



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA, INOVAÇÕES E COMUNICAÇÕES  
**INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS**

**APLICAÇÃO DE AUTOCORRELAÇÃO ESPACIAL EM SÉRIES  
TEMPORAIS DE IMAGENS DE SATÉLITE PARA ANÁLISE DA  
DINÂMICA DAS ÁREAS ÚMIDAS EM UM TRECHO DA  
PLANÍCIE DO RIO DOS SINOS**

Thiago Bazzan

Artigo para a disciplina de Análise Espacial de Dados Geográficos Introdução ao Sensoriamento Remoto (SER-301) no Curso de Pós-graduação em Sensoriamento Remoto. Docentes responsáveis: Dr. Antônio Miguel Vieira Monteiro e Dr. Eduardo G. Camargo.

# APLICAÇÃO DE AUTOCORRELAÇÃO ESPACIAL EM SÉRIES TEMPORAIS DE IMAGENS DE SATÉLITE PARA ANÁLISE DA DINÂMICA DAS ÁREAS ÚMIDAS EM UM TRECHO DA PLANÍCIE DO RIO DOS SINOS

Thiago Bazzan<sup>1</sup>

<sup>1</sup>Instituto Nacional de Pesquisas Espaciais – INPE, Caixa Postal 515 - 12227-010 - São José dos Campos - SP, Brasil

[thiago.bazzan@inpe.br](mailto:thiago.bazzan@inpe.br)

**Resumo:** As áreas úmidas apresentam grande biodiversidade, assim os estudos ambientais nestas áreas são importantes para compreender a sua dinâmica ecológica e hidrológica. Este estudo tem por objetivo aplicar índices globais de autocorrelação espacial em imagens de satélite e comparar seu desempenho para atuarem como preditores das métricas da paisagem e medidas hidrológicas. A área de estudo corresponde a um trecho da planície do rio dos Sinos com áreas úmidas com alto grau de urbanização e atividades agrícolas. Os procedimentos metodológicos envolveram a aquisição e a classificação das imagens de satélite em classes temáticas de água e não-água com o *Modified Normalized Difference Water Index* (MNDWI), foram realizadas análises exploratórias e estatísticas para avaliar as variáveis e regressões lineares para quantificar as relações entre as variáveis e gerar estimativas. Os resultados evidenciaram que os índices globais de autocorrelação espacial (Índice Global de Moran e Indicador de Geary) apresentaram melhor desempenho para atuarem como preditores para a estimativa da cota do rio. Assim, é possível concluir a partir do estudo que a autocorrelação espacial pode caracterizar e explicar a dinâmica do aumento e redução do nível das águas, podendo ser utilizado para análises comparativas e no preenchimento de falhas em séries históricas de dados hidrológicos.

Palavras-chave: áreas úmidas, autocorrelação espacial, métricas da paisagem, hidrologia.

**Abstract:** Wetlands have great biodiversity, so environmental studies in these areas are important to understand their ecological and hydrological dynamics. This study aims to apply global spatial autocorrelation indices to satellite images and compare their performance to act as predictors of landscape metrics and hydrological measurements. The study area corresponds to a stretch of the Sinos River plain with wetlands with a high degree of urbanization and agricultural activities. The methodological procedures involved the acquisition and classification of satellite images in water and non-water thematic classes with the Modified Normalized Difference Water Index (MNDWI). Exploratory and statistical analyses were performed to evaluate the variables and linear regressions to quantify relationships between variables and generate estimates. The results showed that the global indexes of spatial autocorrelation (Moran Global Index and Geary Indicator) presented better performance to act as predictors for the river quota estimation. Thus, it is possible to conclude from the study that spatial autocorrelation can characterize and explain the dynamics of up and down water levels, and can be used for comparative analysis and in filling faults in historical series of hydrological data.

Keywords: wetlands, spatial autocorrelation, landscape metrics, hydrology.

## 1. INTRODUÇÃO

As inundações são processos hidrológicos que fazem parte da dinâmica fluvial (NEIFF, 1999), no entanto, a ocupação e uso do solo e conseqüentemente a alteração da cobertura vegetal em áreas próximas aos cursos da água podem provocar impactos e modificar o regime das cheias (TUCCI, 2005), além de provocar danos socioeconômicos (KOBAYAMA, 2006). Assim, o conhecimento sobre a dinâmica hidrológica das áreas inundáveis é primordial para auxiliar na tomada de decisão para o gerenciamento dos ecossistemas fluviais associados à áreas úmidas.

De acordo com Marconato (2014), uma planície de inundação pode ser definida como uma faixa de terreno adjacente a um canal fluvial principal, com relevo topograficamente pouco expressivo, formada por sedimento transportado pelo rio ao qual está relacionada, ou por processos autóctones (como formação de solos ou de depósitos gerados por atividade biológica), e que é inundado durante enchentes sazonais, seja pelo fluxo de água oriundo do canal principal, de chuva intensa, fluxo superficial vindo dos flancos do vale aluvial, ou uma combinação destes.

As Áreas Úmidas (AUs) são ecossistemas na interface entre ambientes terrestres e aquáticos, continentais ou costeiros, naturais ou artificiais, permanentemente ou periodicamente inundados por águas rasas ou com solos encharcados, doces, salobras ou salgadas, com comunidades de plantas e animais adaptadas à sua dinâmica hídrica (INAU, 2014). Quando estas áreas são preservadas fornecem muitos benefícios aos sistemas humano e ambiental, como redução do número e a severidade das inundações, auxílio no escoamento de águas pluviais, minimizar a poluição da água, entre outros.

As imagens de sensoriamento remoto são uma importante ferramenta para o mapeamento de corpos hídricos e de áreas úmidas. Classificações rápidas de alvos específicos podem ser realizadas com aplicação de índices por diferença normalizada. Dentre eles, destacam-se o *Normalized Difference Water Index* (NDWI) elaborado por McFeeters (1996) e o *Modified Normalized Difference Water Index* (MNDWI) proposto por Xu (2006) para a identificação, delimitação de feições associadas a água. Singh et al. (2014) sugerem que o MNDWI apresenta melhor desempenho para delinear as características da água misturadas com a vegetação em comparação com o NDWI.

Além disso, no mapeamento dos corpos hídricos, a aplicação de métricas da paisagem para o estudo de áreas úmidas é importante, pois auxilia na caracterização do tamanho, forma, densidade, frequência e alterações que ocorrem nestas áreas. De acordo com Carrão et al.

(2001), a quantificação das relações entre as alterações da estrutura da paisagem e diferentes processos ecológicos são uma fonte de informação que providencia um completo conhecimento da dinâmica da paisagem.

Estudos sobre o uso e autocorrelação espacial em áreas inundáveis ainda são incipientes. Li et al. (2019) aplicaram a autocorrelação espacial (Índice Global de Moran) e métricas da paisagem para investigar a retração e expansão das águas no reservatório Guanting na China. Conforme Li et al. (2019) a metodologia poderia ser aplicada na avaliação de áreas úmidas naturais onde o padrão de dinâmica das águas superficiais são mais complexos e diversificados em contraposição aos reservatórios que apresentam padrão de água superficial mais simples. Uemaa et al. (2008) afirmam que a autocorrelação espacial é menor em paisagens com estrutura complexa e alto contraste.

Dada a maior complexidade e alto contraste que caracterizam as áreas úmidas, pode-se propor duas hipóteses. A primeira hipótese que se propõe é: a autocorrelação espacial pode explicar e estimar a configuração ou padrões espaciais quantificadas pelas métricas da paisagem a partir de dados derivados de imagens de satélites? A segunda hipótese que se propõe é: a cota do rio obtida por réguas limnimétricas pode ser explicada e estimada pela autocorrelação espacial e por métricas da paisagem em imagens de satélite? A partir das hipóteses propostas, o objetivo deste estudo é avaliar se índices globais de autocorrelação espacial podem explicar a dinâmica dos padrões das áreas úmidas na planície do Rio dos Sinos entre 1984 e 2019 comparando seu desempenho com as métricas da paisagem e medidas hidrológicas.

A escolha do tema e da área de estudo justifica-se pela relevância ecológica das áreas úmidas e pela intensa ocupação em decorrência da expansão da urbanização e das áreas agrícolas sobre a planície do rio dos Sinos. Estudos realizados por Maltchick (2003) e Bertoluci (2004) destacam a importância da conservação dessas áreas úmidas devido à alta biodiversidade que envolve comunidades de algas e macroinvertebrados. Além disso, as áreas úmidas exercem um importante papel no controle das inundações conforme estudos realizados por (RISSO e GIUGNO, 1994; SALDANHA et al., 1996; PENTEADO, 2006; OLIVEIRA et al., 2009; BAZZAN, 2011; BRUBACHER e GUASSELLI, 2013).

Em relação à área de estudo, a sua localização, posicionada na planície do Rio dos Sinos, constituindo uma extensa área plana, permite a expansão da lâmina de água em períodos de intensa precipitação e a retração da lâmina da água em períodos de estiagem. Desta forma, a avaliação multitemporal de imagens de satélite com autocorrelação espacial na área de estudo possibilita a análise do comportamento e padrões espaciais da água superficial nos diferentes anos permitindo correlaciona-los com as métricas da paisagem e cota fluviométrica.

## 1.1. Área de estudo

A área de estudo corresponde a um trecho da planície e inundações do Rio dos Sinos localizada entre os municípios de Campo Bom, Novo Hamburgo e São Leopoldo, na Região Metropolitana de Porto Alegre (RMPA), no estado do Rio Grande do Sul. Situa-se no baixo curso do Rio dos Sinos, aproximadamente, entre as coordenadas 29°40'30"S e 29°46'40"S de latitude e 51°00'00"W e 51°10'50"W de longitude (Figura 1), abrangendo 205 km<sup>2</sup> de extensão. As áreas urbanas dos municípios estão localizadas à norte e sul do Rio dos Sinos.

