Bacia do Alto Paraguai.

O Pantanal é a maior planície sazonalmente inundada do mundo (SILVA & ABDON, 1998), com baixo índice de declividade, de 3 a 15 cm/km de Norte para Sul e de 30 a 50 cm/km de leste para oeste (ADÁMOLI, 1986). Caracterizada por ciclos anuais de seca e inundações que determinam as interações ecológicas (JUNK et al., 1989), sua hidrografia é formada por grandes rios como o Paraguai, Cuiabá, São Lourenço, Piquiri, Taquari, entre outros.

A precipitação média anual oscila entre 800 mm e 1200 mm, sendo que 80% ocorrem entre os meses de novembro a março (PCBAP, 1997) com pequenas variações interanuais. Segundo a classificação de Köppen o clima é do tipo Aw, quente e úmido com chuvas no verão e estiagem no inverno.

As inundações são ocasionadas pelo transbordamento dos rios ao longo de seu curso, bem como pela precipitação local, sobretudo em locais distantes ou com pouca influência de curso de rio (JUNK et al., 1989; PENHA et al., 1999).

O regime de inundação é monomodal com variações espaço-temporais, uma vez que ao norte da planície o início da inundação coincide com o início de chuvas constantes no mês de dezembro, enquanto na parte central e sul podem ocorrer defasagens de até 3 meses entre o pico das precipitações (fevereiro/março) e o máximo das inundações (FANTIN-CRUZ et al., 2010).

O gradiente espacial da inundação tem sido destacado como um dos principais fatores modeladores da paisagem, atuando na distribuição e abundância das espécies vegetais na planície do Pantanal, além de provocar uma constante movimentação de animais em resposta à disponibilidade de habitats e outros recursos (ZEILHOFER & SCHESSL, 2000; CUNHA & JUNK, 2001; REBELLATO & CUNHA, 2005;

DAMASCENO-JUNIOR et al., 2005; FANTIN-CRUZ et al., 2010; FERNANDES et al., 2010).

2.2 MONITORAMENTO DA INUNDAÇÃO COM LANDSAT TM

O satélite Landsat 5 faz parte da série LANDSAT (*Land Remote Sensing Satellite*) que teve início na década de 60 com objetivo de fornecer produtos destinados a mapeamentos temáticos na área de recursos naturais. O Landsat 5 foi lançado em março de 1984 levando a bordo dois sensores, o MSS (*Multispectral Scanner System*) que foi desativado em 1995 e o TM (*Thematic Mapper*) desativado em janeiro de 2013 (USGS, 2016).

Com significativa melhoria na resolução espacial e espectral em relação aos seus antecessores e uma série histórica consistente com quase 30 anos de dados, os produtos do sensor TM são largamente empregados no monitoramento dos recursos naturais. O sensor TM produz imagens com 185 km de largura no terreno, com resolução temporal de 16 dias e imageamento da superfície terrestre em 7 bandas multiespectrais, sendo as bandas (1 - 5 e 7) com 30 metros de resolução espacial, e a 7 com 120 metros.

Verificam-se diversas aplicações dos produtos LANDSAT TM em estudos de planícies inundáveis (SILVA & ABDON, 1998; BARBOSA, 2007; BORRO et al., 2014; TIAN et al., 2015; THOMAS et al., 2015), notadamente com o emprego de índices espectrais de vegetação e umidade.

Através do Índice da Diferença Normalizada da Água (NDWI) derivado de imagens LANDSAT TM, Jardim-Lima et al. (2005) puderam quantificar a área de inundação e a morfologia dos lagos de várzea da Reserva de Desenvolvimento Sustentável Mamirauá, na Amazônia Central.

A partir da associação de dados limnológicos e batimétricos obtidos em campanhas de campo, com séries históricas de imagens LANDSAT TM Barbosa (2007) desenvolveu um modelo conceitual de circulação da água na planície de Curuaí /Rio Amazonas.

No Pantanal, Silva (1991) foi um dos primeiros a avaliar a dinâmica de inundação a partir de imagens de satélites. Empregando imagens LANDSAT TM, dados de cota dos rios e fotografias aéreas, diferenciou áreas distintas quanto ao padrão de inundação e a variação sazonal dentro de um ano hidrológico. Anos mais tarde, Silva e

Abdon (1998) também utilizaram imagens LANDSAT TM para delimitação e quantificação da planície de inundação do Pantanal e, Shimabukuro et al. (1998) avaliaram a contribuição do Índice de Vegetação da Diferença Normalizada (NDVI) e imagens-fração extraídas do modelo de mistura espectral, ambos derivados de imagens LANDSAT TM, para o monitoramento de dinâmica de cobertura do solo na região do Pantanal.

Nesse cenário, os produtos LANDSAT TM têm ganhado destaque devido ao potencial de aplicação nos estudos de ambientes sujeitos a processos de inundação, demonstrado através dos inúmeros estudos já realizados.

2.3 ÍNDICES ESPECTRAIS NO MONITORAMENTO DA INUNDAÇÃO

Os índices espectrais surgem das combinações matemáticas entre as reflectâncias para realçar características de interesse, como realçar o sinal da vegetação, permitir o delineamento de corpos d'água, aumentar o contraste entre solo e a vegetação, diminuir a influência do solo e da atmosfera, entre outras aplicações.

Desse modo, os índices espectrais de vegetação e umidades são muito úteis nos estudos de ambientes inundáveis, para otimizar a diferenciação de áreas inundadas e não inundadas, bem como para detecção das variações na vegetação conforme as fases do ciclo de inundação. Nesse sentido, serão apresentados os principais índices espectrais de vegetação e umidade frequentemente empregados nos estudos de inundação.

2.3.1 Índice da Vegetação por Diferença Normalizada (NDVI)

O Índice da vegetação por diferença normalizada (em inglês, *Normalized Difference Vegetation Index*) é resultante da combinação dos níveis de reflectância nas faixas espectrais do vermelho (ρ_{vermelho}) e infravermelho próximo (ρ_{ivp}):

$$\text{NDVI} = \frac{\rho_{\text{ivp}} - \rho_{\text{vermelho}}}{\rho_{\text{ivp}} + \rho_{\text{vermelho}}} \quad (1)$$

O NDVI é um índice de vegetação sensível à clorofila, deste modo é frequentemente usado para medir a intensidade da atividade vegetativa, no entanto,

também tem sido utilizado para a delimitação de água uma vez que a água absorve fortemente a luz na região espectral do infravermelho próximo (causando baixa reflexão). Portanto, valores próximos de 1 indicam maior atividade vegetativa, e valores próximos de 0 indicam pouca ou nenhuma atividade clorofiliana, podendo ser um indicativo da presença de água (inundação).

Utilizando os índices NDVI (*Normalized Difference Vegetation Index*) e MNDWI (*Modified Normalized Difference Water Index*) derivados de uma série histórica de imagens LANDSAT TM (1985 - 2013) Tian et al. (2015) classificaram e quantificaram as áreas úmidas em Shanghai e obtiveram uma precisão global de classificação de 99,4%.

Na planície de inundação do Paraná Borro et al. (2014) mapearam a distribuição espacial de lagos rasos utilizando uma série histórica do NDVI (1987 - 2010) derivado de dados LANDSAT TM e ETM.

Apesar de ter se tornado a principal ferramenta em estudos da vegetação, apresenta limitações como a elevada sensibilidade às variações de fundo do dossel, e efeitos aditivos de ruídos causados pela radiação externa que ocorre na atmosfera (HUETE et al., 1985; JIANG et al., 2008).

2.3.2 Índice de Vegetação Realçado (EVI)

O Índice de Vegetação Realçado (em inglês, *Enhanced Vegetation Index*) foi desenvolvido a partir do NDVI com o objetivo de aperfeiçoar a captação do sinal da vegetação, com maior sensibilidade às altas biomassas, fator de ajuste do solo e redução das influências atmosféricas. A equação é dada por:

$$EVI = G \frac{\rho_{ivp} - \rho_{vermelho}}{\rho_{ivp} + C_1 * \rho_{vermelho} - C_2 * \rho_{azul} + L} \quad (2)$$

onde, $\rho_{vermelho}$ e ρ_{ivp} são as reflectâncias nas faixas espectrais do vermelho e infravermelho próximo respectivamente, "L" é o coeficiente para ajustar às variações de fundo do dossel, "C₁" "C₂" são os coeficientes de resistência atmosférica decorrente da presença dos aerossóis, que usam a banda azul para corrigir a influência destes sobre a banda vermelha, e G é uma fator de ganho (LIU e HUETE, 1995).

Analogamente ao NDVI, o EVI também pode ser utilizado para a delimitação de água uma vez que a água absorve fortemente a luz na região espectral do infravermelho próximo (causando baixa reflexão).

