



## DINÂMICA DO USO E COBERTURA DA TERRA DO ENTORNO DO RESERVATÓRIO DO PASSO REAL – RS

Franciel Eduardo Rex<sup>1</sup> Verônica Satomi Kazama<sup>2</sup> Ana Paula Dalla Corte<sup>3</sup> Carlos Roberto Sanquetta<sup>3</sup>

<sup>1</sup>Mestrando em Engenharia Florestal - UFPR, Curitiba, Paraná, Brasil  
(francielrexx@gmail.com)

<sup>2</sup>Doutoranda em Engenharia Florestal, UFPR

<sup>3</sup> Dr(a), Professor do Curso de Engenharia Florestal, UFPR  
Centro BIOFIX de Pesquisa em Biomassa e Sequestro de Carbono, Universidade Federal do Paraná – UFPR

Recebido em: 06/04/2018 – Aprovado em: 10/06/2018 – Publicado em: 20/06/2018

DOI: 10.18677/EnciBio\_2018A35

### RESUMO

O uso da terra em uma paisagem pode apresentar uma série de modificações durante um determinado período. Por meio de imagens de satélite e técnicas de Sensoriamento Remoto é possível obter uma visão do espaço sobre as alterações ao longo do tempo, bem como, inferir se essas modificações estão ocorrendo de forma negativas ou positiva. O objetivo deste estudo foi realizar uma análise temporal do uso e cobertura da terra do entorno do reservatório do Passo Real – RS, com o uso de técnicas de classificação digital em imagens Landsat, em um período de 26 anos. O estudo foi realizado na região centro-norte do Rio Grande do Sul. Foram necessárias duas imagens do satélite Landsat. De posse das imagens, estas foram corrigidas geometricamente, e em seguida foram coletadas as amostras de treinamento e aplicado os algoritmos de classificação. Em seguida foram obtidas as matrizes de confusões, os índices de Exatidão Global e Kappa, para realizar a avaliação da qualidade das classificações. Por fim, foi a realizado a análise temporal (dinâmica) com base no melhor algoritmo de classificação. O melhor desempenho foi do algoritmo da MaxVer, que apresentou valores excelentes de Exatidão Global e de índice Kappa para ambas as imagens do satélite Landsat. A dinâmica observada da área de estudo apresentou relevantes mudanças, sendo que as principais alterações da paisagem estão relacionadas com as classes de vegetação, havendo notáveis transições para as áreas de agricultura. O uso do Sensoriamento Remoto se revela de grande importância para estudos ambientais.

**PALAVRAS-CHAVE:** Análise temporal, máxima verossimilhança; sensoriamento remoto.

## DYNAMICS OF USE AND LAND-COVER IN THE SURROUNDINGS OF PASSO REAL RESERVOIR – RS

### ABSTRACT

The Land use in a landscape can exhibit a number of changes over a given period. Through satellite imagery and Remote Sensing techniques it is possible to obtain a view of space over changes over time, as well as infer whether these modifications are occurring in a negative or positive way. The objective of this study was of realize a temporal analyze of use and land-cover in the surroundings of Passo Real reservoir – RS, with the use of digital classification techniques in Landsat images, over a period of 26 years. The study was conducted in the central-north region of Rio Grande do Sul. Two images of the Landsat satellite were required. With the images, these were corrected geometrically, and then the training samples were collected and the classification algorithms were applied. In the next step, the matrices of confusion, the Global Accuracy and Kappa indices, were obtained to evaluate the quality of the classifications. Finally, we performed the temporal analysis (dynamics) based on the best classification algorithm. The best performance was the MaxVer algorithm, which presented excellent Global Accuracy and Kappa index values for both Landsat satellite images. The observed dynamics of the study area presented relevant changes, and the main changes in the landscape are related to the vegetation classes, with notable transitions to the areas of agriculture. The use of Remote Sensing is of great importance for environmental studies.

**KEYWORDS:** Temporal analysis, remote sensing, maximum likelihood.

### INTRODUÇÃO

Os acordos internacionais para redução dos gases de efeito estufa (GEE) estão mudando o cenário de energia de forma a intensificar a atenção para as fontes que garantam o uso sustentável do meio ambiente (SILVA et al., 2016). No Brasil, o sistema de energia é composto basicamente por Usinas Hidrelétricas (UHE) e Usina Termelétrica (UTE) que representam mais de 80% do total de empreendimentos em operação, sendo a energia de usinas hidrelétricas responsável por 61% da capacidade de geração total de energia do país (ANEL, 2017).

Apesar do Brasil ser destaque em produção de energia de origem hídrica, ainda existe um cenário de crescente produção desta energia, principalmente no norte do país (LESSA et al., 2015), o que tem causado preocupações, devidos as modificações extremas que ocorrem no meio ambiente de entorno. Uma vez que, para a construção de uma usina hidrelétrica são necessárias áreas de empréstimos, locais utilizados para a remoção de solo e descarte de materiais diversos, que causam modificações da paisagem, e produzem impactos ambientais, sociais e econômicos (SILVA et al., 2016).

Assim, as mudanças na dinâmica do uso e ocupação da cobertura da terra nas proximidades de um reservatório de uma usina hidrelétrica é uma zona importante para ser compreendida por representar o reflexo do impacto causado pela necessidade de uma fonte de energia renovável. Uma vez que, a antropização do espaço é capaz de causar problemas de desequilíbrio ambiental, em especial devido ao desflorestamento e à supressão de vários tipos de vegetação (GOUVEIA et al., 2013; SANTOS; AQUINO, 2015).