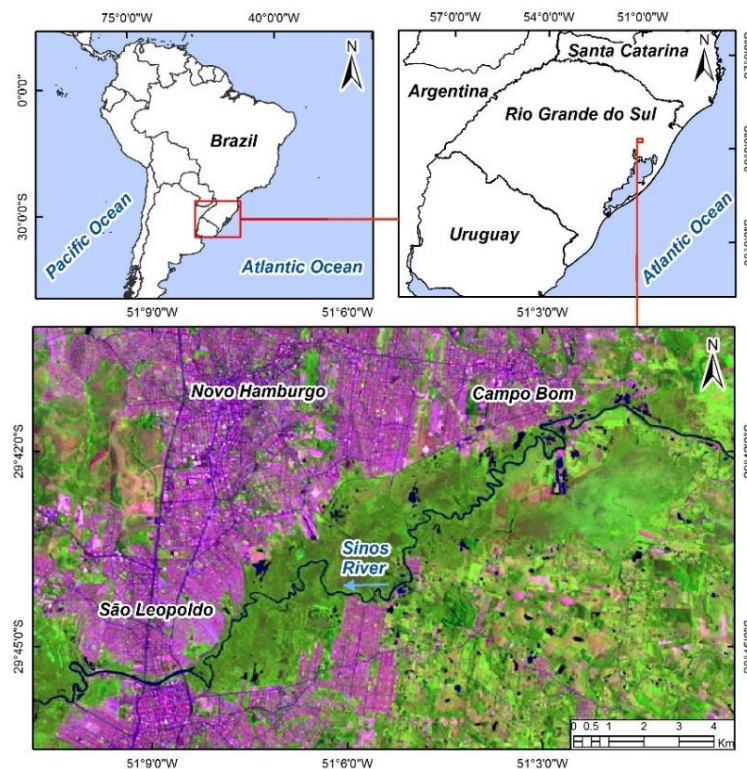


Figura 1 – Mapa de localização de um trecho da planície do Rio dos Sinos na RMPA.

O Rio dos Sinos integra a Bacia Hidrográfica do Guaíba (SEMA, 2002) constituindo-se, juntamente com os Rios Jacuí, Caí e Gravataí, nos principais cursos da água que formam o Delta do Jacuí.

## 2. MATERIAIS E MÉTODOS

Os procedimentos metodológicos foram desenvolvidos nas seguintes etapas: aquisição das imagens de satélite e formação da série temporal; classificação das imagens em duas classes temáticas: água e não água; aplicação de métricas da paisagem nas imagens classificadas; aplicação de indicadores globais de autocorrelação espacial com Índice Global de Moran (I) e Indicador de Geary (C) nas imagens classificadas, levantamento de dados hidrológicos (cota do fluviométrica); análises estatísticas e aplicação da regressão linear.

## 2.1. Série Temporal das Imagens do Satélite Landsat

Para a composição da série temporal no período entre 1984 e 2019 (36 anos) foram utilizadas imagens do sensor TM (*Thematic Mapper*) do satélite Landsat-5 entre 1984 e 2011 e do sensor OLI (*Operational Land Imager*) do satélite Landsat-8 entre 2013 e 2019 referentes a órbita 221 e órbita 81 com resolução espacial de 30 metros (Figura 2). As imagens Landsat-5/TM e Landsat-8/OLI foram adquiridas em formato *.TIFF* na plataforma *on-line EarthExplorer* do *United States Geological Survey* (USGS). Nas imagens disponibilizadas foram selecionadas aquelas com maior presença de água superficial aparente, com exceção do ano de 2012, no qual as imagens do Landsat-7 apresentaram falha de imageamento na área de estudo e as imagens do Landsat-5, de acordo com Embrapa (2013) não estão disponibilizadas devido ao término da operação do satélite. Ainda de acordo com Embrapa (2013) o satélite Landsat-8 foi lançado e tornou-se operacional no ano de 2013.

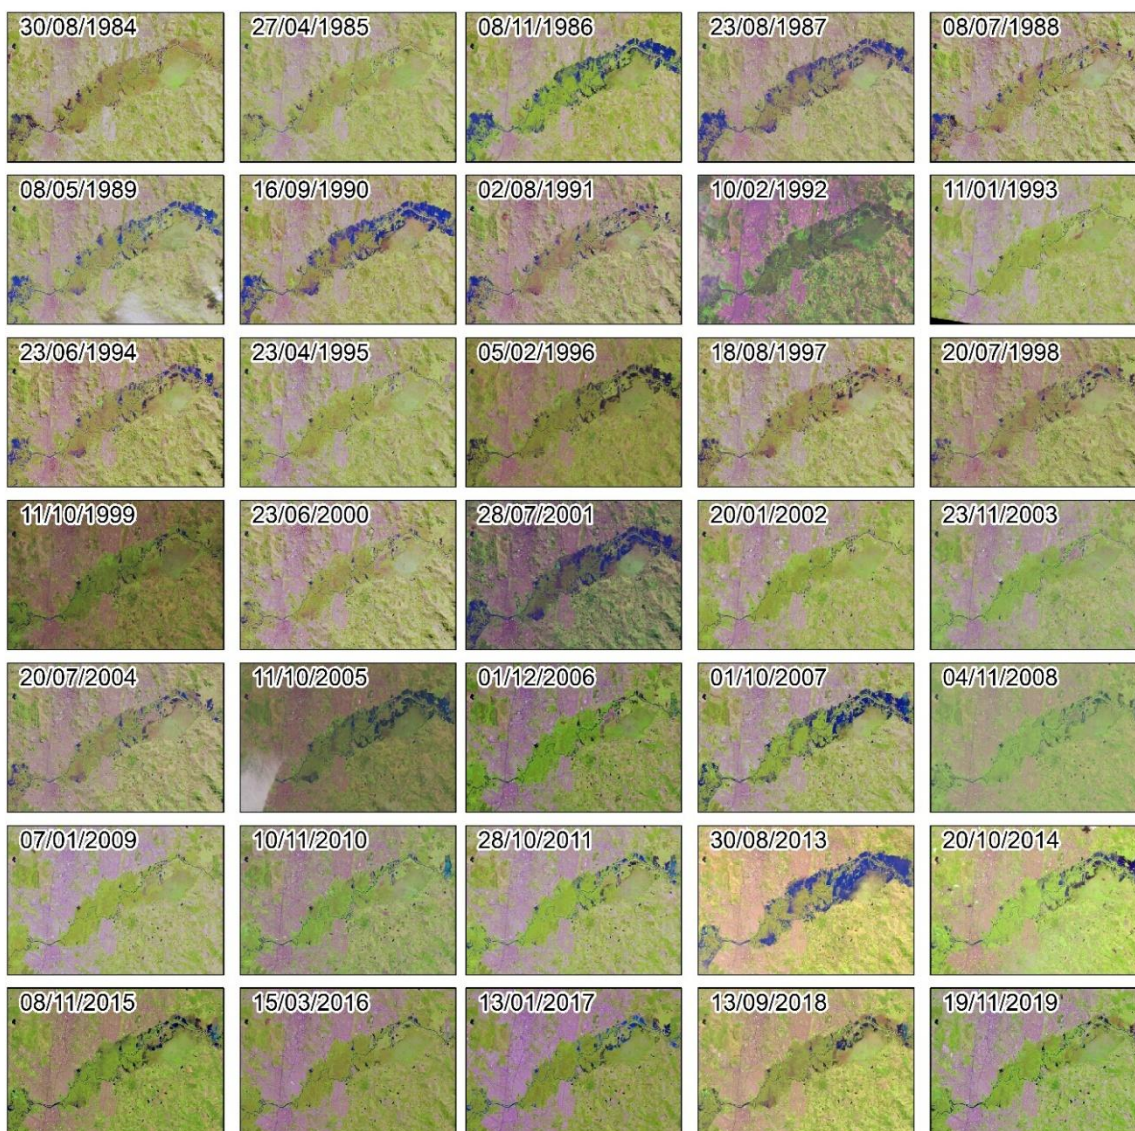


Figura 2 – Série temporal com as imagens dos sensores TM e OLI no período entre 1984 e 2019.

## 2.2. Modified Normalized Difference Water Index (MNDWI)

Para realçar e classificar a presença de água superficial nas imagens de satélite foi utilizado o *Modified Normalized Difference Water Index* (MNDWI) proposto por Xu (2006). O cálculo é realizado por meio da aplicação da equação 1 (Eq.1).

$$MNDWI = (\rho_{GREEN} - \rho_{SWIR}) / (\rho_{GREEN} + \rho_{SWIR}) \quad (Eq.1)$$

onde,  $\rho_{GREEN}$  é a reflectância da banda verde (banda 2 do sensor TM e banda 3 do sensor OLI) e  $\rho_{SWIR}$  a reflectância da banda infravermelho de ondas curtas (banda 5 do sensor TM e banda 6 do sensor OLI).

A aplicação da equação nas imagens de satélite gera uma nova imagem com valores entre -1 e 1, onde o intervalo de -1 a 0 corresponde a feições não-água e valor maior que 0 corresponde a feições água. De acordo com Xu (2006), o MNDWI suprime de forma eficiente o ruído gerado pela área construída, vegetação e solo, melhorando a extração da água, especialmente nas bordas dos cursos de água presentes na imagem de satélite.

A partir da limiarização a imagem MNDWI com valores reais contínuos foi classificada para uma imagem com valores inteiros positivos com duas classes: não água (1) e água (2), onde a classe não água corresponde ao intervalo -1 até 0 e a classe água corresponde a valores acima de 0 do MNDWI.

## 2.3. Métricas da paisagem

As métricas da paisagem foram extraídas das imagens classificadas do MNDWI. Para a extração de métricas da paisagem foi utilizado o *plugin LecoS (Landscape ecology Statistics)* elaborado por Jung (2016) e disponível no *software QGIS*. O LecoS, de acordo com Jung (2016), faz uso das bibliotecas científicas de python, SciPy e Numpy para calcular métricas básicas e avançadas da paisagem e fornece várias funções para realizar a análise da paisagem. O LecoS tem ferramentas equivalentes ao FRAGSTATS desenvolvido por McGarigal (2015).

