

**UNIVERSIDADE FEDERAL DE PELOTAS – UFPEL**  
**Centro de Desenvolvimento Tecnológico – CDTec**  
**Programa de Pós-Graduação em Recursos Hídricos – PPGRH**



**Tese**

**Modelos de espaço de estados e análise em Wavelets no estudo do  
relacionamento entre atributos físico-hídricos do solo e atributos  
topográficos em escala de bacia hidrográfica**

**Luana Nunes Centeno**

Pelotas, 2020

**Luana Nunes Centeno**

**Modelos de espaço de estados e análise em Wavelets no estudo do  
relacionamento entre atributos físico-hídricos do solo e atributos  
topográficos em escala de bacia hidrográfica**

Tese apresentada ao Programa de Pós-Graduação em Recursos Hídricos do Centro de Desenvolvimento Tecnológico da Universidade Federal de Pelotas, como requisito parcial à obtenção do título de Doutora em Recursos Hídricos.

Orientador: Prof. Dsc. Luís Carlos Timm

Coorientadores: Prof. Dsc. Arlan da Silva Ferreira

Prof. Dsc. Willian da Silva Barros

Pelotas, 2020

Universidade Federal de Pelotas / Sistema de Bibliotecas  
Catalogação na Publicação

C397m Centeno, Luana Nunes

Modelos de espaço de estados e análise em Wavelets no estudo do relacionamento entre atributos físico-hídricos do solo e atributos topográficos em escala de bacia hidrográfica / Luana Nunes Centeno ; Luís Carlos Timm, orientador ; Arlan da Silva Ferreira, Willian da Silva Barros, coorientadores. — Pelotas, 2020.

198 f. : il.

Tese (Doutorado) — Programa de Pós-Graduação em Recursos Hídricos, Centro de Desenvolvimento Tecnológico, Universidade Federal de Pelotas, 2020.

1. Bacia hidrográfica arroio fragata. 2. Condutividade hidráulica de solo saturado. 3. Variabilidade espacial do solo. 4. Escala e localização específica. 5. Tipos de uso do solo. I. Timm, Luís Carlos, orient. II. Ferreira, Arlan da Silva, coorient. III. Barros, Willian da Silva, coorient. IV. Título.

CDD : 627

Luana Nunes Centeno

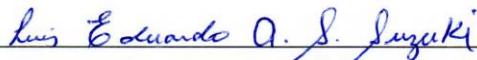
**Modelos de espaço de estados e análise em Wavelets no estudo do  
relacionamento entre atributos físico-hídricos do solo e atributos  
topográficos em escala de bacia hidrográfica**

Tese aprovada, como requisito parcial para obtenção do grau de Doutora em Recursos Hídricos, Programa de Pós-Graduação em Recursos Hídricos, Centro de desenvolvimento, Universidade Federal de Pelotas.

Data da defesa:



Banca examinadora: Prof. Dr. Luís Carlos Timm (Orientador). Doutor em Agronomia pela Escola Superior de Agricultura Luiz de Queiroz/USP.



Prof. Dr. Luis Eduardo Akiyoshi Sanches Suzuki, Doutor em Engenharia Florestal pela Universidade Federal de Santa Maria.



Profª. Drª. Claudia Liane Rodrigues de Lima, Doutora em Agronomia, pela Universidade de São Paulo, USP, Brasil.



Prof. Dr Dionis Glei Bonini Bitencourt. Doutor em Agronomia, pela Universidade Federal de Pelotas.

## Agradecimentos

Agradeço à Deus: pela vida, pelas pessoas que colocou em meu caminho, pelas suas leis, pelo seu amor, por aquietar a minha alma, pelo restabelecimento da minha saúde física e por meio destes me encher de coragem, força e perseverança para prosseguir nesta etapa.

Agradeço a Samanta Tolentino, minha querida “pink”, pelo apoio, pelo carinho e pela atenção a mim dispensada. Por estar sempre me incentivando, por todos os ensinamentos e “puxões de orelha” (e não foram poucos). Por estar ao meu lado quando pedia: “Sá pensa comigo?”. E principalmente por me ajudar a não perder o controle e ser racional nos momentos mais difíceis de minha vida. Por me apresentar o espiritismo e assim me inspirar a seguir em frente sempre. Ah! E não poderia de deixar de agradecer por acreditar em mim desde o início (graduação), sempre será um exemplo de profissional para mim.

Agradeço aos amados bichinhos: Kiara, Sophya, Lara e Hórus, que me mostraram que a vida deve ser curtida através das coisas mais simples, que amor, carinho e lealdade são como leis naturais e essenciais para nossa experiência terrestre. Por escolherem estar trancados comigo em dias lindos de sol, por terem paciência, nos dias que cheguei tarde e atrasei suas comidinhas ou nos dias que dei uma pequena pirada! Sou eternamente grata por ter vocês comigo.

Agradeço aos meus pais Adriana Nunes Centeno e Jair Centeno, que sempre primaram pela minha educação, me incentivaram e apoiaram, agradeço pelo carinho e paciência nos momentos em que não pude estar presente. Como não agradecer a minha maninha Alana Nunes Centeno, por me dar um dos maiores presentes desta vida o pequeno Pedro Henrique, coisa fofa de sua dinda, me trouxe a força, gratidão, amor e a esperança que me faltavam para finalizar mais esta etapa. Sou imensamente grata por todos os momentos em que pude estar com vocês.

Falando em coisinhas fofas não teria como não agradecer a Jujubinha (Júlia), principalmente neste final difícil e conturbado, por todas as brincadeiras, alegria e luz que trouxe com suas visitas!

Agradeço ao meu orientador, Prof. Dr. Luís Carlos Timm, por ter me escolhido e ter acreditado no meu potencial para desenvolver este trabalho. Por

me incentivar a seguir em frente e a enfrentar os meus maiores desafios, me mostrando que não existe problema sem resolução. Agradeço pelos desafios propostos, pois foram com eles que aprendi incríveis lições. Só tenho a lhe agradecer pelos ensinamentos, pelos conselhos, pela ajuda, pelo carinho, amizade, e por toda sua paciência. Termino esta etapa, com a certeza de que não há barreiras e desafios que não possam ser “compreendidos e vencidos”, com muita dedicação, ética, humildade e paciência, características estas que aprendi com o senhor. E principalmente por me mostrar a quão importante e bonita é o mundo das Wavelets. Sendo assim, sou e serei eternamente grata ao senhor.

Agradeço aos meus coorientadores Prof. Arlan da Silva Ferreira e Prof. Willian Silva Barros, por todo o auxílio na parte da estatística e matemática, por terem abraçado o tema conosco e por me auxiliarem a vencer as barreiras e lacunas da minha formação para compreensão deste tema da tese. Por todo carinho, atenção e dedicação a este trabalho, e também por todos “os puxões de orelha”, sou imensamente grata aos senhores.

Agradeço aos meus queridos amigos, Jeferson Pimentel, Rodrigo Mazzarro e Nathan Belluzzo, por terem me auxiliado e muitas vezes terem me ensinado, por todas as vezes que deixaram de fazer suas atividades para me auxiliarem, seja na compilação dos resultados, procurar livros, artigos, finalizar resumos de congressos, organizar scripts, dentre tantas outras tarefas que foram importantes para o andamento e conclusão deste estudo. Meu muito obrigada!