Ao empregar os índices EVI e NDVI do MODIS para analisar a dinâmica de inundação no Pantanal Sul-Mato-grossense, Goltz et al. (2006) observaram que o EVI apresenta maior contraste entre áreas alagadas e não alagadas do que o NDVI, indicando maior sensibilidade às variações que ocorrem entre os períodos de cheia e seca na planície.

Utilizando a técnica de fatiamento manual de histograma, Padovani (2010) estudou a dinâmica de inundação do Pantanal com uso de série temporal do EVI derivado do produto MOD13Q1, por meio da qual pode estimar cenários passados de inundação baseado na relação entre a área inundada total do Pantanal e o nível do rio Paraguai.

2.3.3 Índice de Vegetação Ajustado para o Solo (SAVI)

O Índice de vegetação ajustado para o solo (em inglês, *Soil Adjusted Vegetation Index*) foi proposto por Huete (1988) após Huete e Jackson (1987) constatarem que o NDVI perde eficiência em terrenos com pouca cobertura vegetal ou presença natural de solo exposto devido a sensibilidade do índice de vegetação às variações de reflectância dos tipos de solo. A equação é dado por:

$$SAVI = \left[\frac{\rho_{ivp} - \rho_{vermelho}}{\rho_{ivp} + \rho_{vermelho}} \right] (1 + L) \quad (3)$$

onde, $\rho_{vermelho}$ e ρ_{ivp} são as reflectâncias nas faixas espectrais do vermelho e infravermelho próximo respectivamente, e "L" é um fator de correção para minimizar os efeitos do solo de fundo no sinal da vegetação. Dessa forma, os resultados obtidos para o SAVI serão muito semelhantes ao NDVI, principalmente em locais de vegetação densa onde a reflectância do solo não afeta de maneira significativa na imagem (MIURA, 1999).

2.3.4 Índice da Diferença Normalizada da Água (NDWI)

O Índice da diferença normalizada da água (em inglês, *Normalized Difference Water Index*) proposto por Gao (1996) é um índice de umidade obtido pela razão entre as reflectâncias do infravermelho próximo ($0,86 \mu\text{m}$) e infravermelho médio ($1,24 \mu\text{m}$) que correspondem respectivamente as bandas 4 e 5 do LANDSAT TM. A equação é dada por:

$$\text{NDWI} = \frac{\rho_{ivp} - \rho_{ivm}}{\rho_{ivp} + \rho_{ivm}} \quad (4)$$

onde, ρ_{ivp} e ρ_{ivm} são as reflectâncias nas faixas espectrais infravermelho próximo e infravermelho médio. Esta combinação minimiza a baixa reflectância da água no infravermelho próximo, sendo útil para detecção do teor de umidade presente na vegetação.

Na Austrália, Thomas et al. (2015) utilizaram o NDWI e NDVI derivados do LANDSAT TM para mapeamento de zonas úmidas dos Pântanos Macquarie, com precisão global de classificação de 93%.

McFeeters (1996) apresenta outra combinação que também denomina de NDWI, mas utiliza as reflectâncias espectrais do verde e do infravermelho próximo, respectivamente, bandas 2 e 4 do LANDSAT TM. O comprimento de onda do verde maximiza a reflectância típica da água, com a finalidade de delinear ambientes de águas abertas.

Utilizando a formulação de McFeeters (1996) Brenner e Guasselli (2015) identificaram meandros ativos no leito do canal do rio Gravataí através da aplicação do índice NDWI derivado de uma série temporal do LANDSAT TM (1984 - 2010).

2.3.5 Índice de Água da Superfície (LSWI)

O Índice da Água da Superfície (do inglês, *Land Surface Water Index*) proposto por Chandrasekar et al. (2010) possui uma combinação semelhante ao NDWI denominada de LSWI, que utiliza a banda 7 ($2,13 \mu\text{m}$) no lugar da 5, pois das bandas na região do infravermelho médio, a de número 7 é a que menos é afetada pelo ozônio e pelo espalhamento Rayleigh.

$$LSWI = \frac{\rho_{ivp} - \rho_{ivoc}}{\rho_{ivp} + \rho_{ivoc}} \quad (5)$$

onde, ρ_{ivp} e ρ_{ivoc} são as reflectâncias nas faixas espectrais infravermelho próximo e infravermelho médio, respectivamente. Assim como o NDWI o LSWI é utilizado para detecção da água líquida na vegetação, porém com menor interferência dos efeitos do vapor d'água na atmosfera.

Empregando os índices EVI e LSWI, e a diferença entre os dois índices (DVEL) filtrados por Wavelet, Sakamoto et al. (2007) criaram uma série temporal da inundação do Delta de Mekong. Utilizando a mesma combinação dos índices espectrais (LSWI e EVI) do MODIS e a classificação de uso da terra no modelo de regressão logística para modelagem da dinâmica de inundação no Pantanal, SILVEIRA (2015) obteve acurácia geral de 89,2%.

2.4 REGRESSÃO LOGÍSTICA

A regressão logística (RL) tem sido empregada na classificação de áreas inundadas (ORDOYNE e FRIELD, 2008; HUANG et al., 2014; SILVEIRA, 2015) por permitir o estudo da relação entre uma variável dependente (inundação) e uma ou mais variáveis independentes (hidrológicas, geomorfológicas e fitofisionômicas). Na RL frequentemente, a variável dependente é binária e codificada com 0 (ausência) e 1 (presença) de um evento.

Analizando a dinâmica de inundação nos Everglades, Flórida, Ordoyne e Friel (2008) constataram que a regressão logística apresentou o melhor desempenho dentre outras técnicas estatísticas para resposta binária (inundado / não inundado) resultando em uma acurácia de 83,7% obtida através de validação cruzada.

Na bacia de Murray na Austrália, Huang et al. (2014) utilizaram a regressão logística na obtenção do índice OWL (*Open Water Likelihood*) do MODIS, o qual foi integrado às observações hidrológicas e mapas de inundação gerados a partir de imagens LANDSAT TM/ETM+ resultando em uma acurácia geral de 97,0% e 94,8% para as duas áreas analisadas.

SILVEIRA (2015) utilizou a RL no desenvolvimento de um modelo empírico para classificação da inundação no Pantanal Mato-grossense a partir dos índices espectrais LSWI e EVI do MODIS, com o qual obteve uma acurácia geral de 89,2% e 77,2% na validação externa.

Neste método de regressão a resposta é resultado de uma função não linear da probabilidade de ocorrência de um evento, expressa entre 0 e 1. Desta forma, a variação de y em função de x não é constante, havendo áreas onde pequenas variações nos valores de x causam grandes variações nos valores de y , consequência da maior probabilidade de mudança de estado da variável y em função de x nestas áreas. Para adequar a resposta média ao modelo linear usamos a função de ligação *logit*, $g(x)$:

$$g(x) = \ln\left[\frac{\pi(x)}{1 - \pi(x)}\right] \quad (6)$$

onde, $\pi(x)$ é o valor esperado de um evento dado o valor de x . A regressão logística estabelece uma relação linear entre a variável dependente, a variável independente e a transformação *logit*, logo:

$$g(x) = \beta_0 + \beta_1 x_i \quad (7)$$

onde, β_0 é a constante (intercepto), β_1 o coeficiente da variável independente, estimados pelo método da máxima verossimilhança e, x_i é o valor da variável explicativa. 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.

Assim, a probabilidade de um evento ocorrer $\pi(x_i)$ é dada por:

$$\pi(x_i) = \frac{e^{\beta_0 + \beta_1 x_i}}{1 + e^{\beta_0 + \beta_1 x_i}} \quad (8)$$

2.5 MÉTODOS DE SELEÇÃO DE VARIÁVEIS

Ao desenvolver um modelo de classificação, será preciso definir as variáveis preditivas significativas para o modelo. A decisão de inclusão ou exclusão de variáveis no modelo pode refletir no desempenho do modelo. Portanto, a seleção das variáveis deve ser orientada por métodos estatísticos, propiciando a escolha do modelo mais parcimonioso.

2.5.1 P-valor

O p-valor representa a chance ou probabilidade do efeito observado ser devido ao acaso, e não aos fatores que estão sendo estudados. Uma vez que se trata de uma probabilidade, o valor de p irá variar entre 0 e 1. Em geral, dizemos que uma variável é significativa para o modelo quando $p \leq 0,05$, ou seja, quando há apenas 5% de chance do efeito observado ser devido ao acaso, ou 95% de chances de estar certo (BUSSAB & MORETTIN, 1987).

2.5.2 Fator de Inflação da Variância (VIF)

O Fator de Inflação da Variância (VIF) é utilizado para descrever quanta colinearidade, ou seja, quanta correlação há entre as variáveis explicativas empregados em um modelo de regressão. A colinearidade pode prejudicar o ajuste do modelo de regressão uma vez que inflaciona a variância dos coeficientes de regressão estimados, tornando-os instáveis e difíceis de interpretar (MINITAB INC., 2010).