Para Uuemaa et al. (2008) quantificar a estrutura da paisagem é importante para entender como a estrutura da paisagem afeta os processos ecológicos. Assim, considerando as características e a dinâmica das áreas úmidas da planície de inundação do Rio dos Sinos, a classe de mapeamento água foi caracterizada pelas seguintes métricas da paisagem: *landscape proportion*, *edge length*, *landscape division* e *number of patches* (Tabela 1). As métricas da paisagem foram utilizadas em duas situações: como variáveis dependentes para serem estimadas pelos índices globais de autocorrelação espacial (variáveis independentes) e como variáveis independentes para estimar e explicar a cota do rio (variável dependente).

Tabela 1 – Métricas da paisagem consideradas no estudo

<b>Métrica</b>	<b>Descrição</b>	<b>Unidades</b>	<b>Alcance</b>
<i>Landscape proportion</i>	Abundância proporcional de fragmentos de água	%	0 a 1
<i>Edge length</i>	Comprimentos total da borda dos fragmentos de água	m	$\geq 0$
<i>Landscape division</i>	Probabilidade de que dois pixels escolhidos aleatoriamente na paisagem não estejam situados no mesmo fragmento	Proporção	0 a 1
<i>Number of patches</i>	Número de fragmentos de água	Nenhuma	$\geq 0$

## 2.4. Medida hidrológica

A medida hidrológica utilizada no estudo foi a cota fluviométrica. A caracterização da elevação do nível da água do Rio dos Sinos foi realizada a partir das cotas do rio medidas pela estação fluviométrica São Leopoldo (87382000) e disponibilizadas pela ANA (2019) na plataforma *on-line* Hidroweb. A Tabela 2 apresenta o detalhamento da medida hidrológica utilizada no estudo.

Tabela 2 – Medida hidrológica considerada no estudo

<b>Medida</b>	<b>Descrição</b>	<b>Unidade</b>	<b>Alcance</b>
Cota do rio	Elevação da água do rio em relação a uma referência <sup>1</sup>	cm	$\geq 0$

No estudo, a cota do rio foi considerada como a variável dependente das variáveis explicativas associadas a métrica da paisagem e indicadores globais de autocorrelação espacial com o objetivo de verificar o desempenho e o potencial destas variáveis independentes para explicar a dinâmica de aumento e redução do nível da água do rio.

## 2.5. Autocorrelação Espacial

No estudo foram utilizados dois índices globais de autocorrelação espacial como variáveis independentes: Índice Global de Moran (I) e Indicador de Geary (C) para explicar as métricas da paisagem e cota do rio.

O Indicador de Geary (C) proposto por Geary (1954) é um importante índice global de autocorrelação espacial. O Indicador de Geary (Eq.2) foi aplicado sobre as imagens MNDWI para obter a autocorrelação espacial e para quantificar a água superficial.

<sup>1</sup> Nível zero da régua limnimétrica é -0,42 em relação ao datum vertical de Imbituba/SC.



(Eq.2)

$$C = \frac{(n-1)}{2 \sum_{i=1}^n \sum_{j=1}^n w_{ij}} \frac{\sum_{i=1}^n \sum_{j=1}^n w_{ij} (x_i - x_j)^2}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

Fonte: <https://www.rdocumentation.org/>

onde,  $n$  é o número de composições de MNDWI anuais,  $x_i$  e  $x_j$  representam os valores de MNDWI na posição  $i$  e  $j$ , respectivamente.  $\bar{x}$  é o valor médio do MNDWI em todos os locais e  $w_{ij}$  representa a proximidade espacial entre os locais  $i$  e  $j$ .

De acordo com Camargo e Felgueiras (2015), o índice normalmente assume valores entre 0 a 2. Valor no intervalo  $0 \leq c < 1$  indica autocorrelação espacial positiva ou direta; no intervalo  $1 < c \leq 2$  indica autocorrelação espacial negativa ou inversa; e  $c = 1$  indício de independência espacial entre as áreas.

Com relação ao Índice Global de Moran ( $I$ ) proposto por Moran (1950), este é um indicador frequentemente utilizado para obter a autocorrelação espacial (SHORTRIDGE, 2007; FU et al., 2014; LI et al., 2019). O Índice Global de Moran (Eq.3) foi aplicado sobre as imagens MNDWI para obter a autocorrelação espacial e para quantificar a dinâmica dos padrões das águas superficiais.

$$I = \frac{n}{\sum_{i=1}^n \sum_{j=1}^n w_{ij}} \frac{\sum_{i=1}^n \sum_{j=1}^n w_{ij} (x_i - \bar{x})(x_j - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (\text{Eq.3})$$

Fonte: <https://www.rdocumentation.org/>

onde,  $n$  é o número de composições de MNDWI anuais,  $x_i$  e  $x_j$  representam os valores de MNDWI na posição  $i$  e  $j$ , respectivamente.  $\bar{x}$  é o valor médio do MNDWI em todos os locais e  $w_{ij}$  representa a proximidade espacial entre os locais  $i$  e  $j$ .

De acordo com Li et al. (2019), os valores do índice variam de 1 a -1, e o valor 1 significa a autocorrelação espacial positiva (ou seja, padrões de cluster), o valor -1 significa a autocorrelação espacial negativa (ou seja, padrões de tabuleiro de damas) e o valor 0 não representa autocorrelação (isto é, padrões aleatórios).

Os índices globais de autocorrelação espacial é frequentemente empregado em dados armazenados em polígonos que marcam a área de interesse, mas também é uma ferramenta utilizada na análise de dados matriciais. Dessa forma, as estruturas de dados rasterizadas também são acessíveis ao cálculo dessas métricas.

De acordo com Uuemaa et al. (2008) para imagens *raster*, uma autocorrelação pode ser calculada (a) por todos os pixels apropriados ou (b) usando-se amostras. O primeiro, que é comumente usado, é limitado a dois esquemas direcionados: *Rook* (como a torre de um jogo de xadrez), que leva em consideração as direções vertical e horizontal (quatro vizinhos para cada *pixel*) ou *King*<sup>2</sup> (como o rei em um jogo de xadrez), que também considera as direções diagonais (oito vizinhos). A Figura 3 apresenta as diferenças nas direções nas matrizes 3x3 onde observa-se que a matriz *Rook* tem menor número de vizinhos (4) em relação a matriz em *Queen* que tem um maior número de vizinhos (8) considerados no cálculo das métricas.

Example 3x3 Queen filter:

1	1	1
1	0	1
1	1	1

Example 3x3 Rook filter:

0	1	0
1	0	1
0	1	0

Figura 3 – Diferenças entre a matriz de contiguidade *Queen* e *Rook*.

Fonte: Tinkham (2018).

Assim, conforme Shortridge (2007), um passo importante no cálculo é a escolha da regra de contiguidade ou de vizinhança para determinar os pesos  $W_{ij}$ , uma vez que cada matriz pode produzir resultados diferentes. Em imagens binárias (duas classes) o  $W$  binário também é chamado de adjacência absoluta. O peso é determinado quando um valor em uma região (*pixel*) é igual ou diferente do valor dos seus vizinhos. Se duas entidades geográficas (*pixels* de mesma classe) forem adjacentes:  $w_{ij} = 1$ . Se duas entidades geográficas (*pixels* de mesma classe) não forem adjacentes:  $w_{ij} = 0$ .

Dessa forma, para Shortridge (2007) a estimativa do Índice Global de Moran (assim como no Indicador de Geary) em um padrão *raster* é extremamente sensível à escolha do esquema de contiguidade ou vizinhança. Isto posto, para este estudo foi utilizado *Queen* como matriz de proximidade em cada uma das imagens do MNDWI classificado. A matriz de vizinhança e os índices globais de autocorrelação espacial foram calculados no pacote R (R-TEAM, 2015).

## 2.6. Análise Exploratória

Foi realizada uma análise exploratória com geração de histograma para verificar a frequência dos valores das variáveis, aplicação do coeficiente de correlação de *Pearson* para avaliar a linearidade entre as variáveis, ou seja, medir o grau da relação linear entre a variável

<sup>2</sup> Equivalente a matriz de contiguidade *Queen*.

resposta (Y) e a variável explicativa (X), gráfico de dispersão (*scatterplot*), geração de *boxplot* para verificar a variância e a presença de *outliers* nas observações.

Para as métricas de paisagem foram utilizadas 35 observações ou amostras e para a cota do rio 32 observações ou amostras (para 3 datas não havia medida de cota do rio disponível). Com a finalidade de quantificar a relação entre as variáveis consideradas no estudo, os valores foram normalizados pelo método do mínimo e máximo (Eq.4) para assegurar que todos os valores variem no intervalo de 0 a 1. Este método foi aplicado para a comparação quantitativa de diversas métricas da paisagem por Li et al. (2016) e Li et al. (2019).

$$\text{Valor normalizado} = (x - \min) / (\max - \min) \quad (\text{Eq.4})$$

onde,  $x$  é o valor da variável no respectivo ano,  $\min$  é o valor mínimo no intervalo da variável e  $\max$  é o valor máximo no intervalo da variável.

## 2.7. Análise Estatística

Na sequência, com o objetivo de identificar a relevância da variável independente com as variáveis dependentes, buscou-se encontrar a função que descrevesse como a variável independente (X) se relaciona com a variável dependente (Y) e estimar os parâmetros que definem esta função utilizando um modelo de regressão linear (Eq.5). Com a aplicação da regressão linear foram obtidas as estatísticas relacionadas ao erro padrão, coeficiente de determinação ( $R^2$ ), coeficiente de determinação ajustado ( $R^2$  ajustado), valor-p e estatística F.

$$Y_i = \beta_0 + \beta_1 X_i + \xi_i \quad (\text{Eq.5})$$

onde,  $\beta_0$  é intercepto,  $\beta_1$  é a inclinação da reta,  $X_i$  é o valor da variável independente e  $\xi_i$  é o erro ou resíduo.