Agradeço aos meus queridos colegas do grupo de pesquisa, Thais, Mauricio, Ângelo, Rômulo, Miguel, Rodrigo e Alexssandra, pela atenção dispensada, disponibilidade, pela paciência nos dias em que eu queria “matalos”, pelos desafios impostos que me inspiraram a buscar novas soluções.

O presente estudo foi realizado com o apoio da Coordenação de Pessoal de Nível Superior – CAPES, devido a isso agradeço a esta instituição pelo apoio financeiro e principalmente pelo interesse neste assunto. Agradeço ainda ao Conselho Nacional de Desenvolvimento Científico e Tecnológico - CNPQ, pelo apoio financeiro ao projeto de pesquisa do qual originou esta tese.

Agradeço a Pró-reitoria de Pesquisa, Pós-Graduação e Inovação da Universidade Federal de Pelotas, pela iniciativa de criação e concessão de bolsa

de ações afirmativas, que possibilitou a realização do sonho de me tornar doutora.

Aproveito para agradecer ao Programa de Pós Graduação em Recursos Hídricos, bem como a todos os professores do mesmo, que através de suas aulas e ensinamentos engrandeceram de forma direta ou indireta este trabalho. Estendo os agradecimentos aos professores do PPG MACSA que colaboraram com a construção do meu saber.

Agradeço aos Professores Tirzah Moreira Siqueira, Claudia Liane Rodrigues de Lima, Dioni Glei Bonini Bitencourt, Luis Eduardo Akiyoshi Sanches Suzuki e Tamara Leitzke Caldeira Beskow, membros da banca examinadora que aceitaram com carinho e entusiasmo o convite de engradecer este trabalho e pelo tempo dispensado na avaliação deste, sou grata antecipadamente pelas contribuições e dedicação de cada um de vocês.

Por fim, agradeço a todos os servidores da UFPel, dos terceirizados ao reitor, pois sem o trabalho e dedicação de vocês a Universidade Federal de Pelotas não existiria. Por fim, agradeço a todos os meus parentes e amigos que direta ou indiretamente torceram por mim durante este período de doutoramento.

Sou eternamente grata a todos os supracitados.

## Epígrafe

“-Já param para pensar que desde o momento de nossa concepção  
somos bombardeados por ondas?  
Tudo é transmitido através de ondas, ou seja, elas são parte integrante  
do nosso cotidiano! Os sons, os objetos que enxergamos, até mesmo  
nossos próprios pensamentos são transmitidos por ondas!  
Pensem no mar, onde as ondas podem ser grandes, médias ou  
pequenas e poderemos ver que elas são capazes de se adaptar a  
qualquer local do mar (profundezas ou na costa), porém, apresentam a  
mesma forma, mas diferentes larguras, alturas e comprimentos.  
Pensando nesta elasticidade e da adaptabilidade de uma onda e que  
ela pode ser descrita através de uma fórmula matemática e assim, ser  
incorporada para mensurar ou representar diferentes coisas. Por  
exemplo, atualmente ela é utilizada na medicina para analisar os  
mínimos detalhes de falha que pode ocorrer em um eletrocardiograma e  
assim identificar uma possível doença, mas não só nesta área como na  
automação e controle buscando falhas nos sistemas, ou nas  
geotecnologias, minimizando erros em imagens de satélites, dentre  
tantas outras aplicações!  
Na minha tese eu busquei incorpora a formulação matemática de uma  
onda, denominadas de Wavelets, nos estudos do movimento da água  
no solo esse caracterizado como condutividade hidráulica de solo  
saturado...”  
(Adaptação do texto base da apresentação do evento 3MT).

---

“Que o impossível,  
improvável,  
inconcebível  
se torne crível.”  
(Alexandre Rampazo)

## Resumo

CENTENO, Luana Nunes. **Modelos de espaço de estados e análise em Wavelets no estudo do relacionamento espacial entre atributos físico-hídricos do solo e atributos topográficos em escala de bacia hidrográfica.** Orientador: Luís Carlos Timm. 2020. 200f. Tese (Doutorado em Recursos Hídricos) - Programa de Pós-Graduação em Recursos Hídricos. Engenharia de Recursos Hídricos, Universidade Federal de Pelotas, Pelotas 2020.

**Resumo:** As ferramentas estatísticas que consideram a posição e a possível dependência entre as observações de variáveis no campo têm sido aplicadas em pequenas áreas agrícolas e não em escala de bacia hidrográfica. Assim, o presente trabalho teve como objetivo avaliar o potencial de ferramentas da Análise de Séries Temporais/Espaciais em caracterizar e identificar a estrutura de variabilidade espacial de atributos físico-hídricos do solo e de atributos topográficos bem como no estudo do relacionamento entre eles em uma transeção espacial de 15 km construída na bacia hidrográfica do Arroio Fragata, a partir da seção de controle da Ponte Passo dos Carros (BHAF – PPC), localizada no município de Pelotas (RS). Nesta transeção foram demarcados 100 pontos, equidistantes entre si 150 m, onde amostras de solo, com estrutura deformada e preservada, foram coletadas na camada de 0-0,20 m de profundidade para determinação das frações texturais, densidade do solo, porosidade total, macroporosidade, condutividade hidráulica do solo saturado e carbono orgânico. De posse do modelo digital de elevação hidrológicamente consistente (MDEHC) foram obtidos em cada ponto amostral atributos topográficos, a saber: elevação, declividade e aspecto. A estatística clássica foi aplicada a todos os conjuntos de dados para a obtenção das medidas de posição, de dispersão e da forma da dispersão. Também foi aplicado o teste de *Kolmogorov-Smirnov* para verificar a normalidade de cada conjunto de dados. Para caracterizar e identificar a estrutura de variabilidade espacial de cada atributo ao longo da transeção espacial a função de autocorrelação foi calculada. A correlação espacial entre as variáveis foi calculada por meio da função de crosscorrelação. O relacionamento entre as variáveis foi estudado por modelos de espaço de estados envolvendo o mesmo conjunto de variáveis físico-hídricas do solo e topográficas. A caracterização e quantificação das possíveis correlações multi-espaciais entre os atributos físico-hídricos do solo e os atributos topográficos foram também avaliadas usando as transformadas de Wavelets. Por meio destas ferramentas foi possível concluir que a abordagem em espaço de estados se mostrou uma ferramenta eficaz para descrever as relações espaciais, bem como que as transformadas de Wavelets são ferramentas promissoras no intuito de caracterizar e quantificar as correlações multiespaciais entre a condutividade hidráulica do solo saturado e os atributos físico-hídricos do solo e topográficos e o tipo de uso do solo ao longo da transeção espacial de 15 km construída na Bacia do Arroio Fragata. A substituição da variável macroporosidade do solo pelo tipo de uso do solo como variável representativa da estrutura do solo nos modelos de espaço de estados deve ser melhor avaliada em futuros estudos em escala de bacia hidrográfica.