Não há um valor limite de VIF a ser seguido, em geral valores de $VIF > 5$ são adotados com indicadores de variáveis altamente correlacionadas (LOGAN 2010, p. 11; MINITAB INC., 2010). No entanto, O'Brien (2007) ressalta que os valores de VIF e o nível de tolerância a ser adotado devem ser avaliados em um contexto geral com base nos demais fatores que influenciam a variação dos coeficientes de regressão para não incorrer no risco de questionar resultados bastante sólidos observados a partir de outras análises estatísticas.

2.5.3 Stepwise

Um problema importante em muitas aplicações da análise de regressão envolve a seleção de variáveis independentes ou preditoras a serem utilizadas no modelo. Uma das técnicas mais utilizadas é a seleção automática Stepwise, que constrói sistematicamente uma sequência de modelos de regressão pela adição (*Seleção Forward*) ou remoção (*Seleção Backward*) da variável mais significativa em cada etapa.

O *Seleção Forward* parte da suposição de que não há variável no modelo, apenas o intercepto. A ideia do método é adicionar uma variável de cada vez, iniciando por aquela com maior correlação com a resposta. Em seguida, calcula-se a estatística F para testar se ela realmente é significativa para o modelo. A variável entra no modelo se a estatística F for maior do que o ponto crítico, chamado de F_{in} ou F de entrada calculado para um dado α crítico (MORRISON, 2006).

O *Seleção Backward* incorpora inicialmente todas as variáveis no modelo. Em seguida são calculados os testes F parciais para cada variável explicativa e o F crítico (F_{out} ou F de saída) calculado para um dado valor α crítico. Se o menor valor encontrado for menor do que F_{out} elimina-se do modelo a covariável responsável pelo menor valor da estatística F parcial (BURSAC et al., 2008; MORRISON, 2006).

2.5.4 Critério de Informação de Akaike (AIC)

O Critério de Informação de Akaike é uma medida utilizada na seleção de modelos com diferentes combinações de variáveis independentes. O AIC baseado no conceito de entropia, oferecendo uma medida relativa das informações perdidas quando um determinado modelo é utilizado para descrever a realidade (EMILIANO, 2009).

Similarmente ao VIF não há um valor pré-estabelecido de AIC a ser seguido, desta forma, ao se obter vários modelos concorrentes com diferentes combinações de variáveis independentes, o AIC poderá ser usado como critério de seleção do melhor modelo, sendo aquele com menor AIC o modelo a ser adotado (BURNHAM E ANDERSON, 2002). Esta ferramenta está implementada em grande parte dos softwares estatísticos como R e o Statistica.

2.6 MEDIDAS DA QUALIDADE DE AJUSTE DO MODELO

Segundo Antunes e Lingnau (1997) um mapeamento só deve ser utilizado como fonte fidedigna de informações quando associado a processos de avaliação da acurácia dos dados que o compõem, através do diagnóstico das concordâncias e discordâncias do modelo. Deste modo, destacam-se os métodos de análise da matriz de confusão e do coeficiente de concordância Kappa, amplamente empregados na avaliação da acurácia de mapeamentos gerados a partir de imagens digitais de sensoriamento remoto.

2.6.1 Análise da Matriz de Confusão

A Matriz de Confusão é utilizada para avaliar o resultado de uma classificação. É uma matriz quadrada de números que expressam a quantidade de unidades amostrais associada a uma dada categoria durante o processo de classificação automática, e à categoria real a que pertence essas unidades (CONGALTON, 1991). A Tabela 1 apresenta um modelo da matriz de confusão, em que Y representa a variável binária observada em campo e estimada/classificada pelo modelo. A e D representam as concordâncias entre os valores estimados pelo modelo e os observados em campo, enquanto B e C representam as discordâncias. Ainda, n_0 é o número de casos observados para $Y = 0$, e n_1 os observados para $Y = 1$. Analogamente, m_0 é o número de casos classificados como $Y = 0$, e m_1 os classificados como $Y = 1$. Portanto, $n = n_0 + n_1 = m_0 + m_1$.

TABELA 1 - Estrutura da matriz de confusão para validação do modelo.

Classificado	Observado		Total
	$Y = 0$	$Y = 1$	
$Y = 0$	A	B	m_0
$Y = 1$	C	D	m_1
Total	n_0	n_1	n

Logo, as concordâncias são dadas por:

Sensibilidade ou Taxa de verdadeiro positivo, $TVP = D / n_1$

Especificidade ou Taxa de verdadeiro negativo, $TVN = A / n_o$

E as discordâncias dadas por:

Taxa de falso positivo, $TFP = C / n_o$ ou $TFP = 1 - \text{Especificidade}$

Taxa de falso negativo, $TFN = B / n_1$

Logo, Acurácia = $(A + D) / n$

Deste modo, a classificação gerada pelo modelo poderá ser comparada com as observações de campo, permitindo uma análise das discordâncias do modelo, ou seja, das taxas de falsos positivos (TFP) e taxas de falsos negativos (TFN).

2.6.2 Coeficiente Kappa

O coeficiente Kappa é uma medida de concordância, além do que seria esperado tão somente pelo acaso, que também pode ser empregada para comparar dois métodos ou modelos de classificação. O Kappa tem como valor máximo o 1, onde este valor representa total concordância e os valores próximos e até abaixo de 0, indicam nenhuma concordância, ou que a concordância foi exatamente a esperada pelo acaso (LANDIS e KOCH, 1977). Sua equação é dada por:

$$\hat{k} = \frac{p_0 - p_c}{1 - p_c} \quad (9)$$

onde, p_0 é o número de concordância realmente presente ou "concordância observada" e, p_c é o número de concordância esperada apenas por acaso ou "concordância esperada" (LANDIS e KOCH, 1977). Da Tabela 1 depreende-se:

$$p_0 = \frac{(A + D)}{n} \quad (10)$$

e,

$$p_c = \left[\left(\frac{n_1}{n} \right) * \left(\frac{m_1}{n} \right) \right] + \left[\left(\frac{n_0}{n} \right) * \left(\frac{m_0}{n} \right) \right] \quad (11)$$

Deste modo, o kappa é uma medida que incorpora a informação dos pixels mal classificados, e não apenas os bem classificados. De forma geral, o Kappa é um índice que expressa o grau de acerto da classificação, descontando o efeito dos acertos esperados simplesmente por fatores aleatórios (DIAS, 2004).

3 MATERIAL E MÉTODOS

3.1 ÁREA DE ESTUDO

A pesquisa foi desenvolvida com dados de monitoramento da inundação *in situ* realizado em duas regiões no Pantanal Norte (Figura 1).




FIGURA 1 - Localização da área de estudo. Sítio de Amostragem de Longa Duração (SALD) Pirizal (amarelo) e Transecto na Reserva Particular do Patrimônio Natural Sesc Pantanal (vermelho).

Ao norte (amarelo) o Sítio de Amostragem de Longa Duração (SALD) Pirizal localizado no município de Nossa Senhora do Livramento, Mato Grosso, na bacia do rio Cuiabá, e submetido a um sistema misto, onde a inundação é uma combinação da chuva local, águas oriundas do Rio Cuiabá e áreas adjacentes (FANTIN-CRUZ, 2008). A grade SALD possui um desenho amostral padronizado com 40 parcelas amostrais (régua limnimétrica) distribuídas em uma área de 25 km² a uma distância de 1 km uma da outra.

A área amostral ao sul (vermelho) é constituída de 11 régua limnimétrica, formando um transecto de 12 km de extensão a partir do Rio Cuiabá, localizado dentro

da Reserva Particular do Patrimônio Natural (RPPN) do Sesc Pantanal, no município de Barão de Melgaço, Mato Grosso.

A metodologia adotada foi baseada na aplicação da técnica de regressão logística para estabelecer um modelo de classificação de áreas inundadas e não inundadas no Pantanal Norte, empregando-se como variável dependente dicotômica a condição de inundação medida *in situ* (2007) e, como variáveis independentes índices espectrais de vegetação e umidade (NDVI, EVI, SAVI, NDWI, LSWI) e uma classificação de cobertura do solo derivados de imagens LANDSAT TM.

3.2 MONITORAMENTO DE INUNDAÇÃO

O monitoramento da inundação, com leitura direta da profundidade da coluna d'água em réguas limnimétricas com graduação centimétrica, ocorreu semanalmente entre os dias 14 de dezembro de 2006 e 12 junho de 2007 durante o desenvolvimento de outras pesquisas (FANTIN-CRUZ, 2008; GIRARD et al., 2010, FANTIN-CRUZ et al., 2010).

Foram adotadas as medidas de inundação realizadas nas datas mais próximas às datas das imagens LANDSAT TM, conforme tabela abaixo.