Para avaliar a confiabilidade da regressão linear foi verificada a normalidade dos resíduos com a aplicação do teste Jarque-Bera e teste Shapiro-Wilk. Para avaliar a variância (homocedasticidade e heterocedasticidade) nos resíduos do modelo de regressão linear foi realizado o teste Breusch-Pagan. Todas as análises estatísticas foram realizadas no pacote R (R-TEAM, 2015). As etapas e procedimentos metodológicos podem ser observados no fluxograma da Figura 4.

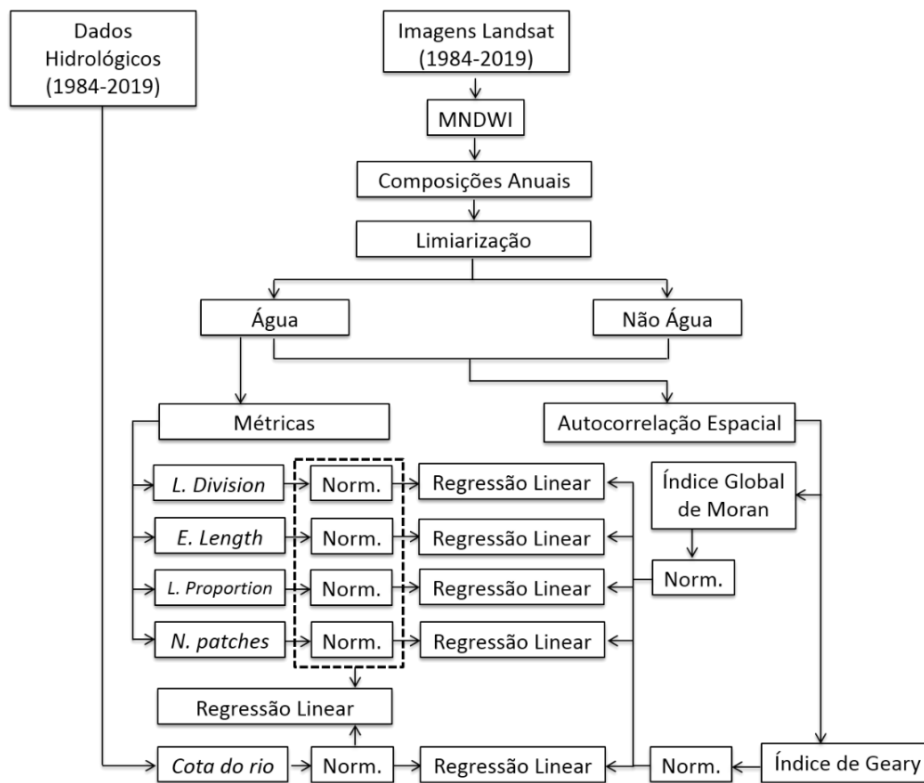


Figura 4 – Síntese dos procedimentos metodológicos.

### 3. RESULTADOS E DISCUSSÕES

#### 3.1. Análise espacial e temporal da água superficial

A análise da série temporal anual (Figura 5) permitiu quantificar e verificar uma significativa variabilidade temporal nos padrões de ocorrência das feições de água superficial e identificar a expansão e contração das áreas úmidas na área de estudo. Em geral, a extensão da área de água superficial anual é inferior à média (6,8 km<sup>2</sup>), indicando uma tendência maior para a contração das áreas úmidas. Anos com valores de área de água superficial acima da média, indicam maior expansão das áreas úmidas, como pode ser observado entre 1986 e 1990, 1994, 2001, 2005, 2007, 2013, 2014 e 2018.




Figura 5 – Quantificação da água superficial em trecho da planície do Rio dos Sinos.

A análise espacial das áreas de água superficial na série temporal (Figura 6), em geral, reflete o padrão identificado na análise temporal, evidenciando uma significativa variabilidade espacial anual associada às áreas úmidas. Em geral, predomina um padrão de menor ocorrência e maior heterogeneidade espacial das áreas úmidas na área de estudo. A maior ocorrência de área de água superficial e maior homogeneidade espacial das áreas úmidas estão associadas à anos com registros de inundação, como pode ser observado entre 1986 e 1990, 1994, 2001, 2005, 2007, 2013, 2014 e 2018.

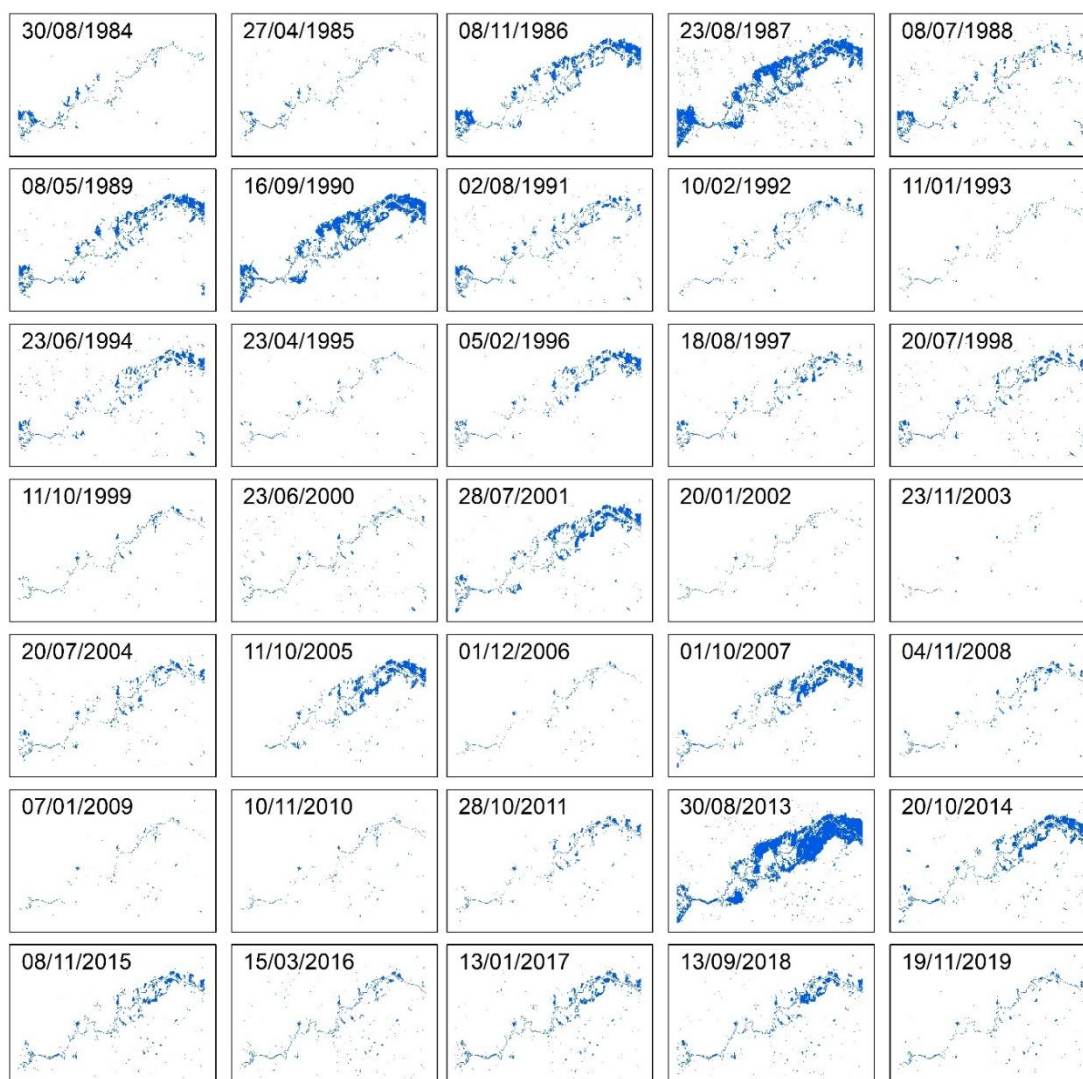


Figura 6 – Espacialização das classes temática associada a água superficial (azul) e não-água (branco) em trecho da planície do Rio dos Sinos.

A dinâmica anual da água superficial evidencia um padrão heterogêneo mais complexo e com alto contraste entre os anos analisados. Dessa forma, a análise espacial e a avaliação dos padrões de fragmentação ou agrupamento da água superficial das áreas úmidas podem ser melhor avaliados a partir da aplicação de índices globais de autocorrelação espacial e métricas da paisagem, assim como a comparação com a cota do rio.

### 3.2. Índice Global de Moran (I) e Métricas da Paisagem

O Índice Global de Moran foi utilizado como variável independente para explicar as métricas da paisagem (variáveis dependentes).

#### 3.2.1. Análise exploratória

O Índice Global de Moran (I) na área de estudo variou entre 0.389 e 0.836. A amplitude nos valores positivos do Índice Global de Moran (I) evidenciam que o padrão de agrupamento espacial das áreas úmidas na área de estudo apresentam uma significativa variabilidade espacial, em contraposição ao identificado por Li et al. (2019) que identificaram uma baixa amplitude em altos valores do Índice Global de Moran (I) na expansão e retração da água em reservatórios. Assim, em um primeiro momento da análise, constata-se que o Índice Global de Moran (I) pode capturar a dinâmica da água superficial mais complexa e heterogênea em áreas úmidas. Para tanto, é necessária a comparação com métricas da paisagem que caracterizam a configuração espacial e fornecem indicadores quantitativos associados a água superficial.