**Palavras-Chaves:** Bacia hidrográfica Arroio Fragata. Condutividade hidráulica de solo saturado. Variabilidade espacial do solo. Escala e localização específica. Tipos de uso do solo.

## Abstract

CENTENO, Luana Nunes. **State-space models and Wavelet analysis in the study of the spatial relationship between soil hydro-physical and topographic attributes at watershed scale.** Advisor: Luís Carlos Timm. 2020. 200f. Thesis (Doctorate Degree Water Resources) - Water Resources Post-Graduate Program. Engineering Water Resources, Center of Technological Development, Federal University of Pelotas, Pelotas 2020.

**Abstract:** The statistical tools that consider the position and the possible dependence between the observations of variables in the field have been applied at small scales and not at watershed scales. Thus, this study aimed to evaluate the potential of statistical tools from the Time Series Analysis to characterize and identify the spatial variability structure of soil hydro-physical and topographic attributes as well as to study the relationship between them in the Fragata River Watershed (FRW), Pelotas, Southern Brazil. From the Passo dos Carros control section (FRW - PPC) a 15 km-spatial transect was established in which 100 points, 150 m equidistantly spaced, were demarcated. Undisturbed and disturbed soil samples were collected in the 0-0.20 m soil layer to determine textural fractions, soil bulk density, total porosity, macroporosity, saturated soil hydraulic conductivity and soil organic carbon. Using the hydrologically consistent digital elevation model (MDEHC), topographic attributes were obtained at each sampling point, namely: elevation, slope, and aspect. Classical statistics were applied to all data sets to calculate position, dispersion, and shape measures of each data set. The Kolmogorov-Smirnov test was applied to verify the normality of each data set. To characterize and identify the spatial variability structure of each attribute along the spatial transect, the autocorrelation function was calculated. The spatial correlation between two variables was calculated using the cross-correlation function. The spatial relationship among variables was studied by state-space models and classical multiple regression models. The characterization and quantification of the possible multi-spatial correlations among all attributes were evaluated through Wavelet analysis. It was possible to conclude that the state-space approach proved to be an effective tool to describe the spatial relationships among all attributes as compared to multiple regression models at watershed scale. Further, Wavelet analysis showed to be a promising tool to characterize and quantify the multispatial correlations among all soil hydro-physical and topographic attributes along the 15 km-FRW spatial transect. The substitution of the soil macroporosity by the land-use system as a potential explanatory variable to represent the soil structure in the state-space models should be better assessed in future studies at watershed scale.

**Key-Words:** Fragata River Watershed. Hydraulic conductivity of saturated soil. Soil spatial variability. scale-location domain. land-use system.

## Lista de Figuras

|  |     |
|--|-----|
| Figura 1 - Seno e cosseno possuem período $2\pi$ .....   | 35  |
| Figura 2: Transformada de Fourier aplicada em cada segmento da série temporal. (a) Série temporal qualquer. (b) Aplicação da transformada de Fourier em cada parte do seguimento da série.....   | 38  |
| Figura 3: Exemplo da função delta de Dirac, com um fenômeno que sofreu uma mudança abrupta.....  | 41  |
| Figura 4: Representação do sinal da Wavelet Chapéu Mexicano. ....  | 45  |
| Figura 5: Representação do sinal de uma Wavelet de Haar.....   | 46  |
| Figura 6: Sinal de uma função escala de Daubechies. ....   | 47  |
| Figura 7: Sinal da Wavelet de Daubechies.....  | 47  |
| Figura 8: Representação de um sinal da Wavelet Morlet. ....  | 48  |
| Figura 10: Localização da bacia hidrográfica do arroio Fragata (BHAF), à montante da seção de Passo dos Carros (BHAF-PC).....  | 59  |
| Figura 11: Mapa das classes de solos e ilustração da transeção espacial construída para amostragem de solo na bacia do Arroio Fragata (BHAF-PC). ....  | 60  |
| Fig. 1 – Location of the study area in the South America, Brazil and Rio Grande do Sul state maps, land-use system map and the 15 km-spatial transect established in the Fragata River Watershed (FRW), outlet “Passo dos Carros”.....   | 69  |
| Fig. 2 – Spatial distribution along the 15 km-spatial transect for: (A) saturated soil hydraulic conductivity, Ksat and (B) elevation, Ele.....  | 78  |
| Fig. 2 – Spatial distribution along the 15 km-spatial transect for: (C) soil slope, Slo and (D) soil organic carbon content, SOC .....   | 79  |
| Fig. 3 – State-space models for saturated soil hydraulic conductivity (log Ksat), when 50% of Ksat observations were not considered in the estimation, based on underlying processes manifested in: (A) the individual values of soil organic carbon (SOC), clay content (Clay), soil macroporosity (Macro) and soil bulk density (Bd) (Table 6). .... | 101 |
| Fig. 4 - State-space models for saturated soil hydraulic conductivity (log Ksat), when 50% of Ksat observations were not considered in the estimation, based on underlying processes manifested in: (A) the individual values of soil macroporosity (Macro) (Table 6). ....  | 103 |
| Fig. 5 - Measured and estimated saturated soil hydraulic conductivity ( $\log_{10}$ Ksat) for the pedotransfer function developed by Vereecken et al. (1990). ....   | 105 |
| Fig 1. Location of the study area in the South America, Brazil and Rio Grande do Sul state maps, hydrologically consistent digital elevation model (HCDEM) map and the 15 km spatial transect established in the Fragata River Watershed (FRW), outlet “Passo dos Carros”.....   | 126 |
| Fig 2. Spatial distribution of all studied variables along the 15 km-spatial transect: (a) Saturated soil hydraulic conductivity (Ksat) and (b) Elevation. ....  | 135 |
| Fig 3. Box-plot for saturated soil hydraulic conductivity values and land-use systems. ....  | 142 |
| Fig 4. Local Wavelet spectrum of all studied variables: (a) Saturated soil hydraulic conductivity (Ksat) and (b) Elevation. Thick solid lines indicate the 5% significance level against the background red noise and thin solid lines indicate the cone of influence (COI) where edge effects might distort the Picture.....                          | 145 |
| Fig 5. Wavelet coherency among Ksat and other soil, topographic and land-use variables: (a) Ksat and Elevation and (b) Ksat and Soil slope. Arrows pointing to the right mean that both spatial series are in phase (positive correlation), while arrows pointing to the left, mean a negative correlation between both series. ....                   | 152 |
| Fig. 6. Multiple Wavelet coherency among Ksat, macroporosity, and land-use system (a).....   | 157 |