TABELA 2 - Datas do monitoramento da inundação em campo e das imagens LANDSAT5-TM utilizadas nesta pesquisa.

LANDSAT 5 TM	DATA	MONITORAMENTO DA INUNDAÇÃO
LT52260712007085CUB00	26/03/2007	29/03/2007
LT52260712007133CUB00	13/05/2007	12/05/2007
LT52260712007165CUB00	14/06/2007	14/06/2007

As medições foram codificadas de forma binária, sendo 1 (inundado) e 0 (não inundado) segundo o limiar estabelecido de que medidas de lâmina d'água ≥ 10 mm representavam áreas inundadas, e medidas < 10 mm áreas não inundadas.

3.3 IMAGENS ÍNDICES ESPECTRAIS

Foram utilizadas imagens índices espectrais derivadas da reflectância de superfície do LANDSAT5 TM, obtidas por meio da plataforma *LSDS Science Research and Development (LSRD)* <<http://espa.cr.usgs.gov>> mantida pelo Geológico dos Estados Unidos (USGS). Nesta plataforma as imagens são disponibilizadas já com os índices calculados, georreferenciadas, ortorretificadas, com correção atmosférica, no Datum WGS84 e Sistema de projeção cartográfica UTM (Universal Transversa de Mercator).

Foram adotadas as imagens índices NDVI (*Normalized Difference Vegetation Index*), EVI (*Enhanced Vegetation Index*), SAVI (*Soil Adjusted Vegetation Index*), NDWI (*Normalized Difference Water Index*) conforme apresentado por Gao (1996) e LSWI (*Land Surface Water Index*) referentes às três datas do ciclo de inundação 2006/2007, conforme apresentado na Tabela 2.

Vale ressaltar que a nomenclatura de alguns índices espectrais pode variar segundo as fontes, como é o caso dos produtos NDWI e LSWI disponibilizados pelo USGS como NDMI (*Normalized Difference Moisture Index*) e NBR (*Normalized Burn Ratio*) respectivamente. Para evitar equívocos os índices foram identificados a partir da análise das combinações espectrais utilizadas para derivação dos índices contidas no "Manual de índices espectrais derivados da reflectância de superfície do LANDSAT" disponibilizado pela USGS e, posteriormente renomeados como NDWI (GAO, 1996) e LSWI (CHANDRASEKAR et al., 2010) para fins de padronizar as comparações com as literaturas empregadas neste trabalho.

3.4 USO E COBERTURA DO SOLO

Para identificação da vegetação existente nos pontos de localização das réguas limnimétricas foi adotado o mapeamento de uso e cobertura do solo produzido pela WWF-BRASIL (World Wildlife Fund - Brasil) em parceria com outras fundações de apoio, denominada "Monitoramento das alterações de cobertura vegetal e uso do solo na Bacia do Alto Paraguai, porção brasileira" no período de 2002 a 2008, na escala de 1:50.000. Este mapeamento foi adquirido gratuitamente no formato *shapefile* através do sítio <<https://www.embrapa.br/pantanal/bacia-do-alto-paraguai>>.

Foram identificadas cinco classes de vegetação nas localidades das réguas de monitoramento, sendo elas, Formações Florestais (FF), Savana Florestada (SF), Savana Arborizada (SA), Vegetação com Influência Fluvial (VF) e Alteração Antrópica (AA) (FIGURA 2).




FIGURA 2 - Classificação de uso e cobertura do solo na área de estudo.

Fonte: WWF-BRASIL (2009).

As características da vegetação contida nas classes são descritas a seguir conforme apresentado em WWF-BRASIL (2009).

3.4.1 Formações Florestais – FF

Essa classe engloba as florestas estacionais decíduas e semidecíduas, caracterizadas pelo aspecto da sazonalidade (Figura 3).



FIGURA 3 - Exemplo de Formações Florestais (FF).
Fonte: WWF-BRASIL (2009).

3.4.2 Savana Florestada – SF (Cerradão)

Essa classe é representada por árvores densamente dispostas. No entanto, de menor porte que as identificadas na categoria de formações florestais (Figura 4).



FIGURA 4 - Exemplo de Savana Florestada
Fonte: WWF-BRASIL (2009).

3.4.3 Savana Arborizada – SA (Cerrado)

Essa classe apresenta árvores de pequeno porte, de forma mais esparsa e dispostas entre vegetação contínua de porte arbustivo e herbácea (Figura 5).



FIGURA 5 - Exemplo de Savana Arboriza (SA).
Fonte: WWF-BRASIL (2009).

3.4.4 Vegetação com Influência Fluvial – VF

Essa categoria de vegetação é composta por vegetação de porte arbóreo e formações pioneiras (ex.: Brejos, Cambarazal, Paratudal, Carandazal), localizadas ao longo dos cursos de água e em áreas de depressões que acumulam água (Figura 6).



FIGURA 6 - Exemplo de Vegetação com influência Fluvial (VF).
Fonte: WWF-BRASIL (2009).

3.4.5 Alteração Antrópica – AA

Áreas cuja vegetação nativa original apresenta sinais de alteração, mas ainda não foi convertida por completo para o uso de pastagem ou o uso agrícola, por exemplo:

- áreas de cerrado com menor densidade de cobertura vegetal;
- áreas de floresta com clareiras ou remoção das árvores de maior porte.



FIGURA 7 - Exemplo de Alteração Antrópica (AA).
Fonte: WWF-BRASIL (2009).

3.5 PROCESSAMENTO E ANÁLISE DE IMAGENS DIGITAIS

Para manipulação e extração de dados e análises geográficas utilizou-se o Sistema de Informação Geográfica ArcGIS 10.2 (ESRI, 2013).

A partir das imagens índices LANDSAT TM foram extraídos os valores correspondentes a cada índice espectral para cada ponto de amostragem da grade SALD e do Transecto. Deste modo, o modelo de regressão logística utilizará apenas as informações dos índices espectrais de cada pixel, para identificar a classe mais provável para o pixel (inundado ou não inundado), similarmente ao que ocorre em uma classificação "pixel a pixel" (SILVA, 2014).

Também foram extraídas as médias dos índices para áreas de entorno do pixel central (buffers) de 30 m, 60 m e 90 m para testes comparativos. Assim, a variabilidade espectral decorrente das variações da cobertura vegetal e umidade do solo/alagamento ao redor das estações limnimétricas será considerada no cálculo da probabilidade estatística de um pixel pertencer ou não a uma determinada classe (inundado ou não inundado), analogamente, ao que ocorre na classificação "por regiões" (OLIVEIRA et al., 2015).

3.6 AJUSTE DO MODELO DE REGRESSÃO LOGÍSTICA

As análises estatísticas e os ajustes dos modelos de Regressão Logística foram realizados com o uso do software R (R Core Team, 2014), usando a função de ligação *logit* e família binomial, do pacote *Rcmdr*.

Inicialmente as amostras (inundação, índices espectrais e a classificação de cobertura do solo) das três datas em análise foram agrupadas em uma única amostra para obter um número amostral maior ($n = 153$) e para incluir toda a variabilidade sazonal, de modo que o modelo seja capaz de prever a inundação em qualquer período do ano.

Inicialmente ajustou-se um modelo contendo todos os índices espectrais citados anteriormente (Seção 3.3) e a variável categórica de uso e ocupação do solo para avaliar seu poder preditivo no mapeamento da inundação. No entanto, outros modelos foram

ajustados sequencialmente a medida que foram empregados métodos de seleção de variáveis.

A seleção das variáveis que iriam compor o modelo foi baseada na análise de significância (p-valor), verificação do Fator de inflação da variância (VIF) para análise de multicolinearidade, método automatizado de seleção de variáveis (*Stepwise - função stepAIC*) e Critério de Informação de Akaike (AIC). Este métodos permitiram comparar modelos concorrentes com diferentes combinações de covariáveis, para selecionar o modelo com melhor ajuste. Também foram empregadas medidas da qualidade de ajuste do modelo como a Análise da Matriz de Confusão e Coeficiente Kappa.

Uma vez que o processo de modelagem por regressão logística (RL) demanda a estruturação de vários modelos até se obter o mais adequado ao fenômeno em análise, foi adotada uma nomenclatura em algarismos romanos para facilitar a referência aos mesmos.

3.7 VALIDAÇÃO DO MODELO

Após identificar o modelo a ser adotado, foram gerados mapas de probabilidade de inundação (p) correspondentes as três datas das observações da inundação em campo. Em seguida, extraiu-se as probabilidades de inundação para os pontos de amostragem do SALD Pirizal e do Transecto, estabelecendo-se um ponto de corte para obter a variável dicotômica, onde:

$$p \leq 0,5 = \text{não inundado}$$

$$p > 0,5 = \text{inundado}$$

Posteriormente, seguiu-se para validação do modelo com base na matriz de confusão apresentada na Tabela 1. Da análise da matriz de confusão foram extraídos o número de falsos positivos (pixels classificados erroneamente como inundados) e falsos negativos (pixels classificados erroneamente como não inundados) em cada data, para determinar a acurácia de classificação que possibilitou uma avaliação do desempenho do modelo de classificação.