A proporção de área de água (*landscape proportion*) comparada com o Índice Global de Moran (I) indica que estas seguem uma tendência semelhante. Em geral, verifica-se que o Índice Global de Moran (I) maior caracteriza uma porcentagem maior da área de água superficial (Fig.7a). O comprimento de borda (*edge length*) é outra métrica que acompanha o Índice Global de Moran (I) aumentando a medida que este aumenta (Fig.7b). Em relação ao índice de divisão da paisagem (*landscape division*), observa-se que esta métrica apresenta uma tendência de se manter constante (sem variabilidade significativa) e com valores altos, exceto quando ocorrem valores altos do Índice Global de Moran (Fig.7c). O número de fragmentos (*number of patches*) tende a aumentar e reduzir a medida que o índice Global de Moran aumenta e reduz, respectivamente (Fig.7d). Os gráficos da Figura 7 apresentam a relação entre o Índice Global de Moran (I) com as métricas da paisagem.




Figura 7 – Relação entre Índice Global de Moran (I) com as métricas da paisagem.

O grau de relacionamento entre o Índice Global de Moran (I) com as métricas da paisagem pode ser melhor avaliado com a realização de uma análise estatística, a fim de quantificar a relação entre as variáveis analisadas.

### 3.2.2. Análise estatística descritiva

Com relação a distribuição e dispersão dos dados no *boxplot* (Figura 8) pode-se verificar a presença de *outliers* em algumas variáveis: *landscape proportion* (3), *edge length* (1), *landscape division* (7) e cota do rio (1). A busca e consulta dos *outliers*, principalmente, nas métricas da paisagem, quando comparado com a cota do rio, revela que estes estão relacionados com inundações de grande magnitude. Assim, observa-se em um primeiro momento, que as métricas da paisagem, capturam a configuração espacial associada a ocorrência de inundações na área de estudo.

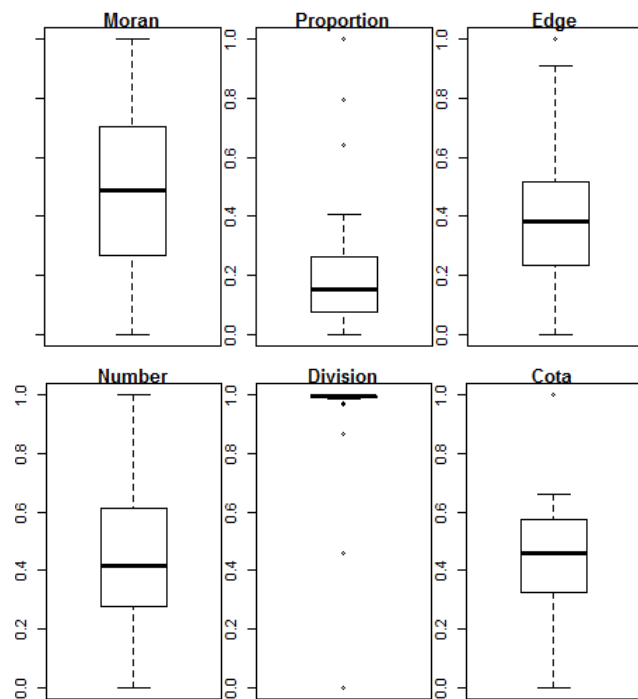


Figura 8 – *Boxplot* das variáveis analisadas.

A relação estatística entre a variável independente (Índice Global de Moran) com as variáveis dependentes (métricas da paisagem) pode ser observada no *scatterplot* (Figura 9). O Coeficiente de *Pearson* (CP) entre o Índice Global de Moran (I) com as métricas *landscape proportion* e *edge length* apresentaram maiores valores de correlação, respectivamente, 0,84 e 0,90, indicando assim maior linearidade. Em contraposição, o Coeficiente de *Pearson* (CP) entre o Índice Global de Moran (I) e as métricas *number of patches* e *landscape division* apresentaram menores valores de correlação, respectivamente, 0,55 e -0,48 indicando assim menor linearidade.

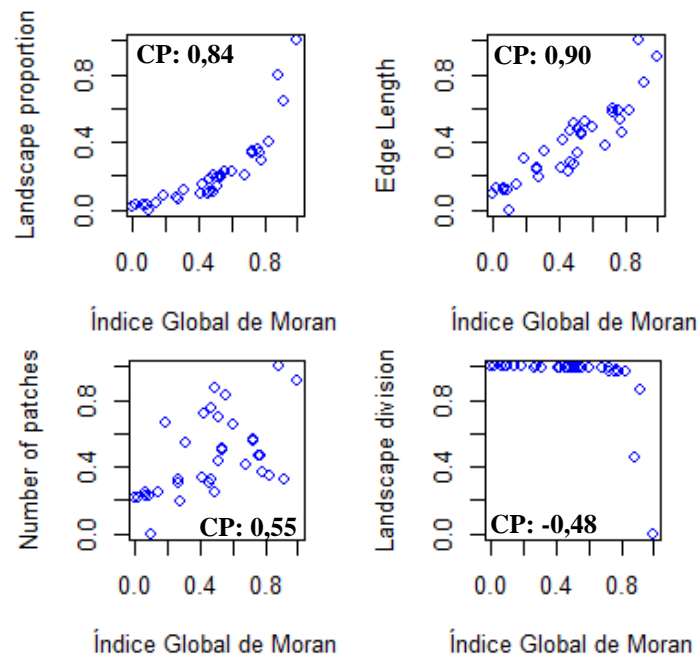


Figura 9 – Linearidade do Índice Global de Moran (I) com as métricas da paisagem.

A partir da análise estatística realizada para avaliação prévia das variáveis e das relações entre as variáveis dependentes e independentes foi aplicada a regressão linear.

### 3.2.3. Análise da regressão linear

Na análise comparativa da regressão linear do Índice Global de Moran (I) com as métricas da paisagem (Tabela 3), observa-se que os menores erros padrão e os maiores coeficientes de determinação ( $R^2$ ) foram na regressão linear *edge length*-Moran e *landscape proportion*-Moran. A regressão linear *landscape division*-Moran e *number of patches*-Moran apresentaram os maiores erros padrão e os menores coeficientes de determinação ( $R^2$ ). Em geral, os todos os resultados da regressão apresentaram valor-p baixo indicando que os resultados são estatisticamente significativos.

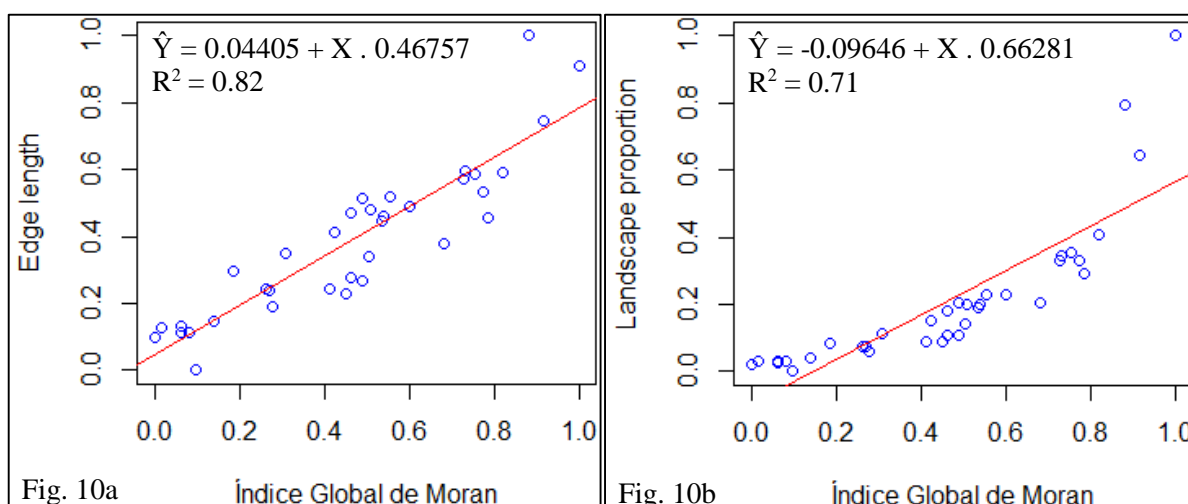
Para os testes de Jarque-Bera e Shapiro-Wilk na regressão linear *edge length*-Moran foi aceita a normalidade evidenciando que a amostra provém de uma população normal, isto é, os resíduos são normalmente distribuídos e no teste de Breusch-Pagan os erros são homocedásticos, ou seja, sua variância é constante. No entanto, para a regressão linear *landscape proportion*-Moran e *landscape division*-Moran foi rejeitada a normalidade provando que a amostra não provém de uma população normal, isto é, os resíduos não são normalmente distribuídos e no teste de Breusch-Pagan os erros são heterocedásticos, ou seja, a variância dos erros será diferente para cada valor condicional de X. Para a regressão linear *number of patches*-Moran a normalidade não foi aceita no teste de Shapiro-Wilk e no teste de Breusch-Pagan apresentou homocedasticidade.