## Lista de Tabelas

### **Artigo 1**

|   |     |
|---|-----|
| <b>Table 1</b> – Curve number values for existing combinations of soil and land-use in the FRW-PC.....  | 72  |
| <b>Table 2</b> – Descriptive statistics and the non-parametric Kolmogorov-Smirnov test for all values of saturated soil hydraulic conductivity and the other soil and topographic attributes and land-use systems along the 15 km-Fragata River Watershed spatial transect .....  | 83  |
| <b>Table 3</b> – Spearman's correlation coefficient values among saturated soil hydraulic conductivity and the other soil and topographic attributes and land-use systems along the 15 km-Fragata River Watershed spatial transect .....  | 84  |
| <b>Table 4</b> – Mean values of saturated soil hydraulic conductivity, soil organic carbon, macroporosity, soil bulk density, clay and sand contents at each land-use system identified along the 15 km-Fragata River Watershed spatial transect ...  | 86  |
| <b>Table 5</b> – (A) Autocorrelation [ $r(j)$ ] and (B) crosscorrelation [ $r_c(j)$ ] values for Ksat and all co-variables that compose the study along the 15 km-spatial transect. Data sets were arranged in the north-west (from location 1 to location 100) and in the west-north (from location 100 to location 1) directions .....                    | 87  |
| <b>Table 6</b> – State-space equations of saturated soil hydraulic conductivity (Ksat expressed as $\log_{10}$ ) using all combinations of selected soil and topographic attributes and land-use systems, and $r^2$ values from linear regression between estimated and measured values of $\log$ Ksat.....   | 91  |
| <b>Table 7</b> - Linear regression equations of saturated soil hydraulic conductivity (Ksat expressed as $\log_{10}$ ) using all combinations of selected soil and topographic attributes and land-use systems, and $r^2$ values from linear regression between estimated and measured values of $\log$ Ksat.....   | 96  |
| <b>Table 8</b> - Results of the principal component analysis applied to the soil attributes (clay content soil organic matter, macroporosity and soil bulk density) .....   | 99  |
| <b>Table 9</b> - State-space equations of saturated soil hydraulic conductivity (Ksat expressed as $\log_{10}$ ) using all combinations considering the selected topographic attribute, land-use systems and principal component data sets (PC1 and PC2), and $r^2$ values from linear regression between estimated and measured values of $\log$ Ksat..... | 100 |

### **Artigo 2**

|   |     |
|---|-----|
| <b>Table 1</b> - Classical statistics applied to all soil and topographical attributes along the 15 km-Fragata River Watershed spatial transect.....  | 140 |
| <b>Table 2</b> – Spearman's correlation coefficient values between the soil saturated hydraulic conductivity and the other soil and topographic attributes evaluated along the 15 km-Fragata River Watershed spatial transect ..... | 141 |

## Sumário

|  |     |
|--|-----|
| 1. Introdução .....  | 15  |
| 2. Objetivos .....   | 17  |
| 2.1. Objetivo Geral .....  | 17  |
| 2.2. Objetivos Específicos .....   | 17  |
| 3. Hipóteses .....   | 18  |
| 4. Revisão da Literatura .....   | 19  |
| 4.1. Wavelets sem formulação matemática .....  | 19  |
| 4.1.2. O antecessor da análise de Wavelet: Jean Fourier .....  | 19  |
| 4.1.3. Fourier e suas contribuições sobre funções trigonométricas .....                                      | 20  |
| 4.1.4. O mundo das Wavelets: através da aplicação de Morlet .....  | 21  |
| 4.1.5. Wavelets: um mundo microscópico .....   | 23  |
| 4.1.6. Teoria das Wavelets e suas compilações .....  | 25  |
| 4.1.7. Wavelet Mãe .....   | 25  |
| 4.1.8. A transformação rápida da Wavelet .....   | 26  |
| 4.1.9. Wavelet e suas aplicações: uma visão sistêmica .....  | 27  |
| 4.2. Formulação matemática e definições das ferramentas estatísticas .....                                   | 29  |
| 4.2.1. A função de autocorrelação .....  | 29  |
| 4.2.2. A função de correlação cruzada (crosscorrelation) .....   | 31  |
| 4.2.3. Modelos em Espaço de Estados .....  | 31  |
| 4.2.4. Séries e Transformadas de Fourier e Análise em Wavelets .....   | 34  |
| 4.2.4.1. Funções periódicas .....  | 34  |
| 4.2.4.2. Séries de Fourier .....   | 35  |
| 4.2.4.3. Forma Exponencial das séries de Fourier .....   | 36  |
| 4.2.4.4. Transformada de Fourier .....   | 377 |
| 4.2.4.5. Transformada Janelada de Fourier .....  | 37  |
| 4.2.4.6. Funções de Auto e Crosscorrelação a partir da Convolução .....                                      | 39  |
| 4.2.4.7. Função Delta de Dirac .....   | 40  |
| 4.2.4.8. Densidade do espectro de potência .....   | 41  |
| 4.2.4.9. Transformadas de Wavelets .....   | 43  |
| 4.2.4.10. Wavelet de Morlet .....  | 48  |
| 4.2.4.11. Espectro de Energia das Wavelets .....   | 48  |
| 4.2.4.12. Transformada cruzada em Wavelets .....   | 49  |
| 4.2.4.13. Ângulo de Fase .....   | 50  |
| 4.3. Estado da arte dos assuntos abordados neste estudo .....  | 52  |
| 5. Material e Métodos .....  | 59  |
| 5.1. Bacia hidrográfica envolvida no estudo .....  | 59  |
| 5.2. Levantamento e processamento de dados básicos da BHAF .....   | 59  |
| 5.3. Amostragem de solo ao longo da transeção espacial e atributos físicohídricos determinados .....         | 61  |
| 5.4. Atributos topográficos obtidos em cada ponto amostral das transecções espaciais .....                   | 61  |
| 5.5. Análises estatísticas .....   | 61  |
| 5.5.1. Caracterização e identificação da estrutura de variabilidade espacial de cada atributo estudado ..... | 61  |
| 5.5.2. Comparação do desempenho dos modelos de espaço de estados e dos modelos de regressão múltipla .....   | 62  |

|  |     |
|--|-----|
| 5.5.3. Caracterização e quantificação das correlações multi-espaciais entre os atributos do solo e os topográficos usando análises em Wavelets ..... | 62  |
| 6. Resultados e Discussão .....  | 63  |
| 6.1. Artigo 1 .....  | 63  |
| Abstract .....   | 63  |
| Introduction .....   | 65  |
| Materials and methods .....  | 68  |
| Characterization of the area .....   | 68  |
| Soil and topographic attributes .....  | 70  |
| Land-use map .....   | 713 |
| Descriptive statistics .....   | 72  |
| State-space approach .....   | 72  |
| Multivariate statistical analysis .....  | 75  |
| Results and Discussion .....   | 76  |
| Conclusions .....  | 107 |
| Acknowledgments .....  | 108 |
| References .....   | 109 |
| 6.2. Artigo 2 .....  | 120 |
| Abstract .....   | 122 |
| Keywords: .....  | 123 |
| 1 Introduction .....   | 123 |
| 2 Material and Methods .....   | 125 |
| 2.1 Description of study area .....  | 125 |
| 2.2 Characterization of the study area and soil sampling .....   | 126 |
| 2.3 Land-use map .....   | 128 |
| 2.4 Wavelet analyses .....   | 129 |
| 3 Results .....  | 133 |
| 4 Discussion .....   | 158 |
| Conclusions .....  | 161 |
| Acknowledgments .....  | 162 |
| References .....   | 162 |
| 7. Conclusões .....  | 171 |
| Referências Bibliográficas .....   | 172 |

## **1. Introdução**

Os atributos físicos, químicos e biológicos do solo diversificam amplamente no espaço. O material de origem e os fatores de formação do solo distinguem-se devido às suas características intrínsecas e como consequência os atributos do solo variam na paisagem. A intensidade dessa variação em uma área depende das condições ambientais e como estas atuam sobre os atributos do solo ao longo do tempo bem como o manejo adotado (VIEIRA; DECHEN, 2010).