4 RESULTADOS E DISCUSSÃO

4.1 AJUSTE DO MODELO DE REGRESSÃO LOGÍSTICA PARA CLASSIFICAÇÃO DA INUNDAÇÃO

A Tabela 3 apresenta os coeficientes estimados pela regressão logística, o erro padrão (E. P.), a estatística Wald (z) e o valor-p associado ao teste no modelo ajustado contendo os índices espectrais EVI, NDWI, NDVI, LSWI, SAVI, e a variável categórica LAND com a classificação da cobertura do solo (Modelo I).

TABELA 3 - Resultado do ajuste do modelo de regressão logística a partir dos índices espectrais EVI (*Enhanced Vegetation Index*), NDWI (*Normalized Difference Water Index*), NDVI (*Normalized Difference Vegetation Index*), LSWI (*Land Surface Water Index*), SAVI (*Soil Adjusted Vegetation Index*), e a variável categórica com a classificação da cobertura do solo, denominada LAND - Modelo I.

Variável	Coeficiente	E. P.	z	p-valor
Intercepto	- 0,8201	3,5710	-0,230	0,8184
EVI	- 0,0074	0,0076	-0,978	0,3282
NDWI	- 0,2714	0,9937	-0,273	0,7848
NDVI	0,0003	0,0012	0,248	0,8043
LSWI	2739	9937	0,276	0,7828
SAVI	0,0005	0,0043	-0,124	0,9010
LAND[Alteração Antrópica]	- 17,24	1777	-0,010	0,9923
LAND[Savana Arborizada]	0,2578	1,433	0,180	0,8573
LAND[Savana Florestada]	1,354	1,760	0,770	0,4415
LAND[Vegetação com Influencia Fluvial]	2,892	1,541	1,876	0,0606

AIC = 96,267

O modelo I resultou em AIC (Critério de Informação de Akaike) = 96,267 e não apresentou nenhum p-valor significativo para as variáveis empregadas. No entanto, a análise de multicolinearidade realizada através do Fator de Inflação da Variância (VIF), evidenciou que o modelo estava sendo prejudicado pela correlação entre as variáveis explicativas. Os valores VIF das variáveis do modelo I são apresentados na Tabela 4.

TABELA 4 - Fator de inflação da variância (VIF), para determinação de multicolinearidade entre as variáveis independentes EVI (*Enhanced Vegetation Index*), NDWI (*Normalized Difference Water Index*), NDVI (*Normalized Difference Vegetation Index*), LSWI (*Land Surface Water Index*), SAVI (*Soil Adjusted Vegetation Index*), e a variável categórica com a classificação da cobertura do solo, denominada LAND.

Variável	VIF
EVI	7,804634
NDWI	2734,328
NDVI	3,142513
LSWI	2734,108
SAVI	9,336821
LAND	1,060032

Segundo Logan (2010), valores de VIF maiores que 5 indicam colinearidade. Tal comportamento já era esperado, uma vez que as reflectâncias espectrais se repetem nas diferentes combinações utilizadas para gerar os índices espectrais, tornando-os altamente correlacionados.

Com base nos valores de VIF demonstrados na Tabela 4 verifica-se que principalmente os dois índices espectrais de umidade (NDWI, LSWI) com valores VIF acima de 2700 possuem altíssima correlação, mas que existe correlação também entre os índices de vegetação SAVI e EVI com valores VIF de 9,3 e 7,8 respectivamente. A variável categórica LAND, derivada do mapeamento de uso da terra pode ser considerada independente das demais.

Dessa forma, optou-se por utilizar o método automatizado de seleção de variáveis *Stepwise Backward* e critério de comparação do AIC (Akaike Information Criterion) para determinar as variáveis que deveriam compor o modelo.

A Tabela 5 apresenta os coeficientes estimados das variáveis independentes, o erro padrão (E.P.), a estatística Wald (z) e o p-valor associado ao novo modelo (Modelo II).

TABELA 5 - Resultado do ajuste do modelo de regressão logística considerando as variáveis selecionadas pelo método *Stepwise*, sendo elas LSWI (*Land Surface Water Index*), EVI (*Enhanced Vegetation Index*) e a variável categórica com a classificação da cobertura do solo, denominada LAND - Modelo II.

Variável	Coefficiente	E. P.	z	p-valor
Intercepto	0,6084	2,198	0,277	0,7819
LSWI	25,877	4,558	5,675	1,39 e ⁻⁰⁸
EVI	-0,0059	0,001338	-4,432	9,32 e ⁻⁰⁶
LAND[Alteração Antrópica]	-17,300	1779	-0,010	0,9922
LAND[Savana Arborizada]	0,2761	1,369	0,202	0,8402
LAND[Savana Florestada]	1,4700	1,652	0,890	0,3735
LAND[Vegetação com Influência Fluvial]	2,9455	1,507	1,954	0,0507

AIC = 90,609

O Modelo II, ajustado a partir das variáveis selecionadas pelo método *Stepwise* apresentou AIC = 90,609, melhor em comparação ao Modelo I uma vez que valores mais baixos de AIC indicam o modelo superior. Com descarte das variáveis correlacionadas, o z dos índices espectrais mantidos se tornam altamente significativas ($p < 0,01$). O cálculo do fator de inflação da variância (VIF), indica que o modelo reduzido não apresenta mais problema de multicolinearidade (Tabela 6).

TABELA 6 - Fator de inflação da variância (VIF), para avaliação de multicolinearidade entre as variáveis independentes LSWI (*Land Surface Water Index*), EVI (*Enhanced Vegetation Index*) e a variável categórica com a classificação da cobertura do solo, denominada LAND.

Variável	VIF
LSWI	1.252
EVI	1.358
LAND	1.041

Ainda da análise do Modelo II, verifica-se que a variável LAND é fracamente significativa, sendo esta dada através da classe “Vegetação com Influência Fluvial” ($p \leq 0,0507$). Embora as demais classes da variável LAND não sejam significativas, uma vez que uma categoria é incluída (ou excluída) em um modelo, a variável categórica devem ser incluída (ou excluídas) (HOSMER JR et al., 2013). Deste modo, a Tabela 7

apresenta os resultados de um modelo sem a variável categórica Land para analisar a sua importância para a capacidade preditiva do modelo.

TABELA 7 - Resultado do ajuste do modelo de regressão logística considerando apenas as variáveis LSWI (*Land Surface Water Index*) e EVI (*Enhanced Vegetation Index*) - Modelo III.

Variável	Coefficiente	E. P.	z	p-valor
Intercepto	-1.024508	1.546171	-0.663	0.507580
LSWI	23.404757	3.846626	6.084	$1,17e^{-09}$
EVI	-0.003881	0.001075	-3.609	$0,3e^{-03}$

AIC= 99,649

O Modelo III, ajustado somente com as variáveis (LSWI e EVI) apresentou AIC = 99,649, o que indica uma perda de desempenho em relação ao Modelo II (Tabela 5) que incluía a variável categórica LAND e apresentava AIC = 90,069. Segundo Logan (2010, p.211) quando a diferença do AIC entre dois modelos for maior que 2, o modelo com menor AIC é o mais parcimonioso.

Desta forma, o AIC indica que o Modelo II contendo a variável categórica de uso do solo é o modelo a ser preferido. Ao comparar modelos de classificação da inundação no Pantanal com diferentes combinações de variáveis preditivas, Silveira (2015) também constatou a importante contribuição da variável de uso e ocupação do solo para o desempenho do modelo, optando pela sua inclusão.

4.1.1 Modelo com informação espectral da área de entorno do pixel

A Tabela 8 apresenta o AIC obtido para os modelos ajustados com base na média dos índices espectrais para uma determinada área de entorno (*buffer*) de 30, 60 e 90 metros a partir dos pontos de monitoramento da inundação, para verificar seu efeito no ajuste no modelo em relação ao modelo ajustado com a informação espectral pontual apresentado na Tabela 5 (Modelo II).

TABELA 8 - Comparação do AIC (Critério de Informação de Akaike) entre os modelos ajustados com a informação espectral pontual (Modelo II) e os modelos ajustados com informação espectral extraída dos buffers de 30, 60 e 90 metros.