Tabela 3 – Estatísticas do Índice Global de Moran com as métricas da paisagem

Variáveis Coeficientes	<i>Landscape proportion-Moran</i>	<i>Edge length-Moran</i>	<i>Landscape division-Moran</i>	<i>Number of patches-Moran</i>
<b>Intercept (<math>\beta_0</math>)</b>	-0.09646	0.04405	1.0985	0.24
<b>Inclinação (<math>\beta_1</math>)</b>	0.66281	0.73887	-0.3246	0.46757
<b>Erro padrão (<math>\epsilon</math>)</b>	0.1213	0.09934	0.1684	0.2015
<b>R<sup>2</sup></b>	0.7056	0.8163	-0.2298	0.3019
<b>R<sup>2</sup> ajustado</b>	0.6967	0.8107	-0.2065	0.2807
<b>valor-p</b>	2.8e-10	1.091e-13	0.003572	0.0006299
<b>F</b>	79.1	146.7	9.846	14.27
<b>Teste Jarque-Bera</b>	6.715e-10	0.2106	< 2.2e-16	0.3675
<b>Teste Shapiro-Wilk</b>	0.000103	0.09681	6.429e-08	0.0431
<b>Teste Breusch-Pagan</b>	0.009359	0.05041	0.01631	0.08644

Com a regressão linear (Figura 10) é possível afirmar que o Índice Global de Moran (I), dado o alto coeficiente de determinação ( $R^2$ ) com *edge length* (Figura 10a), pode explicar os padrões espaciais associados ao comprimento total da borda das áreas úmidas. Também é possível afirmar que a regressão linear entre o Índice Global de Moran (I) e a métrica *landscape proportion* (Figura 10b), embora com alto valor do coeficiente de determinação ( $R^2$ ), esta regressão não poderia ser utilizada como estimador da métrica *landscape proportion* devido à falta de normalidade e heterocedasticidade. Com relação a regressão linear entre Índice Global de Moran (I) e as métricas *number of patches* (Figura 10c) e *landscape division* (Figura 10d), estas apresentaram baixo valor no coeficiente de determinação ( $R^2$ ) e também não poderiam ser utilizadas como estimadores para quantificar o número de fragmentos e divisão (fragmentação) da paisagem das áreas úmidas.






Figura 10 – Modelo de regressão linear entre Índice Global de Moran (I) com as métricas da paisagem.

### 3.3. Autocorrelação Espacial e Cota do Rio

Os índices globais de autocorrelação espacial representados pelo Índice Global de Moran (I) e o Índice de Geary (C) nesta etapa foram utilizados como variáveis independentes para estimar a cota do rio (variável dependente).

#### 3.3.1. Análise exploratória

O Índice Global de Moran (I) aumenta e reduz a medida que a cota do rio aumenta e reduz, respectivamente (Fig.11a). Em contraposição, o Índice de Geary (C) aumenta à medida que a cota do rio reduz e a medida que a cota aumenta o Índice de Geary (C) reduz (Fig.11b). Os gráficos da Figura 11 apresentam a relação entre a cota do rio com o Índice Global de Moran (I) e o Índice de Geary (C).




Figura 11 – Relação entre cota do rio e os índices globais de autocorrelação espacial.

A partir da análise exploratória verifica-se que o Índice Global de Moran (I) tem uma relação direta com a cota do rio, enquanto o Índice de Geary (C) tem uma relação inversa com a cota do rio. O grau de relacionamento entre os índices globais de autocorrelação espacial pode ser melhor avaliado com a realização de uma análise estatística para quantificar a relação entre as variáveis analisadas.

### 3.3.2. Análise estatística

A relação estatística entre as variáveis independentes (Índice Global de Moran e Indicador de Geary) com a variável dependente (cota do rio) pode ser observada no *scatterplot* (Figura 12). O Coeficiente de *Pearson* (CP) do Índice Global de Moran (I) com a cota do rio apresentou valor de correlação direta de 0,91 e portanto evidencia uma significativa linearidade entre as variáveis. O Coeficiente de *Pearson* (CP) do Indicador de Geary (C) com a cota do rio apresentou valor de correlação inversa de -0,91 o que mostra uma expressiva linearidade entre as variáveis. A Figura 12 apresenta os gráficos com a linearidade entre a variável dependente (cota do rio) com as variáveis independentes (Índice Global de Moran e Índice de Geary).

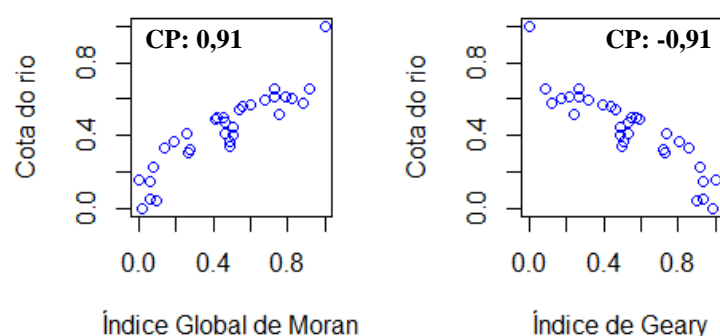


Figura 12 – Linearidade entre os índices globais de autocorrelação espacial e a cota do rio.

A partir da análise estatística descritiva realizada para avaliação prévia das variáveis e das relações entre as variáveis dependentes e independentes foi aplicado e analisado o modelo de regressão linear.

### 3.3.3. Análise da regressão linear

Na análise comparativa da regressão linear (Tabela 4) observa-se que o Índice Global de Moran (I) apresentou um valor ligeiramente menor no erro padrão e ligeiramente maior no coeficiente de determinação ( $R^2$ ) em relação ao Indicador de Geary (C). O coeficiente de determinação ( $R^2$ ) da regressão linear entre o Índice Global de Moran (I) e a cota do rio foi de 0,83. O coeficiente de determinação ( $R^2$ ) da regressão linear entre o Indicador de Geary (C) e a cota do rio foi de -0,82, indicando uma relação inversa, ou seja, quanto maior o valor do Indicador de Geary (C) menor o valor da cota do rio e quanto menor o valor do Indicador de Geary (C), maior o valor da cota do rio. Em geral, os resultados de ambas as regressões lineares apresentaram valor-p baixo indicando que os resultados são estatisticamente significativos. Além disso, nos testes de normalidade de Jarque-Bera e Shapiro-Wilk para ambos os índices globais de autocorrelação espacial foi aceita a normalidade evidenciando que a amostra provém de uma população normal, isto é, os resíduos são normalmente distribuídos e conforme o teste de Breusch-Pagan os erros são homocedásticos, ou seja, sua variância é constante.

Tabela 4 – Estatísticas da cota do rio com Índice Global de Moran (I) e Indicador de Geary (C)

Variáveis Coeficientes	Cota- Moran	Cota- Geary
<b>Intercept (<math>\beta_0</math>)</b>	0.12404	0.7918
<b>Inclinação (<math>\beta_1</math>)</b>	0.67033	-0.6680
<b>Erro padrão (<math>\epsilon</math>)</b>	0.08957	0.08982
<b>R<sup>2</sup></b>	0.83	-0.82
<b>R<sup>2</sup> ajustado</b>	0.82	-0.82
<b>valor-p</b>	6.985e-13	7.594e-13
<b>F</b>	141.4	140.5
<b>Teste Jarque-Bera</b>	0.7554	0.7667
<b>Teste Shapiro-Wilk</b>	0.4899	0.4518
<b>Teste Breusch-Pagan</b>	0.5513	0.5315

A partir das regressões lineares (Figura 13) é possível afirmar que tanto o Índice Global de Moran (Fig.13a) quanto o Índice de Geary (Fig.13b), dado o alto coeficiente de determinação ( $R^2$ ) e confiabilidade do modelo, podem ser utilizados como estimadores para quantificar a cota do rio.

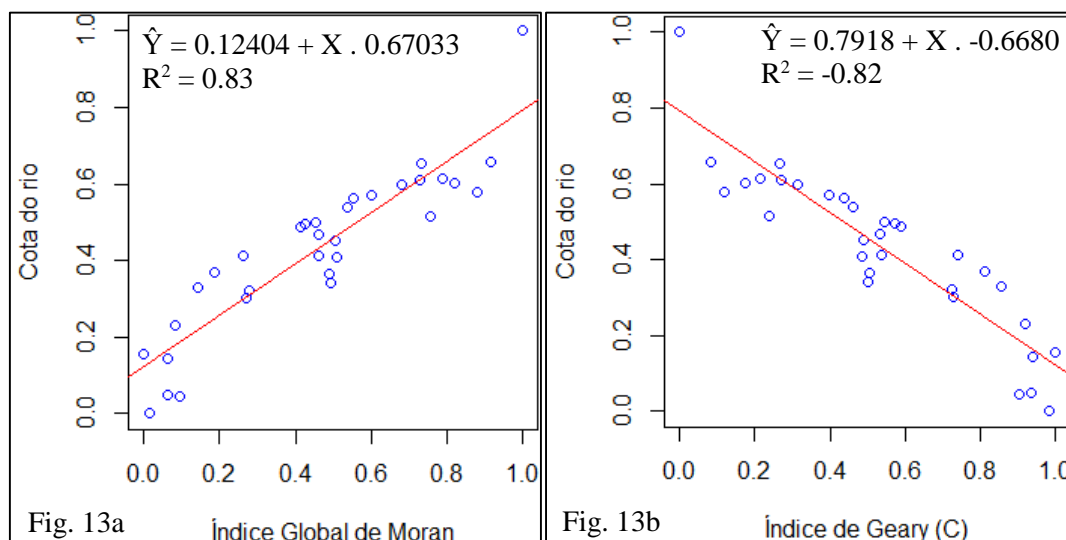


Figura 13 – Modelo de regressão linear entre cota do rio e autocorrelação espacial.

A partir da equação fornecida pela regressão linear utilizando o Índice Global de Moran (I) como uma das variáveis explicativas é possível estimar a cota do rio e compará-la com a cota medida. Na Figura 14 pode-se observar graficamente que a linha da cota medida, em geral, encontra-se próxima da linha da cota estimada. As maiores diferenças entre cota medida e cota estimada ocorrem em valores mais baixos ou valores mais altos das observações.




Figura 14 – Relação entre cota medida e cota estimada utilizando a regressão linear com o Índice Global de Moran (I).

### 3.4. Métricas da Paisagem e Cota do Rio

As métricas da paisagem (*landscape proportion*, *edge length*, *number of patches* e *landscape division*) foram utilizadas como variáveis independentes para verificar se apresentam desempenho superior aos índices globais de autocorrelação espacial para estimar a cota do rio.