A variabilidade espacial dos atributos do solo tem sido alvo de estudos desde o início do século XX. Inicialmente, a variabilidade era estudada por meio de ferramentas da estatística clássica, como média, variância e coeficiente de variação, sem considerar a posição das observações no espaço, e recomendava-se o uso de métodos estatísticos clássicos, os quais, exigem que a variável sob investigação tenha distribuição normal e seja espacialmente independente (VIEIRA; DECHEN, 2010).

Ferramentas estatísticas da Análise de Séries Temporais/Espaciais (autocorrelogramas, crosscorrelogramas, modelos de espaço de estados, etc.) e da Geoestatística (semivariogramas, semivariogramas cruzados, krigagem, etc.), que consideram a posição no espaço (ou no tempo) e a possível dependência entre as observações da variável em estudo, têm sido aplicadas no intuito de estudar a variabilidade das diferentes variáveis que compõem o sistema Solo-Planta-Atmosfera (REICHARDT; TIMM, 2020). Neste intuito, Nielsen e Wendoroth (2003), sugerem uma amostragem ao longo de uma transeção e/ou de uma malha para avaliar a estrutura de variabilidade espacial ou temporal e as relações entre os atributos do solo.

A identificação e quantificação da variabilidade espacial e temporal constitui-se uma ferramenta valiosa, haja vista que permite definir o intervalo adequado de amostragem, reduzindo os custos do monitoramento de dados de campo, sobretudo em estudos associados à simulação hidrológica (HUPET; VANCLOOSTER, 2004; SCHNEIDER et al., 2008), dentre outros. A realização de estudos hidrológicos em bacias hidrográficas surge da necessidade de se compreender o funcionamento do balanço hídrico, dos processos que controlam o movimento, a quantidade e a qualidade da água (ANDRADE et al., 2013).

Neste intuito, a identificação e quantificação da estrutura de variabilidade espacial e temporal dos atributos do solo tornam-se importantes para um melhor entendimento da dinâmica da água no sistema solo-planta-atmosfera.

Na maioria das situações, a aplicação de ferramentas da Análise de Séries Temporais/Espaciais no estudo da variabilidade espacial dos atributos do solo tem sido conduzida em pequenas áreas agrícolas como os trabalhos de Jia et al. (2011), Oliveira et al. (2011), Timm et al. (2003), dentre outros, e não em escala de bacia hidrográfica (BH), que tem sido a unidade adotada para o planejamento e gestão de recursos naturais. Dentre as bacias hidrográficas localizadas no sul do estado do Rio Grande do Sul (RS), a do arroio Fragata (BHAF) é estratégica para o desenvolvimento econômico e social da região. Ademais os cursos d'água principais da BHAF é um importante afluente do canal São Gonçalo, que abastece o município de Rio Grande – RS e ainda é uma via navegável importante que liga a laguna dos Patos à Lagoa Mirim.

Em virtude da importância econômica e social e a carência de estudos na bacia hidrográfica supracitada há a necessidade da atenção de pesquisadores em especial para estudos relacionados a um melhor entendimento do meio físico. Visando a aplicação de ferramentas estatísticas no intuito de caracterizar a variabilidade espacial dos atributos físico-hídricos do solo e dos atributos topográficos bem como do relacionamento entre eles em nível de escala de bacia hidrográfica, possibilitando, por exemplo, a utilização de modelos hidrológicos na região visando o gerenciamento dos recursos hídricos.

## **2. Objetivos**

### **2.1. Objetivo Geral**

O objetivo principal deste estudo foi avaliar o potencial de ferramentas estatísticas da Análise de Séries Temporais/Espaciais em caracterizar e identificar a estrutura de variabilidade espacial de atributos físico-hídricos do solo e de atributos topográficos, bem como no estudo do relacionamento entre eles, em escala de bacia hidrográfica, em uma transeção espacial de 15 km construída na Bacia do Arroio Fragata, a montante da seção de controle Passo dos Carros.

### **2.2. Objetivos Específicos**

- Caracterizar e identificar a estrutura de variabilidade espacial dos atributos físico-hídricos do solo e dos atributos topográficos determinados ao longo da transeção espacial construídas na Bacia do Arroio Fragata, usando ferramentas da Análise de Séries Temporais/Espaciais;
- Comparar o desempenho dos modelos de espaço de estados no estudo do relacionamento entre os atributos físico-hídricos do solo e os atributos topográficos com modelos de regressão estatística múltipla (modelos globais);
- Caracterizar e quantificar as correlações multi-espaciais entre os atributos físico-hídricos do solo e os atributos topográficos ao longo da transeção construídas na Bacia do Arroio Fragata, usando Wavelets.

### **3. Hipóteses**

- Ferramentas estatísticas da Análise de Séries Temporais/Espaciais podem ser usadas para caracterizar e identificar a estrutura de variabilidade espacial de atributos físico-hídricos do solo e de atributos topográficos em escala de bacia hidrográfica;
- Modelos de espaço de estados podem ser usados para estudar o relacionamento entre atributos físico-hídricos do solo e atributos topográficos em escala de bacia hidrográfica;
- O uso de modelos de espaço de estados descreve melhor o relacionamento das variáveis em estudo quando comparados com o uso dos modelos de regressão estatística múltipla;
- As Wavelets podem ser usadas para caracterizar e quantificar as correlações multi-espaciais entre atributos físico-hídricos do solo e atributos topográficos.

## **4. Revisão da Literatura**

### **4.1. Wavelets sem formulação matemática**

Neste tópico será apresentado o referencial teórico baseado nos autores Addison (2016), Hubbard (1998) e Mallat (2008). Pretende-se apresentar como surgiram as Wavelets, bem como sua relação com os demais campos da Ciência.

#### **4.1.2. O antecessor da análise de Wavelet: Jean Fourier**

A história das Wavelets embora extremamente difundida e partilhada entre as Ciências, teve seu princípio na análise de Fourier. Sendo que, Fourier é um ponto de partida lógico, sua influência na matemática, na ciência e em nossas vidas diárias tem sido incalculável.

A análise de Fourier foi desenvolvida pelo matemático Jean Baptiste Joseph Fourier, que nasceu em 1768, em Auxerre na França e que ficou órfão aos 10 anos de idade.

Após a morte de seus pais, Fourier continuou frequentando a escola e, em 1780, ingressou na academia militar real de Auxerre, onde aos 13 anos ficou fascinado pela matemática. Diz-se que durante o dia ele secretamente colecionava tocos de velas, e que à noite, quando todo mundo dormia, ele acordava e se arrastava até a sala de aula onde acendia as velas e passava longas horas trabalhando em na resolução de problemas matemáticos.