Modelo	AIC
Modelo II (Informação espectral pixel central)	90,609
Modelo IV - Buffers 30 m	101,01
Modelo V - Buffers 60 m	102,69
Modelo VI - Buffers 90 m	111,24

Apesar das possíveis implicações metodológicas (geometria de aquisição da imagem ou assinatura espectral não representativa) derivadas da comparação de valores espectrais de um pixel com observações de campo pontuais (inundação em uma régua fluviométrica, por exemplo), verificou-se que a inclusão da variabilidade espectral por meio da média dos índices na área de entorno do pixel não gerou melhoria no ajuste do modelo, constatada pelo expressivo aumento do AIC (Tabela 8). Com base na definição dada por Logan (2010, pág. 215), se a diferença do AIC entre dois modelos for maior que 2, o modelo com menor AIC é o mais parcimonioso.

Deste modo, concluiu-se que dentre todos os modelos ajustados, o Modelo II (Tabela 5) baseado na informação espectral referente unicamente ao pixel nas quais se localizam supostamente os pontos de amostragem (régua limnimétrica) e que inclui os índices espectrais LSWI, EVI e a variável categórica LAND foi o que apresentou melhor desempenho, sendo portanto, adotado para a sequência de análises.

Os índices LSWI e EVI também se demonstraram os mais adequados ao modelo classificatório de inundação desenvolvido por Silveira (2015) baseado em técnicas de regressão logística utilizando os índices espectrais do MODIS como variáveis preditivas.

4.2 DESEMPENHO DO MODELO DE CLASSIFICAÇÃO DA INUNDAÇÃO

A partir da seleção do modelo com melhor desempenho (Modelo II - Tabela 5), foram gerados mapas de probabilidade de inundação para os três períodos em análise. Apesar de o modelo ter sido gerado com todos os dados amostrais, incluindo todas as datas, os mapas de probabilidade de inundação foram gerados individualmente, pois a

condição de inundação muda ao longo do ano. Com base no ponto de corte estabelecido ($p \leq 0,5$ corresponde a áreas não inundadas e $p > 0,5$ corresponde a áreas inundadas (Figura 8).




FIGURA 8 - Mapas de inundação preditos pelo modelo de regressão logística (Modelo II) considerando as variáveis selecionadas pelo método *Stepwise* sendo elas LSWI (*Land Surface Water Index*) e EVI (*Enhanced Vegetation Index*) e a variável categórica com a classificação da cobertura do solo, denominada LAND.

A análise visual da Figura 8 demonstra que no mês de março o modelo classificou grande parte da área de estudo como inundada, correspondendo ao período de cheias no Pantanal Norte, e nos meses de maio e junho apresenta uma redução da área de inundação, correspondendo ao período de vazante e seca, respectivamente.

No entanto, verifica-se que a área inundada nas regiões sul e leste da área de estudo foram mantidas estáveis nos meses de maio e junho, se comparadas com a imagem de março, próximo ao pico da inundação na região. Ao comparar o mapa de inundação com a classificação de cobertura vegetal apresentada na Figura 2, verifica-se que tais regiões (flechas) correspondem a áreas cobertas por vegetação com influência fluvial. Essa vegetação é caracterizada por possuir porte arbóreo e formações pioneiras, como brejos, Cambarazal e Paratudal (WWF-BRASIL, 2009). Resultados obtidos em Zeilhofer (2006) utilizando dados multitemporais do LANDSAT TM para mapeamento do solo no Pantanal de Mato Grosso, demonstram que os índices de umidade não

variam somente em função da presença/ausência de água (inundação), mas também em função das características biofísicas do dossel. Segundo Xiao et al. (2005), no período da seca a resposta dos índices EVI e LSWI em áreas vegetadas é basicamente uma função do estado fisiológico do dossel. Neste caso, o índice LSWI detecta o teor de água presente na vegetação, e o modelo interpreta este valor como um padrão de inundação, gerando uma tendência de superclassificação da área inundada em regiões de vegetação de porte arbóreo, como o caso da classe vegetação com influência fluvial.

Na Tabela 9 é apresentada a matriz de confusão do modelo para cada data analisada, permitindo a análise das concordâncias e discordâncias entre as classificações e as observações de campo.

TABELA 9 - Validação do modelo de regressão logística aplicado aos mapas de inundação individualmente.

	Classificado	Observado	
		Não inundado	Inundado
26/03/2007	Não inundado	06	03
	Inundado	03	39
13/05/2007	Não inundado	37	00
	Inundado	07	07
14/06/2007	Não inundado	36	02
	Inundado	08	05
Total	Não inundado	79	05
	Inundado	18	51

Percebe-se que no mês de março (cheia) o modelo apresentou 6 discordâncias, sendo 3 casos de falsos positivos e 3 casos de falsos negativos. No mês de maio (vazante) apresentou 07 discordâncias, sendo todos falsos positivos. Por fim, no mês de junho (seca) apresentou 10 discordâncias, sendo 08 falsos positivos e 02 falsos negativos. Como visto na Figura 8, ocorrem nestas duas últimas datas principalmente superclassificações nas regiões sul e leste da área de estudo.

A Tabela 10 apresenta a acurácia de classificação, coeficiente Kappa e as taxas de falsos positivos (TFP) e falsos negativos (TFN) obtidas em cada uma das três imagens geradas pelo modelo, e os valores globais, obtidos a partir de uma análise de desempenho geral (independente da data).

TABELA 10 – Acurácia, coeficiente Kappa e taxas de falsos positivos (TFP) e falsos negativos (TFN) das imagens geradas pelo modelo de classificação para 26/03/2007; 13/05/2007 e 14/06/2007, e os valores globais, obtidos a partir de uma análise de desempenho geral (independente da data).

Conjunto	N	Acurácia (%)	Kappa	TFP (%)	TFN (%)
26/03/2007	51	88,24	0,595	33,33	7,14
13/05/2007	51	86,27	0,592	15,90	0
14/06/2007	51	80,39	0,391	18,18	28,57
Geral	153	84,97	0,691	18,56	8,93

Apesar de o modelo ter gerado apenas 3 falsos positivos em março, proporcionalmente esta classificação foi a que apresentou a maior TFP = 33,3%, pois de 9 pontos observados como não inundado, o modelo classificou 3 como inundados.

Verifica-se que a acurácia de classificação da imagem de março foi de 88,24%, superior à obtida nas classificações das outras duas datas (86,27% e 80,39%, para maio e junho, respectivamente). Apesar da classificação de março possuir acurácia superior às demais, a análise do coeficiente Kappa demonstra que as classificações de março e maio têm um coeficiente Kappa muito similar ($Kappa_{\text{março}} = 0,595$ e $Kappa_{\text{maio}} = 0,592$). Este resultado pode estar relacionado ao fato de que o coeficiente Kappa é uma medida de concordância que desconsidera a probabilidade de acerto casual, diferente da acurácia que expressa a proporção geral de pixels corretamente classificados independente de fatores aleatórios (CONGALTON, 1991). A imagem de maio apresentou a menor TFP = 15,90% e nenhum falso negativo.

Já no mês de junho verifica-se uma redução expressiva da acurácia e do coeficiente Kappa (0,391), indicando uma perda de desempenho do modelo no período de seca.

Percebeu-se também que o desempenho do modelo foi influenciado pelo tipo de cobertura do solo, pois a maior TFP = 33,33% foi verificada no período chuvoso (26/03/2007), em pontos correspondentes a áreas de Savana arborizada (Cerrado) localizadas na área do SALD Pirizal conforme mapa de uso e cobertura do solo (Figura 2). A Savana Arborizada é caracterizada por árvores de pequeno porte, de forma mais esparsa e dispostas entre vegetação contínua de porte arbustivo e herbácea (WWF-BRASIL, 2009). Comportamento semelhante foi encontrado por Silveira (2015) que verificou as maiores TFP para a formação de florestas inundáveis, seguida da formação Cerrado. Segundo Xiao et al. (2005), no período chuvoso o sinal da umidade de

formações vegetais, principalmente aquelas com dossel esparsos, é influenciado pela umidade da superfície do solo devido à ocorrência das chuvas. Deste modo, a umidade da vegetação e/ou do solo detectada pelo índice espectral pode confundir o modelo, gerando falsos positivos. Nos meses de maio e junho houve redução da taxa de falsos positivos, respectivamente TFP = 15,90% e TFP = 18,18%.

O modelo geral apresentou uma acurácia geral de 84,97%, e Índice de kappa de = 0,691, sendo o kappa obtido "muito bom", segundo os limiares estabelecidos por Landis e Koch (1977).

Com o objetivo de mapear áreas úmidas da planície de inundação do médio Araguaia, Dias (2004) empregou uma série histórica do LANDSAT TM (1987 - 2011) e um Modelo Digital de Elevação (MDE) e obteve uma acurácia de classificação das áreas úmidas de 87,1% e Kappa = 0,72. O autor destaca, que o uso do MDE possibilitou a detecção de áreas suscetíveis à inundação, mesmo que sob o dossel mais denso.