#### 3.4.1. Análise exploratória

Em geral, verifica-se que a quanto maior a proporção de água (*landscape proportion*), maior é a cota do rio (Fig. 15a). O comprimento de borda (*edge length*) é outra métrica que acompanha a cota do rio aumentando a medida que esta aumenta e reduzindo a medida que a cota do rio reduz (Fig.15b). Em relação ao número de fragmentos (*number of patches*) tende a aumentar e reduzir a medida que a cota do rio aumenta e reduz, respectivamente (Fig.15c). Com a métrica *landscape division* (Fig.15d) observa-se que esta apresenta uma tendência de se manter constante e com valores altos, exceto quando ocorre cota do rio com valores mais altos. Os gráficos da Figura 15 apresentam a relação entre as métricas da paisagem e cota do rio.

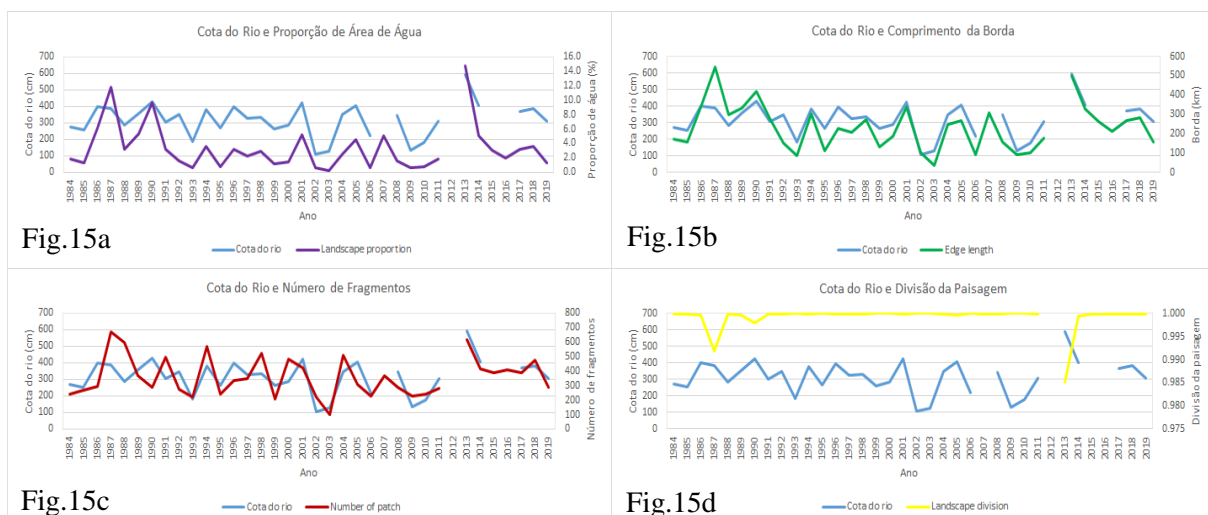


Figura 15 – Relação entre cota do rio e métricas da paisagem.

### 3.4.2. Análise estatística

A relação estatística entre as variáveis independentes (métricas da paisagem) com a variável dependente (cota do rio) pode ser observada no *scatterplot* (Figura 16). O Coeficiente de *Pearson* (CP) entre a cota do rio e as métricas *landscape proportion* e *edge length* apresentaram maiores valores de correlação, respectivamente, 0,78 e 0,83, indicando assim maior linearidade. Em contraposição, o Coeficiente de *Pearson* (CP) entre a cota do rio e as métricas *number of patches* e *landscape division* apresentaram menores valores de correlação, respectivamente, 0,62 e -0,54, indicando assim menor linearidade entre as relações analisadas.

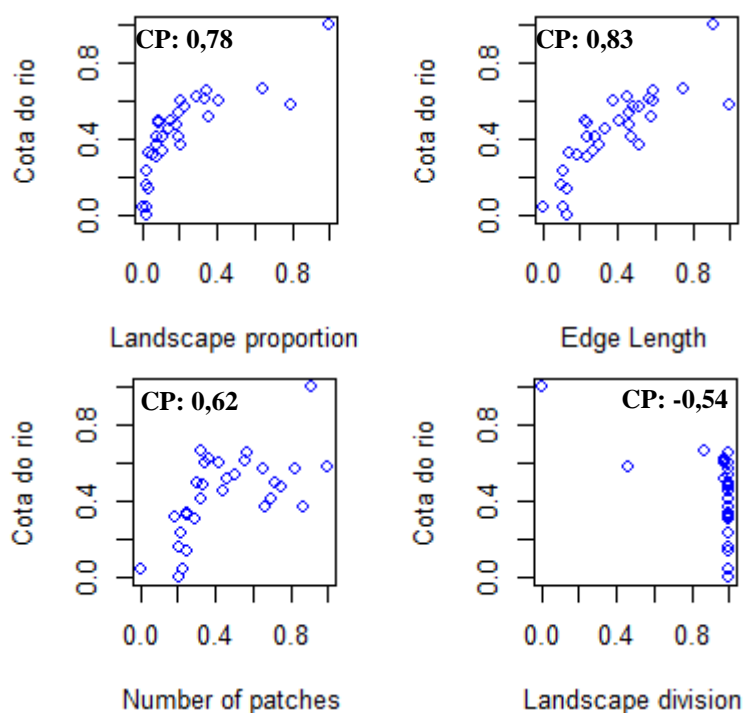


Figura 16 – Linearidade entre a cota do rio e as métricas da paisagem.

A partir da análise estatística realizada para avaliação das relações entre as variáveis dependentes e independentes foi aplicado e analisado o modelo de regressão linear.

### 3.4.3. Análise da regressão linear


Na análise comparativa da regressão linear das variáveis independentes (métricas da paisagem) com a variável dependente cota do rio (Tabela 5), observa-se que os menores erros padrão e os maiores coeficientes de determinação ( $R^2$ ) foram na regressão linear cota-*edge length* ( $R^2=0,69$ ) e cota-*landscape proportion* ( $R^2=0,61$ ). A regressão linear cota-*landscape division* ( $R^2=0,38$ ) e cota-*number of patches* ( $R^2=-0,29$ ) apresentaram os maiores erros padrão e os menores coeficientes de determinação ( $R^2$ ). Em geral, os todos os resultados da regressão apresentaram valor-p baixo indicando que os resultados são estatisticamente significativos.

Nos testes de normalidade de Jarque-Bera e Shapiro-Wilk da regressão linear entre cota do rio e métricas da paisagem (*edge length*, *landscape proportion*, *number of patches* e *landscape division*) foi aceita a normalidade evidenciando que a amostra provém de uma população normal, isto é, os resíduos são normalmente distribuídos e conforme o teste de Breusch-Pagan os erros são homocedásticos, ou seja, sua variância é constante.

Tabela 5 – Estatísticas da cota do rio com as métricas da paisagem

Variáveis Coeficientes	Cota – <i>Landscape proportion</i>	Cota – <i>Edge length</i>	Cota – <i>Number of patches</i>	Cota – <i>Landscape division</i>
<b>Intercept (<math>\beta_0</math>)</b>	0.27895	0.1490	0.1946	0.9770
<b>Inclinação (<math>\beta_1</math>)</b>	0.71894	0.7375	0.5225	-0.5788
<b>Erro padrão (<math>\epsilon</math>)</b>	0.1335	0.1191	0.1687	0.1799
<b>R<sup>2</sup></b>	0.61	0.69	0.38	-0.29
<b>R<sup>2</sup> ajustado</b>	0.60	0.68	0.36	-0.27
<b>valor-p</b>	1.266e-07	3.877e-09	0.0001765	0.001336
<b>F</b>	47.18	67.01	18.31	12.52
<b>Teste Jarque-Bera</b>	0.1428	0.2834	0.6918	0.2328
<b>Teste Shapiro-Wilk</b>	0.01091	0.1633	0.8137	0.03682
<b>Teste Breusch-Pagan</b>	0.85	0.1213	0.4986	0.397

A partir da regressão linear, é possível afirmar que as métricas *edge length* (Figura 17a), *landscape proportion* (Figura 17b) apresentam razoável capacidade para estimar a cota do rio. No entanto, as métricas *number of patches* (Figura 17c) e *landscape division* (Fig.17d) devido ao coeficiente de determinação ( $R^2$ ) mais baixo, não podem estimar de forma precisa e satisfatória o padrão de aumento ou redução da cota do rio.



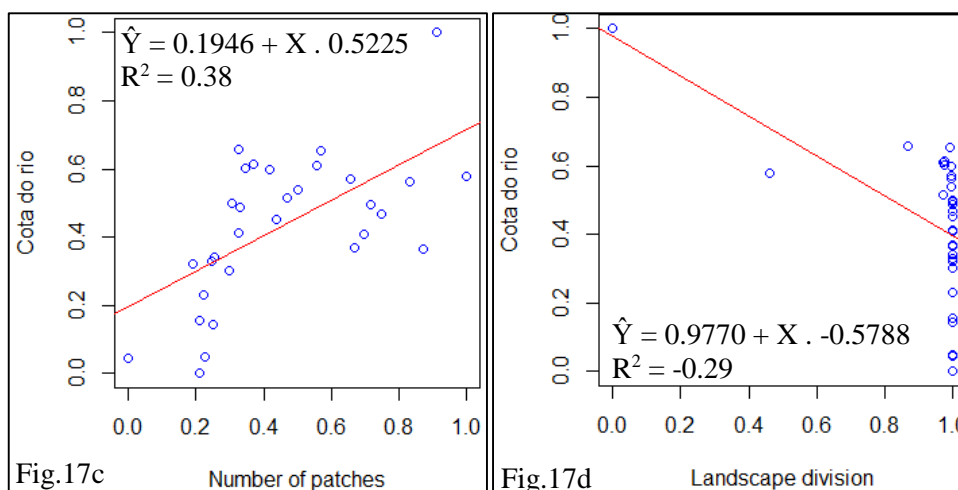


Figura 17 – Modelo de regressão linear entre cota do rio e métricas da paisagem.