Contudo, ao final de seus estudos, mesmo apresentando extremas habilidades com números, seu pedido de ingressar no exército foi rejeitado (segundo conta a literatura, Fourier foi rejeitado pelo exército porque não havia nascido em família nobre e, portanto, inelegível) mesmo sendo considerado um gênio dos números, sendo comparado ao grande Isaac Newton.

A partir de então, tornou-se cada vez mais comprometido com a causa de estabelecer um “governo” livre isento de reis e padres, e em 1793 ingressou no comitê revolucionário de Auxerre, neste período foi preso duas vezes, sob acusação de terrorismo, pois era extremamente preocupado com as questões sociais, o que na época era contrário ao “governo”.

Destaca-se ainda que, após a Revolução Francesa, Fourier lecionou matemática em Paris, depois acompanhou Napoleão no Egito e serviu como

secretário permanente do Instituto do Egito. Mais tarde, ele escreveu um livro sobre o Egito; ainda hoje algumas pessoas o conhecem como egíptólogo e desconhecem suas contribuições para a matemática e a física.

Ao retornar para à França em 1802, Napoleão o nomeou prefeito do departamento de Isere. Ele serviu como prefeito por 14 anos, em Grenoble, ganhando a reputação de administrador capaz; uma de suas realizações foi convencer 37 comunas a trabalharem juntas para drenar cerca de 8094 hectares de pântanos que haviam causado epidemias de febre, tarefa que, segundo Cousin, exigia todo o seu tato e "uma paciência inesgotável". Por fim, ele encontrou um porto seguro no Bureau da estatística em Paris onde foi eleito para a Academia de Ciências.

Paralelamente aos deveres administrativos e ao seu isolamento de Paris por muitos anos, Fourier conseguiu prosseguir em sua pesquisa científica com relação a matemática, que o tornou conhecido entre inúmeros cientistas, técnicos e engenheiros. Essa fama baseia-se em seu livro publicado em 1822, intitulado *La Theorie Analytique de la Chaleur* (A teoria analítica de calor). No livro supracitado, Fourier substanciou uma maneira prática de extrair soluções de equações lineares: parciais e diferenciais, as definidas pela segunda lei de Newton, no século XVII.

A partir de então suas descobertas dominaram a análise matemática por cem anos, tendo ramificações surpreendentes para a teoria dos números e probabilidade. Para se entender a grandiosidade de sua descoberta, destaca-se que praticamente toda vez que cientistas modelam sistemas ou fazem previsões, eles usam a análise de Fourier. Neste sentido, suas descobertas estão inseridas atualmente desde programações lineares, cristalografia e a inúmeros dispositivos de radiofrequências, máquinas de raios-x, dentre outros.

#### **4.1.3. Fourier e suas contribuições sobre funções trigonométricas**

Há duas partes na contribuição de Fourier: primeiro, uma matemática afirmativa mais tarde comprovada por Johann Peter Gustav Lejeune Dirichlet (que apresentou a definição formal de função); e segunda, uma explicação prática a respeito de função periódica, ou seja, que esta pode ser representada como uma soma de senos e cossenos denominado a partir de então de série de Fourier.

De forma geral, definiu-se que qualquer curva que se repita periodicamente, não importa o quanto irregular seja, pode ser expressa como uma série de soma de funções senos e cossenos. Sendo assim, a curva irregular (“matemática afirmativa”) e a soma dos senos e cossenos (“matemática prática”) são duas representações diferentes do mesmo objeto, ou seja, como ver uma mesma palavra em idiomas diferentes.

Na prática multiplica-se os senos e os cossenos por um coeficiente (que é a sua amplitude), para que os termos da série se adicionem ou se anulem quando é alterada a fase, por um valor específico, das funções periódicas. Sendo assim, por meio da série de Fourier, pode-se reconstruir a função original, ou seja, como em uma tradução de idioma onde nenhuma informação é perdida, apenas transformada.

No ano de 1807, Fourier mostrou que praticamente qualquer função periódica pode ser expressa como uma soma infinita de uma série de senos e ou cossenos. As realizações de Fourier contribuíram significativamente para mudanças na maneira de matemáticos pensaram sobre funções. Sendo esta, uma simples maneira de resolver certas equações diferenciais, pavimentando assim, o caminho para a tecnologia digital, incluindo computadores e discos compactos. Ademais, a análise de Fourier também é uma linguagem natural para a mecânica quântica.

A transformada de Fourier traduz um sinal através de uma maneira simples e “real”, ou seja, transformando um sinal que varia no tempo (ou no espaço) em uma nova função, mostrando por meio desta, quanto de cada frequência o sinal contém.

Posteriormente estabeleceu-se a transformada janelada de Fourier, a qual se baseia na ideia de estudar as frequências de um sinal segmento por segmento. Onde tornou possível “simbolicamente” limitar o período de tempo durante o qual algo está acontecendo, contudo, a descrição mais prática de ocorrência de um fenômeno tornou-se possível por meio das Wavelets.

#### **4.1.4. O mundo das Wavelets: através da aplicação de Morlet**

Existem diversas vertentes a respeito da história das Wavelets, a saber: tendo como base a física, definiram-na como pequenas ondas, já na matemática a Wavelet foi denominada como “decomposições atômicas”, servindo para

estudar diferentes funções no espaço. Cabe destacar ainda que outros pesquisadores desenvolveram Wavelets, que chamaram de “funções auto similares de Gabor”, com o intuito de modelar sistemas digitais.

Entretanto, como foi a função incorporada neste estudo (função de Morlet), tomar-se-á como ponto de partida o trabalho de Jean Morlet, um geofísico da companhia petrolífera francesa Elf-Aquitaine, que desenvolveu Wavelets como ferramenta para prospecção de petróleo, porém as mesmas nunca foram utilizadas para esta finalidade.

A maneira padrão de procurar petróleo subterrâneo, na década de 1960, era enviar vibrações ou impulsos ao solo e analisar seus ecos. Esta análise deveria dizer o quão profunda e espessa as várias camadas são e de que elas são feitas. Destaca-se que ecos de altas frequências correspondem as camadas finas, e baixas frequências as camadas grossas. Porém, estes sinais produzidos interferiam entre si tornando confusa a procura por petróleo.

Para extrair informações desse emaranhado de ecos, a análise de Fourier foi incorporada em todo o sinal. À medida que computadores mais poderosos se tornaram disponíveis, grandes janelas foram inseridas em diversos seguimentos no sinal e colocadas cada vez mais próximas até ocorrer a sobreposição. Porém, em um dado momento, não havia melhora na distinção dos ecos.

Sendo assim, Morlet objetivava uma definição local mais refinada; em particular, para se ter acesso a informações sobre camadas de diferentes espessuras. Para fazer isso, por volta de 1975, Morlet baseou-se na representação da transmissão de sinais de Gabor, criadas cerca de 30 anos antes, usando Análise de Fourier. A grande desvantagem deste sistema era de ser impreciso sobre o tempo nas altas frequências. Sendo necessário que a janela fosse reduzida, o que significava perder todas as informações sobre baixas frequências.