Com o uso do sensoriamento remoto é possível ter acesso às informações do ambiente, muitas vezes com baixos custos, visto que algumas plataformas já disponibilizam gratuitamente seus produtos, como os da série Landsat (NEVES; SILVA, 2014). Ademais, é possível monitorar a evolução espaço-temporal do ambiente em diferentes escalas (ZAKS; KUCHARIK, 2011; KUEMMERLE et al., 2013).

Nesse sentido, o presente trabalho teve como objetivo efetuar uma análise temporal da dinâmica do uso e cobertura da terra em período de 26 anos (1990 – 2016) do entorno do reservatório do Passo Real – RS, por meio da seleção do melhor desempenho de algoritmos de classificação digital de imagens e combinações de bandas da série Landsat.

## MATERIAL E MÉTODOS

### Caracterização da área de estudo

O local de estudo está situado no centro-norte do estado do Rio Grande do Sul, o reservatório Passo Real, que é considerado o maior lago artificial do estado, pertencente à Usina Hidrelétrica Passo Real. A extensão deste corpo de água varia em função do nível de água aproximando-se de 220km<sup>2</sup>, alagando área de sete municípios, sendo eles: Fortaleza dos Valos, Salto do Jacuí, Campos Borges, Quinze de Novembro, Ibirubá, Alto Alegre e Selbach.

### Obtenção das Imagens de Satélite e Processamento

Para a realização deste estudo foram utilizadas duas imagens da série Landsat. A primeira imagem refere-se ao satélite Landsat 5, sensor TM (*Thematic Mapper*) datada de 06 de agosto de 1990, com uma órbita/ponto de 222/80. A segunda imagem faz parte da série Landsat 8, do sensor OLI (*Operational Land Imager*), datada de 13 de agosto de 2016, possuindo a mesma órbita/ponto. Desta forma, com as referidas imagens, tem-se um intervalo de tempo de 26 anos para realizar a análise temporal da dinâmica do uso e cobertura da terra do entorno da represa do Passo Real – RS.

As imagens foram adquiridas a partir do catálogo do Instituto Nacional de Pesquisas Espaciais - INPE (<http://www.inpe.br/>). Optou-se por uma cena que estivesse livre de interferências como a presença de nuvens, as quais podem prejudicar na interpretação dos dados, e também, por imagens de uma mesma época.

As bandas utilizadas e testadas neste estudo foram as seguintes: Para o satélite Landsat 5, utilizou-se as bandas (1, 2, 3, 4, 5 e 7) e para o Landsat 8 foram utilizadas as bandas (2, 3, 4, 5, 6 e 7). Com posse destes dados, o primeiro procedimento foi a realização da correção geométrica destas imagens, também conhecido como georreferenciamento. O procedimento de georreferenciamento deste estudo, teve como base/referência a imagem do satélite Landsat 8, ou seja, esta cena foi utilizada para corrigir geometricamente a imagem do satélite Landsat 5. Neste procedimento, buscou-se por pontos homólogos e de fácil reconhecimento nas duas imagens, tais como cruzamentos de estradas.

A escolha dos pontos de controle foi feita obedecendo uma distribuição uniforme por toda a imagem, tentando obter um georreferenciamento com o menor erro possível. Ao realizar um georreferenciamento de imagens, leva-se em consideração o erro quadrático máximo (RMS), assume-se o valor de até 0,5 pixel. De acordo com Meneses e Almeida (2012), o valor de RMS é expresso em números de pixels.

Após o georreferenciamento, a imagem foi recortada para a área de interesse. O *software* utilizado no processamento digital das imagens foi o *Envi Classic* na versão 5.1, em ambiente *Windows*. Ademais, foi utilizado o *software* livre QGIS 2.18 para obtenção das áreas das classes em estudo e confecção dos *layouts* de mapa.

### Construção da chave de interpretação

Para realizar as classificações, primeiramente foram definidas sete classes do uso e cobertura da terra, conforme a análise da área de estudo na imagem. Essas classes são representadas no Quadro 1.

**QUADRO 1:** Chave de Interpretação para coleta das amostras de treinamento para a classificação das imagens.

Chave de Interpretação	
Classes	Informações
Água	Fazem parte desta categoria os cursos d'água de rios, as lagoas e os lagos artificiais (reservatórios).
Vegetação Florestal	Categoria de cobertura vegetal natural, arbórea, representada por vários tipos fitosionômicos de florestas.
Vegetação Agrícola	Áreas cobertas predominantes por algum tipo de vegetação do tipo agrícola, ou, gramíneas, plantas gramínoideas, etc.
Solo 1	Descaracterizado de cobertura vegetal, solo com alto teor de argila, apresentando alto teor de água.
Solo 2	Geralmente essas áreas representam o solo preparado ou cultura colhida.
Sombra	As áreas de sombra aparecem com tonalidade muito escura, devido à geometria de visada e ao relevo.
Urbano	A área urbana compreende as áreas ocupadas por edificações, como cidades, vilas, etc

FONTE: Os Autores.

O Quadro 1 foi utilizado como base para a seleção de amostras, as quais são posteriormente foram utilizadas em um processo de treinamento do algoritmo para a alocação dos pixels em classes.

### Classificações digitais de imagens

Foram utilizados três algoritmos classificadores, dois de classificação supervisionada e um algoritmo de classificação não-supervisionada. Os classificadores podem ser não-supervisionados ou supervisionados. Nos algoritmos do primeiro tipo, a classificação está apoiada em métodos estatísticos de análise de agrupamento, e a identificação das classes ocorre sem a intervenção direta do intérprete. Os supervisionados fundamentam-se na definição das classes e na coleta das amostras executadas pelo usuário, e utilizam-se das amostras para gerar os padrões e, assim, rotular os pixels como pertencentes a uma determinada classe, através de métodos paramétricos e não-paramétricos (NOVO, 2011).