#### 4. CONCLUSÕES

A formação de uma série temporal anual das imagens de satélite permitiu capturar de forma satisfatória a variabilidade espacial e temporal nas ocorrências de áreas úmidas. Considerar mais de uma imagem de satélite por ano poderia aumentar a amostragem e proporcionar um maior número de observações, o que poderia melhorar a análise comparativa nas estatísticas entre as variáveis e aumentar a precisão da regressão linear.

A aplicação do *Modified Normalized Difference Water Index* (MNDWI) nas imagens de satélite apresentou um bom desempenho para a classificação temática das feições associadas a águas superficiais nas imagens de satélite, delimitando de forma satisfatória classes temáticas de água e não-água na área de estudo. A realização de testes de limiares diferentes no MNDWI utilizados no presente estudo e a eliminação de pixels ou fragmentos isolados poderiam melhorar a classificação das classes temáticas de água e não-água, especialmente, nas imagens de satélite em períodos com registro de inundação que tendem a superestimar a classificação das áreas como água.

Os índices globais de autocorrelação espacial aplicados neste estudo apresentam melhor desempenho para estimar a cota do rio do que as métricas da paisagem. Tanto o Índice Global de Moran (I) quanto o Indicador de Geary (C) podem explicar de forma precisa e satisfatória a dinâmica de aumento e redução do nível da água e podem ser utilizados para estimar a cota do rio. Além disso, como as fontes de dados entre cota do rio e índices globais de autocorrelação deste estudo são de origens diferentes, régua limnimétrica e imagens de satélite, respectivamente, os índices globais de autocorrelação tem grande potencial para serem utilizados isoladamente ou em conjunto com outros dados para o preenchimento de falhas em cotas fluviométricas, parâmetro importante para a caracterização do regime hidrológico e pulsos de inundação nas áreas úmidas.



## 5. REFERÊNCIAS

- AGÊNCIA NACIONAL DE ÁGUAS (ANA). **Hidroweb**. Disponível em: <http://hidroweb.ana.gov.br/>. Acesso em 14 nov. 2019.
- BAZZAN, T. Mapeamento das áreas com risco de inundação do Rio dos Sinos no município de São Leopoldo, RS. 2011. 135 f. **Dissertação** (Mestrado em Geografia). Programa de Pós-graduação em Geografia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2011.
- BERTOLUCI, V. D. M. Inventário, biodiversidade e conservação de áreas úmidas do município de São Leopoldo. **Dissertação de Mestrado** (Programa de Pós-Graduação em Biologia). Universidade do Vale do Rio dos Sinos, 2004.
- BRUBACHER, J. P.; GUASSELLI, L.A. Mapeamento da área inundável da planície do Rio dos Sinos a partir do índice NDWI, São Leopoldo. In: XVI Simpósio Brasileiro de Sensoriamento Remoto - SBSR, **Anais...** Foz do Iguaçu, PR, Brasil. INPE. Abril, 2013.
- CAMARGO, E., G.; FELGUEIRAS, C. Módulo: análise de padrão de áreas. 2015. Disponível em: < <http://wiki.dpi.inpe.br/doku.php?id=ser301-2019>>. Acesso em: 18 nov. 2019.
- CARRAO, G.; CAETANO, M.; NEVES, N. LANDIC - Cálculo de Indicadores de Paisagem em ambiente SIG. In: **Anais...** Encontro de utilizadores de Informação Geográfica (ESIG), v. 1. 2001.
- EMBRAPA MONITORAMENTO POR SATÉLITE. **Satélites de Monitoramento**. Campinas: Embrapa Monitoramento por Satélite, 2013. Disponível em: <<http://www.sat.cnpm.embrapa.br>>. Acesso em: 16 dez. 2019.
- INSTITUTO NACIONAL DE CIÊNCIA E TECNOLOGIA EM ÁREAS ÚMIDAS (INAU). **Definição e Classificação das Áreas Úmidas (AUs) Brasileiras**: Base Científica para uma Nova Política de Proteção e Manejo Sustentável. 2014.
- JUNG, M. LecoS - A python plugin for automated landscape ecology analysis. **Ecological Informatics**, 31, 18–21, 2016.
- GEARY, R. C. The contiguity ratio and statistical mapping. *The Incorporated Statistician* 5: 115-145. 1954.
- KOBIYAMA, M (org). **Prevenção de desastres naturais: conceitos básicos**. Curitiba: Ed. Organic Trading, 109p, 2006.
- LI, Z; FENG, Y; GURGEL, H; XU, L; DESSAY, N; GONG, P. Use of spatial autocorrelation and time series Landsat images for long term monitoring of surface water shrinkage and expansion in Guanting Reservoir, China, **Remote Sensing Letters**, vol. 10, no. 12, 1192–1200, 2019.
- LI, Z.; ROUX, E.; DESSAY, N.; GIROD, R.; STEFANI, A.; NACHER, M.; MOIRET, A.; SEYLER, F. Mapping a Knowledge-Based Malaria Hazard Index Related to Landscape Using Remote Sensing: Application to the Cross-Border Area between French Guiana and Brazil. **Remote Sensing**, 8 (4): 319. 2016.

- LI, Z.; FENG, Y.; GURGEL, H.; XU, L.; DESSAY, N.; GONG, P. Use of spatial autocorrelation and time series Landsat images for long-term monitoring of surface water shrinkage and expansion in Guanting Reservoir, China, **Remote Sensing Letters**, 10:12, 1192-1200, 2018.
- MCGARIGAL, K. FRAGSTATS Help. 2015. Disponível em: <<http://www.umass.edu/landeco/research/fragstats/documents/fragstats.help.4.2.pdf>>. Acesso em: 2 dez. 2019.
- MALTCHICK, L. (org.). **Biodiversidade e conservação de áreas úmidas da bacia do rio dos Sinos**. Universidade do Vale dos Sinos. Editora UNISINOS. 79 p., 2003.
- MARCONATO, A. **Planícies de Inundação Fluviais Pré-vegetação: exemplos do Supergrupo Espinhaço (Mesoproterozoico, BA) e do Supergrupo Camaquã (Ediacarano-Cambriano, RS)**. Tese (Doutorado). Programa de Pós-graduação em Geoquímica e Geotectônica. Universidade de São Paulo. São Paulo. 2014.
- MCFEETERS, S. K. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. **International Journal of Remote Sensing**, [s.i.], v. 17, n. 7, p.1425-1432, maio 1996.
- MORAN, P.A.P. Notes on continuous stochastic phenomena. **Biometrika** 37:17-23. 1950.
- NEIFF, J. J. El régimen de pulsos en ríos y grandes humedales de Sudamérica, p. 97-145. In: MALVÁREZ, A.I. e KANDUS, E.P. (eds.). **Tópicos sobre grandes Humedales Sudamericanos**. ORCYT-MAB (UNESCO), 229 p. 1999.
- OLIVEIRA, G. G. de. **Modelos para previsão, espacialização e análise das áreas inundáveis na bacia hidrográfica do Rio Caí, RS**. 2010. 197 f. Dissertação (Mestrado em Sensoriamento Remoto). Programa de Pós-graduação em Sensoriamento Remoto, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2010.
- PENTEADO, A. F. Análise Ambiental da Bacia Hidrográfica do Arroio Kruze - Região Metropolitana de Porto Alegre. **Dissertação de Mestrado** (Programa de Pós-Graduação em Geografia). Universidade Federal do Rio Grande do Sul. 210 p., 2006.
- RISSO, A.; GIUGNO, N. B. **Áreas de inundação, alagamento e banhados da Região Metropolitana de Porto Alegre - RS**. Porto Alegre: CPRM/METROPLAN. 53 p., 1994.
- R-TEAM. **R: A language and environment for statistical computing**. Vienna, Austria: T Development Core Team. 2015. Disponível em: <<https://www.r-project.org/>>. Acesso em: 2 dez. 2019.
- SINGH, K. V. et al. Evaluation of NDWI and MNDWI for assessment of waterlogging by integrating digital elevation model and groundwater level. **Geocarto International**, [s.i.], v. 30, n. 6, p.650-661, 12 nov. 2014.
- SALDANHA, D. L.; *et al.* L. Mapeamento e avaliação das áreas inundáveis do rio dos sinos através da utilização de imagens TM-Landsat 5. **Rev. Geog**, São Paulo, 1996.
- SECRETARIA DO MEIO AMBIENTE (SEMA). **Bacias Hidrográficas do Rio Grande do Sul**. 2002. Disponível em: <[www.sema.rs.gov.br](http://www.sema.rs.gov.br)>. Acesso em: 15 out. 2008

- SHORTRIDGE, A. Practical limits of Moran's autocorrelation index for raster class maps. *Computers, Environment and Urban Systems*, 31, 362–371, 2007.
- UUEMAA, E.; ROOSAARE, J.; KANAL, A.; MANDER, U. Spatial correlograms of soil cover as an indicator of landscape heterogeneity. *Ecological indicators*, 8, 783–794, 2008.
- TINKHAM, W. **Spatial Statistical Modeling**. Warner College of Natural Resources. 2018. Disponível em: <<https://sites.warnercnr.colostate.edu/wtinkham/courses-taught/nr-512-spatial-statistical-modeling/>>. Acesso em: 09 dez. 2019.
- TUCCI, C. E. M. **Curso de Gestão das Inundações urbanas**. 2005.
- UNITED STATES GEOLOGICAL SURVEY (USGS). **EarthExplorer**. Disponível em: <<https://earthexplorer.usgs.gov/>>. Acesso em: 19 nov. 2019.
- WANG, Z.; LI, H.; CAI, X. Remotely sensed analysis of channel bar morphodynamics in the middle Yangtze River in response to a major monsoon flood in 2002. *Remote Sensing*, v. 10, p. 1-11, May 2018.
- XU, H. Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery. *International Journal of Remote Sensing*, [s.i.], v. 27, n. 14, p.3025-3033, 20 jul. 2006.