Outra desvantagem do uso da análise de Fourier janelada foi que ao contrário da análise clássica de Fourier, não havia maneira numérica de reconstruir o sinal. Sendo assim, objetivando contornar esta limitação Morlet em vez de manter o tamanho da janela fixa e preenchida com oscilações de diferentes frequências, fez o inverso: manteve o número de oscilações na janela constante e variou a largura da janela, esticando ou comprimindo as mesmas.

Um fato interessante é que quando ele aumentou o comprimento da largura da janela, as oscilações no interior foram esticadas, diminuindo sua "frequência"; quando ele encurtou as oscilações dentro foram também encurtadas, produzindo frequências mais altas. Após observar que essas novas funções tinham semelhanças, na forma, mesmo ao sofrerem dilatação e compressão, Morlet as chamou de "Wavelets de forma constante", para diferenciá-las das funções de Gabor.

Através de uma pequena calculadora, Morlet desenvolveu métodos básicos para decompor um sinal em Wavelets e reconstrui-los. Porém, os demais estudiosos da época não acreditaram em seus resultados. Em meados de 1981, Morlet pediu a Roger Balian, um físico que havia sido seu colega de classe na *Escole Polytechnique*, para ajudá-lo a corrigir seu primeiro trabalho sobre Wavelets. Balian declarou não ser capaz de auxiliá-lo, mas lhe apresentou o especialista Alex Grossmann em Marselha.

Para validar matematicamente seus resultados empíricos, Grossmann e Morlet demonstraram através de seus computadores que quando as Wavelets são usadas para representar um sinal, a "energia" do sinal é inalterada. Isso significa que é possível transformar um sinal em uma transformada de Wavelet e receber exatamente o mesmo sinal novamente, sendo esta uma condição crucial.

Ao contrário da transformada de Fourier, que gera um sinal com uma variável (tempo ou espaço) e outra função com outra variável (frequência ou escala), a transformada de Wavelet produz uma transformação com duas variáveis simultaneamente, tempo e frequência (espaço e escala). Ademais, Morlet e Grossmann reconstruíram o sinal usando uma única integral, e após vários anos constataram que o erro desta era zero.

#### **4.1.5. Wavelets: um mundo microscópico**

Conforme descrito anteriormente, as Wavelets são uma extensão da análise de Fourier. O objetivo é transformar as informações de um sinal em números (coeficientes) que podem ser manipulados, armazenados, transmitidos, analisados ou usados para reconstruir o sinal original.

A abordagem básica nas transformadas de Fourier e Wavelets é a mesma, ou seja, os coeficientes descrevem de que maneira a função em análise

(senos e cossenos ou Wavelets) possa ser modificada para reconstruir um sinal qualquer. Sendo assim, pode-se literalmente construir o sinal incorporando Wavelets de diferentes tamanhos, em diferentes posições, assim como se pode construir um sinal adicionando senos e cossenos. A técnica subjacente ao cálculo dos coeficientes é a mesma, ou seja, o sinal e a função de análise são multiplicados juntos, e a integral do produto é computada.

Para o envelope (que definição da forma) da Wavelet, Morlet usou a função gaussiana, bem como a função de Gabor na análise de Fourier janelada. Assim sendo, ao “comprimir” ou “esticar” a Wavelet, altera-se a frequência. Com isso, é possível utilizar-se de uma pequena janela para compreender as baixas frequências, procedimento este denominado de *multiresolution* (multiresolução).

As Wavelets foram denominadas como "microscópio matemático", pois se estuda o sinal primeiramente em uma escala grosseira para assim se obter uma imagem geral e posteriormente em escalas maiores para ver detalhes mais finos. Isso possibilita ao pesquisador um “olhar” mais crítico e atento aos pequenos detalhes existentes no sinal.

Destaca-se que as escalas estão relacionadas ao número de Wavelets usadas, ou seja, ao número de vezes em que o sinal é amostrado. E na natureza peculiar das Wavelets, o resultado de sua "forma constante", é que resolução, escala e frequência se alteram simultaneamente.

Todos os coeficientes em todas as escalas apresentam uma qualidade representativa da imagem ou função do sinal. Sendo assim, em contraponto com o que ocorre nas séries de Fourier, os coeficientes da série Wavelets traduzem as propriedades da função ou distribuição de maneira simples e precisa. Não apenas porque as Wavelets possibilitam olhar atentamente os detalhes de um sinal, mas também porque eles codificam apenas alterações. Sendo assim, um coeficiente da Wavelet mede a correlação entre a Wavelet (com seus picos e vales) e o segmento correspondente do sinal. Uma forte correlação significa que existe um pequeno sinal que aparece na Wavelet. Assim como, expansões (dilatações) constantes fornecem coeficientes de Wavelet com o valor zero. Por definição, uma Wavelet tem uma integral zero quando a metade da área que circunda é positivo e a outra metade negativa. Multiplicando esta Wavelet por uma constante muda as partes positivas e negativas igualmente, contudo a integral permanece zero.

Em suma, neste estudo a análise da Wavelet será uma ferramenta empregada para descrever a sensibilidade dos recursos naturais à mudança. Ou seja, é como a resposta do homem em relação a velocidade. O corpo humano é apenas sensível às acelerações, não à velocidade. Enquanto a velocidade de um trem ou avião é constante, não é possível distinguir se o mesmo está em movimento ou em repouso. Essa característica permite que as Wavelets compactem informações.

Normalmente, um sinal contendo cerca de 100.000 valores podem ser reduzidos para 10.000 coeficientes de Wavelet, sendo que as iguais a zero são automaticamente retiradas, ou seja, é uma leitura inteligente de sinais indo direto para o essencial, sendo esta definida como Wavelets discreta.

Entretanto, utiliza-se da Wavelet contínua quando é necessária a reconstrução perfeita do sinal, estudando o sinal em resoluções e deslocando ao longo de todos os valores, não apenas os discretos.

#### **4.1.6. Teoria das Wavelets e suas compilações**

A literatura matemática sobre Wavelets já existia em 1986, algumas desenvolveram-se antes mesmo que a Wavelet fosse inventada, porém, sem a teoria. Mas esta compilação de ideias tornou-se possível por meio de Stéphane Georges Mallat, um engenheiro eletricista e matemático francês, através de sua tese intitulada *Multiresolution representations and Wavelets*.

Mallat criou uma teoria geral sobre as Wavelets ao observar que os trabalhos que existiam de muitas formas diferentes e sob muitos nomes diferentes eram a mesma “Wavelet”, a saber: os algoritmos de pirâmide, usados no processamento de imagens, a codificação de sub-bandas no processamento de sinal, os filtros de imagem e quadratura na linguagem de processamento digital, enfim, todos estavam no mesmo cerne.

#### **4.1.7. Wavelet Mãe**

Em uma transformada Wavelet ortogonal, um sinal é analisado em escalas sempre variando por um fator de dois. Obedecendo, o teorema de Nyquist–Shannon, também conhecido simplesmente como teorema de Nyqui, onde cada vez que a frequência dobra, dobra-se também o número de Wavelets usadas para amostrar o sinal.