Chormanski et al. (2011), utilizaram imagens LANDSAT ETM +, que possuem características semelhantes às imagens TM, para determinar a extensão da inundação na Baixa Bacia do Biebrza, na Polônia. Os autores obtiveram um mapa de classificação de áreas inundadas e não inundadas com acurácia geral de 85% com as medições de campo.

Zarista (2013) desenvolveu modelos de regressão logística para diferenciação de áreas inundadas e não inundadas na mesma área amostral (SALD) do presente estudo, no Pantanal Norte. No entanto, Zarista (2013) empregou os índices EVI e LSWI do MODIS derivados de imagens com diferentes níveis de qualidade, alcançando uma acurácia de classificação entre 79,95% e 84,56%. Ainda na mesma área de estudo, Silveira (2015) desenvolveu modelos classificatórios de inundação utilizando os índices espectrais do MODIS como variáveis preditivas, e obteve um desempenho geral na faixa de 89% e kappa = 0,78.

Dessa forma os resultados obtidos a partir da análise de matriz de confusão. (acurácia de classificação de 84,97% e kappa de 0,691) demonstram que a metodologia empregada é eficaz no estabelecimento de um modelo de detecção de áreas inundadas e não inundadas no Pantanal Norte, com acurácia e Kappa semelhantes aos obtidos em estudos semelhantes voltados para classificação ou delimitação de áreas submetidas a processos de inundação.

5 CONCLUSÕES

Na seleção das variáveis independentes para compor o modelo, a combinação dos índices espectrais EVI e LSWI e a classificação de cobertura do solo, foi a que resultou no melhor ajuste do modelo.

Percebeu-se que o desempenho do modelo foi por vezes afetado pelo tipo de cobertura vegetal, o que sugere a realização de trabalhos futuros voltados especialmente para o entendimento desta relação, e sua qualidade variou de acordo com os períodos do ciclo de inundação, com melhor desempenho nos períodos de cheias e vazante.

De modo geral, pode-se concluir que o modelo de detecção da inundação no Pantanal Norte a partir de produtos LANDSAT TM, apresentou desempenho de classificação satisfatório.

Ademais, o modelo poderá ser utilizado para obter estimativas sobre as condições de inundações em outras datas de interesse, bastando substituir em cada caso as imagens índices LANDSAT TM referentes ao período de interesse. Tais informações poderão ser de grande utilidade na interpretação dos resultados obtidos em outras pesquisas ecológicas conduzidas na mesma área de estudo, referente ao Sítio de Amostragem de Longa Duração, uma vez que os níveis de inundação no Pantanal determinam as dinâmicas de fauna, flora, sedimentação, nutrientes, entre outras.

REFERÊNCIAS BIBLIOGRÁFICAS

ADÂMOLI, J. A dinâmica das inundações no Pantanal. **Anais do I Simpósio sobre Recursos Naturais e Socioeconômicos do Pantanal**. CPAP Embrapa, Corumbá, p. 51-62, 1986.

ANTUNES, A. F. B., LINGNAU, C. Uso de índices de acurácia para avaliação de mapas temáticos obtidos por meio de classificação digital. In: **III Congresso e Feira para Usuários de Geoprocessamento**. Curitiba, p. s/n. 1997.

BARBOSA, C. C. F. **Sensoriamento remoto da dinâmica de circulação da água do sistema planície de Curuaí/Rio Amazonas**. 2007. 282 f. Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2007.

BORRO, M. et al. Mapping shallow lakes in a large South American floodplain: a frequency approach on multitemporal Landsat TM/ETM data. **Journal of Hydrology**, v. 512, p. 39-52, 2014.

BRENNER¹, V. C., GUASSELLI, L. A. Índice de diferença normalizada da água (NDWI) para identificação de meandros ativos no leito do canal do rio Gravataí/RS–Brasil. *Anais XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR*, João Pessoa-PB, Brasil, 25 a 29 de abril de 2015, INPE.

BURNHAM, K.P.; ANDERSON, D.R. **Model selection and multimodel inference: a practical information-theoretic approach**. New York: Springer, 2002. 488p.

BURSAC, Zoran et al. Purposeful selection of variables in logistic regression. **Source code for biology and medicine**, v. 3, n. 1, p. 1, 2008.

BUSSAB, W. O. MORETTIN, P. A. **Basic Statistics**. São Paulo: Atual, 1987.

CHANDRASEKAR, K.; SAI, M. V. R. S.; ROY, P. S.; DWEVEDI, R. S. Land Surface Water Index (LSWI) response to rainfall and NDVI using the MODIS Vegetation Index product. **International Journal of Remote Sensing**, v. 31, n. 15, p. 3987–4005, 2010.

CHORMANSKI, J., OKRUSZKO, T., IGNAR, S., BATELAAN, O., REBEL, K. T. WASSEN, M. J. Flood mapping with remote sensing and hydrochemistry: A new method to distinguish the origin of flood water during floods. **Ecological Engineering**, v. 37, n. 9, p. 1334-1349, 2011.

CUNHA, C.; JUNK, W. J. Distribution of woody plant communities along the flood gradient in the Pantanal of Poconé, Mato Grosso, Brazil. **International Journal of Ecology and Environmental Sciences**, v. 27, n. 2, p. 63-70, 2001.

CONGALTON, R. G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote sensing of environment**, v. 37, n. 1, p. 35-46, 1991.

DAMASCENO-JUNIOR, G. A. et al. Structure, distribution of species and inundation in a riparian forest of Rio Paraguai, Pantanal, Brazil. **Flora-Morphology, Distribution, Functional Ecology of Plants**, v. 200, n. 2, p. 119-135, 2005.

DIAS, A. P. **Análise espacial aplicada à delimitação de áreas úmidas da planície de inundação do médio Araguaia**. Dissertação (Mestrado em Ciências Ambientais e Florestais) - Universidade Federal de Mato Grosso, 2004.

EMILIANO, P. C. **Fundamentos e aplicações dos critérios de Informação: akaike e bayesiano**. Dissertação (Mestrado em Estatística e Experimentação Agropecuária) - Universidade Federal de Lavras, 2009.

ESRI. **ArcGIS Desktop: Release 10**. 2013. Redlands, CA: Environmental Systems Research Institute.

FANTIN-CRUZ, I. **Dinâmica da inundação em mesoescala na planície de inundação do rio Cuiabá-Brasil**. 2008. Dissertação (Mestrado em Ecologia e Conservação da Biosiversidade) - Instituto de Biociências, Universidade Federal de Mato Grosso, Cuiabá, 2008.

FANTIN-CRUZ, I., GIRARD, P., ZEILHOFER, P., COLLISCHONN, W., CUNHA, C. N. Meso-scale phytophysognomic units in the Northern Pantanal and their relations with geomorphology, **Biota Neotropica**, v. 10, n. 2, p. 31-38, 2010.

FERNANDES, I. M.; SIGNOR, C. A.; PENHA, J. Biodiversidade no Pantanal de Poconé. **Cuiabá: Centro de Pesquisa do Pantanal**, 2010.

WWF-BRASIL. **Monitoramento das alterações da cobertura vegetal e uso do solo na Bacia do Alto Paraguai - Porção Brasileira - Período de Análise 2002 a 2008**. Brasília, 2009.

GIRARD, P., FANTIN-CRUZ, I., OLIVEIRA, S. M. L., HAMILTON, S. K. Small-scale spatial variation of inundation dynamics in a floodplain of the Pantanal (Brazil). **Hydrobiologia**, v. 638, n. 1, p. 223-233, 2010.

GAO, B.-C. NDWI - A Normalized Difference Water Index for Remote Sensing of Vegetation Liquid Water From Space. **Remote sensing of environment**, v. 58, p. 257-266, 1996.

GOLTZ, E., BRANDÃO, D., TOMÁS, L. R., MANTELLI, L. R., ADAMI, M., SHIMABUKURO, Y. E., & FORMAGGIO, A. R. Utilização de índices espectrais de vegetação (MODIS) na determinação de áreas suscetíveis a alagamento no Pantanal Sul-matogrossense. **SIMPÓSIO DE GEOTECNOLOGIAS NO PANTANAL**, v. 1. 2006.

Hayakawa, E. H., do Couto, E. V., de Souza Filho, E. E., do Prado, B. R., & Paula, P. F. Análise temporal da planície de inundação do alto rio Paraná (região de Porto Rico-PR)

através de dados de sensoriamento remoto-[doi: 10.4025/bolgeogr. v28i1. 8086](https://doi.org/10.4025/bolgeogr.v28i1.8086). **Boletim de Geografia**, v. 28, n. 1, p. 115-126, 2010.

HAMILTON, S. K.; SIPPEL, S. J.; MELACK, J. M. Inundation patterns in the Pantanal wetland of South America determined from passive microwave remote sensing. **Archiv für Hydrobiologie**, v. 137, p. 1–23, 1996.