Os algoritmos supervisionados testados foram: método da Mínima Distância, e o método da Máxima Verossimilhança (MaxVer), que é um método de classificação estatística baseado na média ponderada das distâncias entre as classes estudadas (RÊGO et al., 2018). E o algoritmo de classificação não supervisionada foi o "ISODATA", que consiste em uma técnica de agrupamento que classifica regularidades em conjuntos de dados (LI et al., 2017). Para este algoritmo, foi especificado o número de classes, o que foi definido com base na chave de interpretação, ou seja, 7 classes. A principal diferença entre os dois métodos de classificação é se existem amostras de treinamento suficientes (LI et al., 2017).

### **Avaliação das Classificações**

De acordo com Moreira (2005), para aferir a veracidade do resultado da classificação de uma imagem, deve-se determinar a qualidade do mapa temático. Desta forma a acurácia do mapa foi produzida utilizando a matriz de confusão ou de erros. Como subproduto da matriz de confusão é calculado o índice Kappa (k), ou ainda, segundo Ponzoni e Rezende (2002), é calculado a partir da seguinte Equação 1:

$$k = \frac{N \sum x_{ii} - \sum x_{i+} \cdot x_{+i}}{N^2 - \sum x_{i+} \cdot x_{+i}} \quad \text{Eq. 1}$$

Em que:  $N$  = número total de observações;  $x_{ii}$  = elementos da diagonal principal da matriz; e  $x_{i+}$  e  $x_{+i}$  = somatório dos elementos da linha e coluna, respectivamente.

O valor de  $k$  expressa a concordância entre a classificação dos dados contidos nos produtos de sensoriamento remoto considerados e a realidade de campo (verdade terrestre), mostrando a qualidade da classificação. Já o índice de exatidão global, conforme descrito por Ponzoni e Rezende (2002), é descrito pela Equação 2:

$$G = \frac{\sum n_{ii}}{n} \quad \text{Eq. 2}$$

Em que:  $G$  é a exatidão global;  $n_{ii}$  o número de elementos da diagonal da matriz de confusão; e  $n$  o número total de observações.

A avaliação do algoritmo de classificação não-supervisionada foi realizada com base na imagem de melhor classificação dos algoritmos de classificação supervisionada.

### **Combinações de bandas**

Após realizar todos os procedimentos de classificação e aferição das classificações, o algoritmo de melhor desempenho foi testado em diferentes combinações de bandas. A primeira combinação de bandas do satélite Landsat 5 levou em consideração apenas as bandas do visível, ou seja, a banda 3 (região do vermelho), banda 2 (região do verde) e a banda 1 (região do azul). A segunda combinação considerou as bandas do infravermelho médio (banda 7), as bandas 5 e 4 do infravermelho próximo e a banda 3 da região do visível. Por fim, a última combinação

de bandas levou em consideração a banda 7 e 5 com a incorporação de um índice de vegetação (NDVI).

O índice de vegetação - NDVI foi utilizado para transformar os dados multiespectrais do sensor TM, ou seja, para reduzir a dimensionalidade da imagem, assim tem-se uma única banda representando a distribuição da vegetação. Os valores do NDVI indicam a quantidade de vegetação verde presente no pixel, ou seja, quanto maior o valor do NDVI, mais vegetação verde possui o pixel. O NDVI foi gerado por meio do seguinte algoritmo padrão, conforme a Equação 3:

$$NDVI = (NIR - R) / (NIR + R) \quad \text{Eq.3}$$

Em que: *NIR* = valor do pixel na faixa do espectro eletromagnético correspondente à região do infravermelho próximo (0,7 a 0,9  $\mu\text{m}$ ); *R* = valor do pixel na faixa do espectro eletromagnético correspondente a região do vermelho (0,6 a 0,7  $\mu\text{m}$ ).

## RESULTADOS E DISCUSSÕES

### Análise das classificações

Para análise das classificações foi realizado um *ranking* com os valores encontrados para os índices de Exatidão Global (G%) e índice Kappa (K) para todos os algoritmos testados, estes foram ranqueados conforme o melhor desempenho. O índice Kappa de todos os classificadores supervisionados foi superior a 0,87, o que de acordo Landis e Koch (1977), são considerados como excelentes resultados, para o classificador não-supervisionado, o valor encontrado para o índice Kappa foi de 0,33, que é considerado como uma classificação razoável.

O algoritmo MaxVer apresentou o melhor desempenho com base nos parâmetros avaliados (Exatidão Global e Índice Kappa) entres os algoritmos de classificação. Estes resultados são comumente observados na literatura, pode-se citar trabalhos como o de Lu et al. (2014) e Adam et al. (2014) que encontraram resultados semelhantes, com bom desempenho do algoritmo classificador MaxVer. De modo geral, este classificador é considerado um dos que costumam apresentar acurácia mais alta entre os métodos existentes (NIKNEJAD et al., 2014). Por outro lado, Martins et al. (2017) ao compararem o desempenho de classificadores supervisionados na região amazônica, encontraram resultados onde o método MaxVer obteve-se o pior desempenho, sendo o método da distância mínima e redes neurais artificiais o melhor resultado.

Nesse sentido, percebe-se que a utilização de classificadores digitais de imagens revela-se com uma ferramenta potencial para obtenção de informações, como explanado por Sothe et al. (2017) que concluíram que o uso de classificação automatizada se mostra como uma alternativa interessante para auxiliar no estudo de áreas extensas e de difícil acesso, economizando assim esforço do operador bem como tempo de processamento computacional.

Em síntese, os valores encontrados para os classificadores foram os seguintes: Min Dist (G% = 90,20, K = 0,8787); MaxVer (G% = 94,90; K = 0,9368) e Isodata (G% = 43,33; K = 0,3364). Dado o exposto, o algoritmo MaxVer serviu como base para os demais procedimentos, ou seja, a aplicação desse algoritmo foi aplicada em diferentes combinações de bandas com explanado anteriormente na metodologia. De acordo com o resultado desta etapa, todas as combinações de bandas testadas apresentaram

valores excelentes, conforme a classificação proposta por Landis e Koch (1977), tendo o melhor desempenho, a combinação das bandas 7 e 5 com a inclusão do índice de vegetação (NDVI) do satélite Landsat 5, os valores encontrados de  $G\% = 94,74\%$  e  $K = 0,9348$ .

O segundo melhor desempenho foi da combinação das bandas (7, 5, 4 e 3) do mesmo satélite, que representam as bandas do infravermelho médio, próximo e a banda do vermelho. A combinação das bandas do visível, que representam a cor verdadeira, apresentou o menor valor para os parâmetros de avaliação da qualidade da classificação, porém, enquadrando-se em excelente classificação.

Goldblatt et al. (2018) testaram índices de vegetação como entrada para classificação supervisionada e encontraram melhorias nos resultados de classificação, o que vem de acordo com este trabalho. Este resultado pode ser justificado pelo fato de que a combinação de bandas com um índice de vegetação além de reduzir a dimensionalidade dos dados, pode apresentar resultados mais satisfatórios uma vez que a intuito do índice de vegetação é de ressaltar com maior vigor as diferenças na vegetação.

### Análise das matrizes de confusões

Em seguida é apresentada a matriz de confusão das classificações do algoritmo MaxVer utilizando todas as bandas do satélite Landsat 5 e em seguida a replicação desse algoritmo para a imagem do Landsat 8 com a mesma composição de bandas, já que esta apresentou o melhor desempenho.

Conforme o resultado da matriz de confusão do algoritmo MaxVer (Tabela 1) percebe-se que a classe “Urbano” apresentou a maior confusão entre as classes classificadas, apenas 45,43% dos pixels foram classificados corretamente, a maior confusão com essa classe se deu com a classe “Solo 1” cerca de 44,35% dos pixels foram classificados erroneamente, também houve confusão com a classe “Solo 2”, cerca de 9,68% e uma pequena confusão de 0,27% com a classe “Vegetação Agrícola”.

**TABELA 1:** Matriz de confusão do algoritmo MaxVer para a imagem do Landsat 5 e valores de Acurácia do Produtor e Usuário.

Classes	Água	Veg. F	Urbano	Veg. A	Solo 1	Solo 2	Sombra
Água	99,3	0	0	0	0	0	0
Veg. F	0	97,89	0,27	0	0,09	0	0
Urbano	0,7	0,13	45,43	0	3,33	3,05	0
Veg. A	0	0,04	0,27	98,7	0	0	0
Solo 1	0	1,93	44,35	0	93,67	2,76	1,12
Solo 2	0	0	9,68	0	2,92	94,19	0
Sombra	0	0	0	1,3	0	0	98,88
Total	100	100	100	100	100	100	100

FONTE: Os Autores.

As classes “Solo 1” e “Solo 2” após a classe “Urbano” apresentaram os valores mais baixos de acerto, mesmo assim, essas classes apresentaram bons valores de classificação correta dos alvos, os valores foram acima de 93%. Pode-se ainda comentar que as confusões destas classes seguem o mesmo padrão de confusão da classe “Urbano”, ou seja, as confusões são verificadas entre os tipos de solos ou com os alvos referentes a classe “Urbano”.

As demais classes avaliadas apresentaram pequenas confusões, para a classe “Vegetação Arbórea” a maior confusão deu-se com a classe “Solo 1” cerca de 1.93%, já para a “Vegetação Agrícola” houve apenas confusão com a classe “Solo 2”, sendo essa de baixo valor (1.30%). Já a classe “Sombra” apresentou uma pequena confusão (1.12%) com a classe “Solo1”.

Com esses resultados, percebe-se que a maior confusão se dá com a classe “Urbano”, devido à grande variação de alvos que podem ser encontrados em um pixel da imagem neste alvo, uma vez que, em imagens da série Landsat a resolução espacial é de 30 m. Assim, em um pixel que supostamente refere-se a áreas urbanas podem haver outros alvos, tais como, tipos de solos expostos, vegetação, além de uma grande quantidade de materiais com uma constituição diferente no meio urbano. Chagas et al. (2009) unem as classes referentes a áreas urbanas e solo exposto, para evitar esse tipo de confusão, no trabalho destes autores as maiores confusões não foram referentes a essa classe, apesar de mesmo assim apresentar uma certa confusão com outras classes.

A detecção de mudanças digitais em ambientes urbanos é um desafio devido aos seguintes fatores: as mudanças no uso / cobertura da terra urbana geralmente representam uma pequena proporção da área de estudo e estão dispersas em diferentes locais; eles são frequentemente confundidos com outras mudanças devido à complexidade de superfícies impermeáveis e características espectrais semelhantes entre superfícies impermeáveis e outras coberturas de terra não vegetativa; um grande número de pixels mistos geralmente resultam em uma fraca precisão da classificação devido à natureza heterogênea dos ambientes urbanos e à limitação da resolução espacial na imagem remota (LU et al., 2011).

Já em relação à matriz de confusão referente a classificação da imagem do satélite Landsat 8, pode ser observado um melhor resultado, conforme apresenta a Tabela 2. No geral, houve pequenas confusões entre as classes, sendo a maior confusão observada na classe de “Solo 2”, na qual apresentou cerca de 3,41% de confusão com a classe “Urbano” e 0.5% com a “Vegetação Agrícola”, porém apresentou uma boa porcentagem de acerto, cerca de 96.54% dos pixels foram classificados de forma correta. Além dos melhores acertos com base matriz de confusão a classificação gerada para essa imagem apresentou um valor de Exatidão Global de 98,86% e um índice Kappa de 0.9853, o que representa uma excelente classificação conforme Landis e Koch (1977).