HOSMER JR, D. W., LEMESHOW, S., STURDIVANT, R. **Applied logistic regression**. John Wiley & Sons, 2013.

HUETE, A. R., JACKSON, R. D., POST, D. F. Spectral response of a plant canopy with different soil backgrounds. **Remote sensing of environment**, v. 17, n. 1, p. 37-53, 1985.

HUETE, A. R.; JACKSON, R. D. Suitability of spectral indices for evaluating vegetation characteristics on arid rangelands. **Remote sensing of environment**, v. 23, n. 2, p. 213IN1-232IN8, 1987.

HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote sensing of environment**, v. 25, n. 3, p. 295-309, 1988.

HUANG, C., CHEN, Y.; WU, J. Mapping spatio-temporal flood inundation dynamics at large river basin scale using time-series flow data and MODIS imagery. **International Journal of Applied Earth Observation and Geoinformation**, v. 26, p. 350-362, 2014.

JARDIM-LIMA, D., PIEDADE, M. T. F., QUEIROZ, H. D., NOVO, E. M. L. M. RENNÓ, C. D. A dinâmica do Pulso de inundação: aplicações de sensoriamento remoto na avaliação da área de águas abertas e morfologia dos lagos de várzea da Reserva de Desenvolvimento Sustentável Mamirauá-Amazônia Central. **XII Simpósio Brasileiro de Sensoriamento Remoto, Goiânia/INPE**, p. 3069-3076, 2005.

JIANG, Z., HUETE, A. R., DIDAN, K., MIURA, T. Development of a two-band enhanced vegetation index without a blue band. **Remote Sensing of Environment**, v. 112, n. 10, p. 3833-3845, 2008.

JUNK, W.J.; BAYLEY, P.B. & SPARKS, R.E. The flood pulse concept in river - floodplain systems. p. 110-127. In: D.P. Dodge (ed.). **Proceedings International Large River Symposium (LARS)**, Canadian Special Publication of Fisheries and Aquatic Sciences, Ottawa, v. 106, p. 110-127, 1989.

LANDIS, J. R., KOCH, G. G. The measurement of observer agreement for categorical data. **Biometrics**, p. 159-174, 1977.

LIMA, L. P. Z. **Caracterização multitemporal das planícies de inundação dos rios Grande e Aiuruoca através da aplicação de técnicas de sensoriamento remoto e SIG**. 113 f. Dissertação (Mestrado em Ecologia Aplicada). Universidade Federal de Lavras, Lavras, 2010.

LOGAN, M. **Biostatistical Design and Analysis Using R: A Practical Guide**. [S.l.]: John Wiley & Sons, 2010.

LIU, H., HUETE, A. A feedback based modification of the NDVI to minimize canopy background and atmospheric noise. **Geoscience and Remote Sensing, IEEE Transactions on**, v. 33, n. 2, p. 457-465, 1995.

MINITAB INC. (2010). Regressão e correlação, **Introdução ao Minitab 17**. Disponível em: <www.minitab.com>.

MIURA, A. K. **Identificação e quantificação de áreas de formação pioneira de influencia fluvial do Litoral Centro-Sul Paranaense, por meio de técnicas de sensoriamento remoto**. 118 f. Dissertação (Mestrado em Engenharia Florestal). Universidade Federal do Paraná, Curitiba, 1999.

MORRISON, J. S. Seleção de variáveis no desenvolvimento de modelos. **Tecnologia de Crédito-Serasa**, v. 57, p. 24-40, 2006.

O'BRIEN, R. M. A caution regarding rules of thumb for variance inflation factors. **Quality & Quantity**, v. 41, n. 5, p. 673-690, 2007.

OLIVEIRA, F. P.; FERNANDES FILHO, E. I.; SOUZA, A. L.; SOARES, V. P. Mapeamento de florestas monodominadas por *Myrcrodruon urundeuva* com imagens TM-Landsat 5 e Rapideye. **Floresta e Ambiente**, v. 22, p. 322-333, 2015.

ORDOYNE, C.; FRIEDL, M. A. Using MODIS data to characterize seasonal inundation patterns in the Florida Everglades, **Remote Sensing of Environment**, v. 112, n. 11, p. 4107-4119, 2008.

PADOVANI, C. R. **Dinâmica Espaço-Temporal das Inundações do Pantanal**. 175 p. Tese (Doutorado) — Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo, Piracicaba, 2010.

PCBAP, Brasil. Diagnóstico dos meios físico e biótico. Projeto Pantanal, Programa Nacional do Meio Ambiente. Plano de Conservação da Bacia do Alto Paraguai. MMA/PNMA, Brasília, 433p., 1997.

PENHA, J. M. F.; DA SILVA, C. J.; BIANCHINI-JÚNIOR, I. Productivity of the aquatic macrophyte *Pontederia lanceolata* Nvtt.(Pontederiaceae) on floodplains of the Pantanal Mato-grossense, Brazil. **Wetlands Ecology and Management**, v. 7, n. 3, p. 155-163, 1999.

PIEDADE, M. T. F. et al. As áreas úmidas no âmbito do Código Florestal brasileiro. **Código Florestal e a Ciência: O que nossos legisladores ainda precisam saber.**, p. 9, 2012.

R CORE TEAM. **R: A Language and Environment for Statistical Computing**. Vienna, Austria, 2014. Disponível em: <<http://www.R-project.org/>>.

REBELLATO, L; CUNHA, C. N. Efeito do “fluxo sazonal mínimo da inundação” sobre a composição e estrutura de um campo inundável no Pantanal de Poconé, MT, Brasil. **Acta Botânica Brasilica**, v. 19, n. 4, p. 789-799, 2005.

SAKAMOTO, T.; NGUYEN, N. V.; KOTERA, A.; OHNO, H. ISHITSUKA, N.; YOKOZAWA, M. Detecting temporal changes in the extent of annual flooding within the Cambodia and the Vietnamese Mekong Delta from MODIS time-series imagery. **Remote Sensing of Environment**, v. 109, n. 3, p. 295-313, 2007.

SILVA, J. V. **Aplicações de técnicas de sensoriamento remoto e sistema de informações geográficas na avaliação da dinâmica de inundação no Pantanal**. São José dos Campos. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, 1991.

SILVA, J. D. S. V., ABDON, M. M. Delimitação do Pantanal brasileiro e suas sub-regiões. **Pesquisa agropecuária brasileira**, 33(13), 1703-1711, 1998.

SILVA, J. S. et al.. Avaliação de superfícies inundáveis em zonas úmidas da bacia Amazônica por meio de dados espaciais, **Anais do XIV Simpósio Brasileiro de Sensoriamento Remoto**, 2009.

SILVA, V. M. **Classificação de Imagens por Sensoriamento Remoto: Análise comparativa das Metodologias Pixel-a-Pixel e Segmentação por Região**. Monografia (Especialização em Geoprocessamento). Instituto de Geociências, Universidade Federal de Minas Gerais, Belo Horizonte, 2014.

SILVEIRA, S. W. G. **Análise de desempenho de produtos Modis para modelagem da dinâmica De inundação do pantanal Mato-grossense**. 2015. 100 f. Tese (Doutorado em Física Ambiental) - Instituto de Física, Universidade Federal de Mato Grosso, Cuiabá, 2015.

USGS. 2016. United States Geological Survey. **The Final Journey of Landsat 5: A Decommissioning Story**. Disponível em: < <http://landsat.usgs.gov>>.

TIAN, B. et al. Detecting wetland changes in Shanghai, China using FORMOSAT and Landsat TM imagery. **Journal of Hydrology**, v. 529, p. 1-10, 2015.

THOMAS, R. F. et al. Mapping inundation in the heterogeneous floodplain wetlands of the Macquarie Marshes, using Landsat Thematic Mapper. **Journal of Hydrology**, v. 524, p. 194-213, 2015.

XIAO, X., Zhang, Q., Saleska, S., Hutyrá, L., De Camargo, P., Wofsy, S. Moore, B. Satellite-based modeling of gross primary production in a seasonally moist tropical evergreen forest. **Remote Sensing of Environment**, v. 94, n. 1, p. 105-122, 2005.

ZARISTA, S. **Monitoramento da dinâmica de inundação no Pantanal Norte com uso dos índices EVI e LSWI do MODIS**. Dissertação (Mestrado em Física Ambiental). Instituto de Física - Universidade Federal de Mato Grosso, Cuiabá, 2013.

ZEILHOFER, P; SCHESSL, M. Relationship between vegetation and environmental conditions in the northern Pantanal of Mato Grosso, Brazil. **Journal of Biogeography**, v. 27, n. 1, p. 159-168, 2000.

ZEILHOFER, P. Soil Mapping in the Pantanal of Mato Grosso, Brazil, using Multitemporal Landsat TM data. **Wetlands Ecology and Management**, v. 14, pg. 445-461, 2006.