**TABELA 2:** Matriz de confusão do algoritmo MaxVer para a imagem do Landsat 8, e valores de Acurácia do Produtor e Usuário.

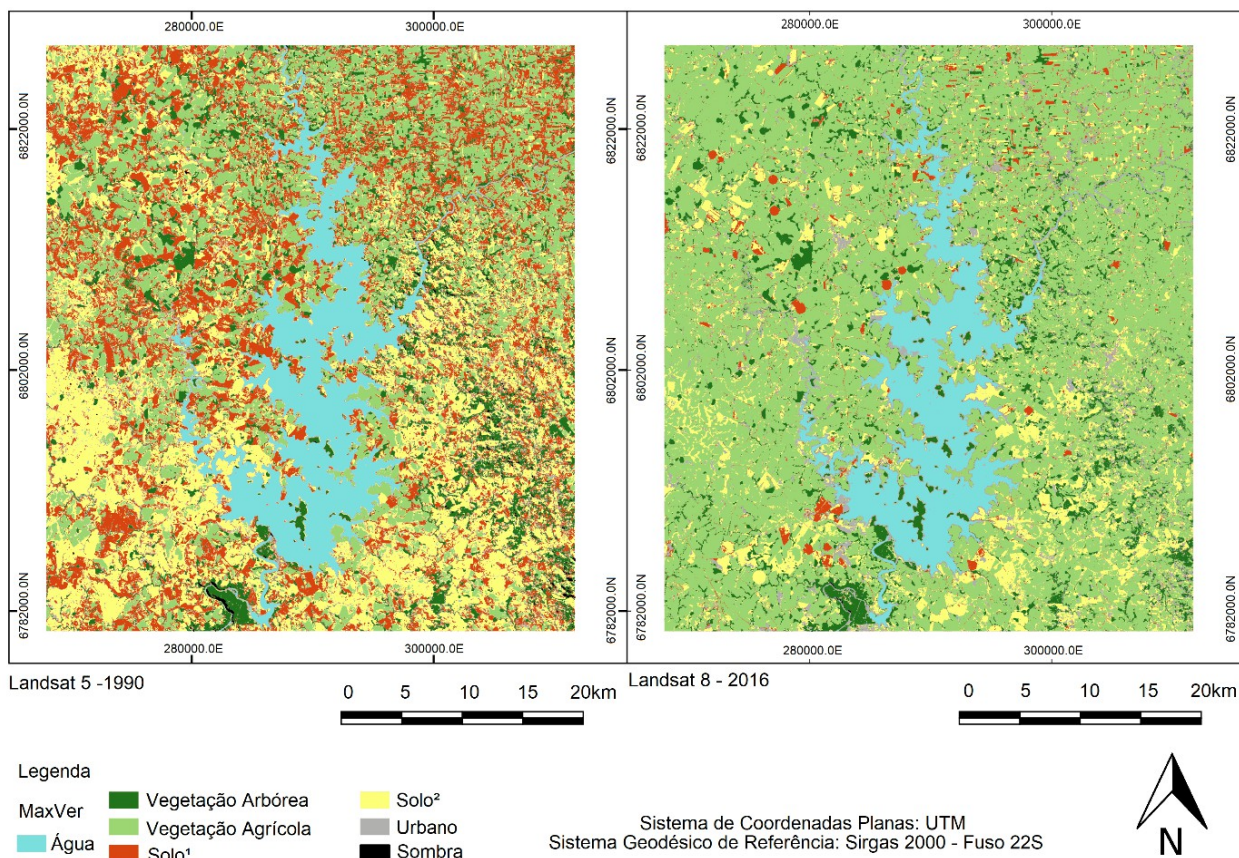
<b>Classes</b>	Água	Veg. F	Urbano	Veg. A	Solo 1	Solo 2	Sombra
Água	99,87	0	0	0	0	0	0
Veg. FI	0	99,91	0	0	0	0	0
Urbano	0,13	0,09	100	0,07	0,11	3,41	0
Veg. A	0	0	0	98,22	0	0,05	0
Solo 1	0	0	0	0,07	99,79	0	0
Solo 2	0	0	0	1,63	0,11	96,54	0
Sombra	0	0	0	0	0	0	100
<b>Total</b>	100	100	100	100	100	100	100

FONTE: Os Autores.

Percebe-se que a imagem do Landsat 8 apresentou um melhor resultado de forma geral, fato esse que pode estar atrelado a melhor resolução radiométrica do sensor OLI, o qual possui 16 *bits*, ou seja, possui uma melhor capacidade de detectar pequenos sinais de mudanças.

### Análise Temporal

A análise temporal gerada via classificação de imagens permitiu observar espacialmente as mudanças ocorridas na área de estudo (Figura 1). É possível visualizar contrastantes mudanças na paisagem no período de 26 anos, principalmente a incorporação para as áreas de vegetação agrícola, que predominam na imagem do satélite Landsat-8 (2016).

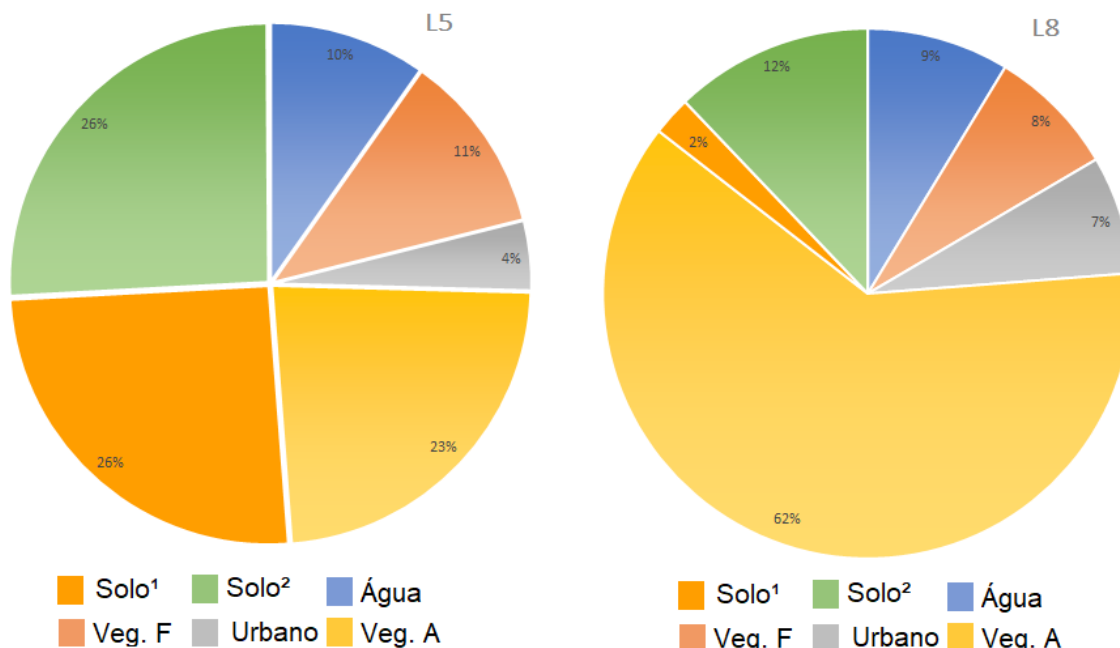


**FIGURA 1:** Uso e cobertura da terra no entorno da represa do Passo Real – RS, por meio de classificação supervisionada, utilizando o algoritmo da Máxima Verossimilhança.

FONTE: Os Autores.

Em seguida é apresentada a Figura 2 que ilustra a distribuição das áreas em (%) do uso e cobertura da terra no período avaliado. De modo a simplificar a interpretação dos resultados, os valores de hectares das classes “Vegetação Agrícola” “Solo 1 e Solo 2” foram somadas, uma vez que estas classes geralmente representam áreas de

agricultura, e apresentam-se diferentes em função do período de avaliação, e dos tratos empregados de preparado de solo e colheita.



**FIGURA 2:** Distribuição espacial em (%) do uso e cobertura da terra nos anos avaliados (1990-2016).

FONTE: Os Autores.

A área de estudo, ou seja, o entorno da represa do Passo Real apresenta um total de 212,561.53 ha, tendo como predomínio as áreas de agricultura (“Vegetação Agrícola” “Solo 1 e Solo 2”), como pode ser visualizado na Figura 2. Para a imagem de 2016, cerca de 76% refere-se a áreas de agricultura, em seguida as áreas de água, que apresentam a segunda maior cobertura da imagem, cerca de 9%, e as áreas de “Vegetação Arbórea” e “Urbano”, 8% e 7%, respectivamente.


Como pode ser observado na Figura 2, as maiores mudanças no período avaliado se dão nas classes “Vegetação Agrícola” “Solo 1 e Solo 2”, porém, como mencionado anteriormente, ao serem somadas essas classes encontrou-se um valor positivo de 3713.22 ha, ou seja, um aumento de 1.74% de áreas agrícolas em relação a área total analisada. Outra classe que teve um saldo positivo de mudanças foi a classe “Urbano”, que apresentou um aumento de áreas classificadas de 6120.63 ha, representando assim, uma expansão das áreas urbanas de 2.17%.

Em contraposto as classes de “Água” e “Vegetação Arbórea” apresentaram um saldo negativo, tendo uma diminuição das suas áreas. A classe “Água” apresentou um decréscimo de 2351.07 ha, o que representa em termos totais 1.10%. Já as áreas de Vegetação Arbórea, apresentaram um decréscimo de 7284.33 ha, representando cerca de 3.42% de perdas destas áreas no período avaliado. Uma justificativa para essa causa pode ser em relação à característica da região, que mostra o predomínio pela

atividade agrícola, o que é afirmado pelo Plano de uso e ocupação do solo no entorno do Reservatório Passo Real (CEEE-GT, 2011) onde a maior parte da área do entorno do reservatório está ocupada por cultivos agrícolas. A pecuária também é desenvolvida na área de captação do reservatório.

Para a classe sombra foi observada uma redução de 198.45 ha, esse valor apesar de baixo deve ser levado em consideração, pois representa classes que não puderam ser observadas em função do sombreamento. Na análise temporal desta classe, percebeu-se que, as maiores mudanças desta classe foram com as classes “Vegetação Arbórea” e “Urbano”, sendo os valores: 80.37 ha e 102.51 ha, respectivamente.

Por fim, foram verificadas as áreas que não apresentaram mudança no intervalo de 26 anos no entorno do reservatório do Passo Real – RS (Figura 3). Como já era esperada a classe que menos apresentou mudança nesse meio de tempo foi a classe “Água”, cerca de 88% desta classe não apresentou mudanças, ou seja, essa porcentagem representa a mesma área classificada em ambas imagens. Em seguida a classe “Vegetação Agrícola” com cerca de 83% das áreas sem mudanças, destaca-se que esta classe apresentou as maiores incorporações de áreas de outras classes. A partir desta análise de mudanças, foi possível identificar em quais classes houve essas incorporações, e assim, observou-se que estas foram advindas em grande escala por parte das classes “Vegetação Arbórea”, “Solo 2” e “Solo 2”, os valores em hectares foram respectivamente: 9124.65 ha; 38279.61 ha e 38402.1 ha, sendo estes incorporados para a classe “Vegetação Agrícola”.



**FIGURA 3:** Porcentagem das áreas que não apresentaram mudanças no período de 26 anos.

FONTE: Os Autores.

Chama-se atenção para a classe “Vegetação Arbórea” que apresentou cerca de 55% das suas áreas de mudanças, perdendo espaço principalmente para as áreas de agricultura, ou seja, para a classe “Vegetação Agrícola” foram computadas cerca de 38% de mudanças, o que representa 9124,65 ha. As classes de “Solo 1” e “Solo 2” apresentaram cerca de 70% de migração de áreas para a classe “Vegetação Agrícola”. Em relação as áreas de sombra, cerca de 7% não apresentou mudanças no período avaliado, sendo os maiores valores de mudanças encontrados para as classes Urbano e Vegetação Arbórea, cerca de 48% (102,51 ha) e 37% (80,37 ha), respectivamente.

O uso e cobertura da terra de forma indiscriminada podem causar graves modificações para o ambiente. Conforme exposto, as ferramentas utilizadas nesse estudo mostram que é possível detectar essas modificações e assim, de posse destas informações torna-se possível realizar medidas para proteger áreas naturais e até mesmo o restabelecimento dessas áreas que foram suprimidas para outros usos.

A área de estudo desta pesquisa é um exemplo dessa forma indiscriminada do espaço territorial, uma vez que no período de 26 anos houveram transições acentuadas da cobertura florestal para outros usos, refletindo um cenário desmatamento da vegetação nativa. As maiores parcelas dessas mudanças são para áreas agrícolas o que requer uma maior atenção do avanço dessa atividade quanto a compatibilidade legal da mesma.

Além disso, é importante levantar qual a natureza dessa atividade agrícola, uma vez que, pesquisas mostram que o tipo de cultivo agrícola interfere na maior susceptibilidade para escoamento superficial e carregamento de sedimentos para cursos d’águas, que é responsável em assoreamentos das hidrografias (MAEDA et al., 2008). Essa informação tem extrema importância em específico para o presente estudo por se tratar de um lago de barragem hidrelétrica. Sendo que é de conhecimento que maiores volumes de sedimentos para esse local impactam, não só o meio ambiente devido à perda de estrutura e nutrientes do solo, mas também nos custos de durabilidade e manutenção de barragens, o que compromete a viabilidade futura desta (MIRANDA et al., 2013).

## **CONCLUSÕES**

Para o período de tempo de 26 anos, a análise temporal conforme a classificação pelo algoritmo MaxVer, mostrou que a dinâmica do uso e cobertura da terra do entorno da represa do Passo Real apresentou relevantes mudanças. As maiores transições de áreas ocorreram da classe de vegetação para a classe de vegetação agrícola

A dinâmica ocorrida entre os anos 1990 e 2016 revela que as áreas naturais são principalmente as que mais sofrem com os processos de modificação do ambiente, e que a partir de uma análise temporal é possível compreender com melhor exatidão os processos de mudanças do espaço no tempo.

A utilização de técnicas e métodos computacionais para a classificação do uso da terra mostra-se uma ferramenta de grande importância para dimensionar e entender a dinâmica temporal, de forma rápida e precisa de extensas áreas impactadas por reservatórios das usinas hidrelétricas.

## REFERÊNCIAS

ADAM, E., MUTANGA, O., ODINDI, J., ABDEL-RAHMAN, E. M. Land-use/cover classification in a heterogeneous coastal landscape using RapidEye imagery: evaluating the performance of random forest and support vector machines classifiers. **International Journal of Remote Sensing**, v. 35, n. 10, p. 3440-3458, 2014. doi: 10.1080/01431161.2014.903435.

ANEEL. **Banco de informações de geração**. Disponível em: <<http://www2.aneel.gov.br/aplicacoes/capacidadebrasil/OperacaoCapacidadeBrasil.cfm>>. Acessado em 26 de set 2017

CHAGAS, C. S., VIEIRA, C. A., FERNANDES FILHO, E. I., JÚNIOR, C. (2009). Use of artificial neural networks in the classification of degradation levels of pastures. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 13, n. 3, p. 319-327, 2009. <http://dx.doi.org/10.1590/S1415-43662009000300014>

CEEE-GT – Companhia Estadual de Geração e Transmissão de Energia Elétrica. **Plano de uso e ocupação do solo no entorno do Reservatório da UHE Passo Real**. Porto Alegre: PROFFIL, 2011.

GOLDBLATT, R., STUHLMACHER, M. F., TELLMAN, B., CLINTON, N., HANSON, G., GEORGESCU, M., BALLING, R. C. Using Landsat and nighttime lights for supervised pixel-based image classification of urban land cover. **Remote Sensing of Environment**, v. 205, p. 253-275, 2018. <https://doi.org/10.1016/j.rse.2017.11.026>

GOUVEIA, R. G. L.; GAVANIN, E. A. S.; NEVES, S. M. A. S. Aplicação do índice de transformação antrópica na análise multitemporal da bacia do córrego do bezerro vermelho em Tangará da Serra-MT. **Revista Árvore**, v. 37, n. 6, 2013 <https://doi.org/10.1590/s0100-67622013000600006>

KUEMMERLE, T., ERB, K., MEYFROIDT, P., MÜLLER, D., VERBURG, P. H., ESTEL, S., LEVERS, C. Challenges and opportunities in mapping land use intensity globally. **Current Opinion in environmental sustainability**, v. 5, n. 5, p. 484-493, 2013. <https://doi.org/10.1016/j.cosust.2013.06.002>

LANDIS, J.; KOCH, G. G. The measurements of agreement for categorical data. **Biometrics**, v.33, n.3, p.159-179, 1977.

LI, D., TANG, C., XIA, C., ZHANG, H. Acoustic mapping and classification of benthic habitat using unsupervised learning in artificial reef water. **Estuarine, Coastal and Shelf Science**, v. 185, p. 11-21, 2017. <https://doi.org/10.1016/j.ecss.2016.12.001>

LESSA, A.C.R.; SANTOS, M.A. dos; MADDOCK, J.E.L.; BEZERRA, C. dos S. Emissions of greenhouse gases in terrestrial areas pre-existing to hydroelectric plant reservoirs in the Amazon: The case of Belo Monte hydroelectric plant. **Renewable and**

**Sustainable Energy Reviews**, v. 51, p. 1728-1736, 2015.  
<https://doi.org/10.1016/j.rser.2015.07.067>

LU, D., LI, G., MORAN, E., KUANG, W. A comparative analysis of approaches for successional vegetation classification in the Brazilian Amazon. **Giscience & Remote Sensing**, v. 51, n. 6, p. 695-709, 2014. doi: 10.1080/15481603.2014.983338

LU, D.; MORAN, E.; HETRICK, S. Detection of impervious surface change with multitemporal Landsat images in an urban-rural frontier. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 66, n. 3, p. 298-306, 2011.  
<https://doi.org/10.1016/j.isprsjprs.2010.10.010>

MAEDA, E. E.; FORMAGGIO, A. R.; SHIMABUKURO, Y. E. Historical changes of the Amazonian Forest into agricultural lands in the Suia-Miçu River Basin. **Sociedade & Natureza**, v. 20, n. 1, p. 5-24, 2008. <http://dx.doi.org/10.1590/S1982-45132008000100001>

MARTINS, A. P. M.; GAIAD, N. P.; DEBASTIANI, A. B.; DALLA CORTE, A. P.; SANQUETTA, C. R. Desempenho de classificadores supervisionados para a dinâmica da área de inundação da UHE Teles Pires. **Enciclopédia Biosfera**, v. 14, p. 372-381, 2017.

MENESES, P.R.; ALMEIDA, T.; **Introdução ao processamento de imagens de sensoriamento remoto**. Unb, Brasília, 2012, 266p.

MIRANDA, R. B.; SCARPINELLA, G. D.; MAUAD, F. F. Influência do Assoreamento na Capacidade de Armazenamento do Reservatório da Usina Hidrelétrica de três Irmãos (SP/BRASIL). **Recursos Hídricos**, v. 34, n. 2, 2013. <https://doi.org/10.5894/rh34n2-6>

MOREIRA, M. A. **Fundamentos de Sensoriamento Remoto e Metodologias de Aplicação**. 1.ed. São José dos Campos: INPE, 2001. 250 p.

NEVES, C. E.; SILVA, G. M. F. Dinâmica da paisagem em 10 municípios do cerrado piauiense entre 1991, 2001 e 2010 através de técnicas de geoprocessamento. **Revista Geonorte**, v. 5, n.17, p. 41-46, 2016

NIKNEJAD, M., MIRZAEI ZADEH, V., HEYDARI, M. Comparing different classifications of satellite imagery in forest mapping (Case study: Zagros forests in Iran). **International Research Journal of Applied and Basic Sciences**, v. 8, n. 7, p. 1407-1415, 2014.

NOVO, E. M. L. M. **Sensoriamento remoto: Princípios e aplicações**. São Paulo, SP: Edgard Blücher, 2011. 388 p.

PONZONI, F. J.; REZENDE, A. C. P. Influência da resolução espacial de imagens orbitais na identificação de elementos da paisagem em Altamira-PA. **Revista Árvore**, Viçosa, v. 26, n. 4, p.403-410, 2002.

RÊGO, J. C. L.; SOARES-GOMES, A.; DA SILVA, F. S. Loss of vegetation cover in a tropical island of the Amazon coastal zone (Maranhão Island, Brazil). **Land Use Policy**, v. 71, p. 593-601, 2018. <https://doi.org/10.1016/j.landusepol.2017.10.055>

SANTOS, F. A.; AQUINO, C. M. S. Análise da dinâmica do Índice de Vegetação por Diferença Normalizada (NDVI), dos aspectos econômicos e suas relações com a desertificação/degradação ambiental em Castelo do Piauí, Piauí, Brasil. **Revista Eletrônica de Investigação e Desenvolvimento**, n. 4, 2015.

SILVA, A. M., CANUTO, D. S. O., ALVES, M. C., BUZETTI, S., MORAES, M. L. T., SAKAMOTO, A. Y. Características Químicas de um latossolo Vermelho em Recuperação sob plantio de Pinus spp. **Ciência Florestal**, v. 26, n. 4, 2016.

SILVA, A. R., PIMENTA, F. M., ASSIREU, A. T., SPYRIDES, M. H. C. Complementarity of Brazil's hydro and offshore wind power. **Renewable and Sustainable Energy Reviews**, v. 56, p. 413-427, 2016. <https://doi.org/10.1016/j.rser.2015.11.045>

SOTHE, C.; SCHIMALSKI, M.B.; LIESENBERG, V.; DE ALMEIDA, C.M. Approaches for classifying successional forest stages in São Joaquim National Park using Landsat-8 and RapidEye images. **Boletim de Ciências Geodésicas**, v. 23, n. 3, p. 389-404, 2017 <http://dx.doi.org/10.1590/s1982-21702017000300026>

ZAKS, DAVID P.M; KUCHARIK, CHRISTOPHER J. Data and monitoring needs for a more ecological agriculture. **Environmental Research Letters**, v. 6, n. 1, p. 014017, 2011. <https://doi.org/10.1088/1748-9326/6/1/014017>