Uma “família” de pequenas Wavelets é composta didaticamente por três partes: a Wavelet *mother*, “uma função pai” (conhecida como escala da função) e uma grande variedade de Wavelets bebês, que variam em tamanho, contudo apresentam a mesma forma da Wavelet mãe.

A Wavelet pai não é essencial em uma transformada contínua de Wavelet, mas em uma transformada rápida sim, pois, dá o ponto de partida para a análise e torna possível calcular os coeficientes de Wavelet rapidamente. Por conseguinte, as Wavelets bebês, são clones da Wavelet mãe, apenas dilatadas ou comprimidas. Estas sofrem deslocamentos e transladamentos para assim percorrer as diferentes partes do sinal.

O primeiro passo quando as Wavelets percorrem o sinal é capturá-lo graficamente se for representativo. Para isso, divide-se o sinal para que cada um corresponda a uma função de escala e calcula-se um coeficiente para cada um, isso fornece valores médios. O tamanho da função de escala determina a melhor resolução usada para a análise. Em suma, a escala fornece o ponto de partida, ou seja, a menor escala com a qual se pode trabalhar.

#### **4.1.8. A transformação rápida da Wavelet**

Quando se leva em consideração a velocidade, sempre se pode decompor um sinal da Wavelets comparando com o sinal original, em cada escala, contudo iniciar sequencialmente esta comparação com o sinal original torna o processo lento.

Fazendo uma analogia, voltar ao sinal original seria o mesmo que, em um mapa de toda de viagem, estudar não apenas as principais cidades e rodovias, mas também córregos e estradas secundárias. Sendo assim, este é o motivo principal, citado em tópicos anteriores: analisar um sinal nas escalas mais finas para as mais grossas. Frente a isto, primeiramente deve-se dividir o sinal em duas partes, a saber: imagem imprecisa (*fuzzy*) do sinal e pequenos detalhes (a tendência geral do sinal e as flutuações). A imagem imprecisa ou suavizada é o sinal visto em meia resolução (com metade do número de amostras), é criado com a ajuda de um filtro passa-baixa associado à função de escala; isso é porque a função de escala às vezes é chamada de função de suavização. Os detalhes são os retoques finais que teriam que ser adicionados ao sinal

suavizado para reproduzir o sinal original. Eles são obtidos usando um filtro passa-alta associado às menores Wavelets.

Na sequência salva-se os primeiros coeficientes da Wavelet (codificação dos mínimos detalhes) e repete-se o procedimento, trabalhando desta vez com o sinal visto em meia resolução. Este sinal suavizado é dividido em mais duas partes; em um sinal ainda mais suave e novos detalhes, duas vezes maiores que o primeiro. Em um segundo passo os novos detalhes codificados pelas Wavelets e os valores médios calculados com a função de escala é baseada em segmentos do sinal duas vezes maiores. Contudo, o sinal analisado neste momento é suavizado, entretanto os seguimentos maiores contêm o mesmo número de pontos dos segmentos menores estabelecidos no início. O terceiro passo novamente leva metade do tempo que o segundo. Computa-se novamente metade dos coeficientes para produzir um sinal em uma escala original.

Assim toda a informação será compilada para os coeficientes da Wavelet, que são classificados por resolução, cada resolução corresponde a uma determinada escala e frequências. Contudo, se ocorrer a parada antes do sinal convergir, ou seja, se tornar inexistente, as informações restantes serão codificadas pela função de escala. Em suma o algoritmo rápido, ou a transformada rápida de Wavelet, está muito próxima dos algoritmos de pirâmide de Burt e Adelson, usando bancos de filtros.

#### **4.1.9. Wavelet e suas aplicações: uma visão sistêmica**

As Wavelets são adequadas para uma ampla gama de aplicações. Uma vez que pode ser informativo comparar os coeficientes da Wavelet, pois estes definem o grau de importância das variáveis em diferentes escalas. Sendo que coeficientes iguais a zero não indicam mudança e assim podem ser ignorados, mas diferentes de zero indicam que algo está acontecendo, seja um erro, uma mudança abrupta no sinal ou um ruído (que pode ser um erro). Destaca-se, entretanto, que se os coeficientes aparecem apenas em escalas finas, geralmente indicam as variações leves, contudo rápidas, que são em sua maioria características de um ruído. Enquanto Wavelets com resoluções mais grossas são muito parecidas e representam pequenas variações.

Os coeficientes que aparecem na mesma parte do sinal em todas as escalas indicam algo real. Se os coeficientes correspondentes ao mesmo instante do sinal não tenderem para zero em escalas finas, isso indica um salto no sinal. Por conseguinte, sinal menores, indicam que haverá uma descontinuidade no derivado; se eles diminuem rapidamente, o sinal é suavizado. É ainda possível usar o reescalonamento para aprimorar o sinal suavizado. Se ocorre os coeficientes em escalas grossa e média sugerem que existe uma singularidade, mas se for em altas frequências o ruído excede o sinal.

Como as Wavelets são sensíveis a mudança e podem restringir-se a partes específicas de um sinal, pesquisadores do *Institut du Globe* em Paris estão usando-as para estudar o efeito minúsculo na velocidade de rotação da Terra. Na corrente oceânica de El Nino, que flui ao longo da costa do Peru, enquanto pesquisadores da *University of Southampton* estão usando Wavelets para estudar as correntes oceânicas ao redor da Antártica. Na engenharia mecânica, os pesquisadores estão explorando o uso de Wavelets para detectar falhas nas engrenagens, analisando vibrações.

O fato dos erros em uma transformada de Wavelet não corromper a transformada inteira, pode ser útil em imagens médicas, pois quando a análise de Fourier é usada na ressonância magnética, qualquer movimento do órgão estudado distorce toda a imagem. O matemático Dennis Healy Jr. e o radiologista John Weaver no Dartmouth College descobriram que, com Wavelets, esses movimentos são drasticamente reduzidos.

Em astronomia, Wavelets estão sendo usadas para estudar as distribuições da matéria no universo, que durante anos se pensava ser aleatória, mas que agora parece ter uma estrutura complicada, com "vazios" e "bolhas". Deste modo, as Wavelets permitem identificar estruturas em diferentes escalas, podendo distinguir entre uma estrela e uma galáxia, o que não é sempre óbvio.

As Wavelets são ainda particularmente adequadas para se entender multifractais (estes necessitam de mais de um parâmetro de escala para a sua descrição), geralmente caracterizados por autossimilaridade em diferentes escalas. Isso porque as Wavelets são conforme descritos anteriormente são verdadeiros microscópio matemático, sendo assim, essa transformada nos convida a descer para as partes hierárquicas dos fractais.

## **4.2. Formulação matemática e definições das ferramentas estatísticas**

A aplicação de ferramentas da análise de séries temporais, nas últimas décadas, tem sido crescente, em estudos de variabilidade espacial de atributos do solo. Neste contexto entende-se como série temporal um conjunto de observações discretas, observadas em tempos equidistantes, que apresentam uma dependência serial entre si, ou seja, as observações são temporalmente dependentes (REICHARDT; TIMM, 2020).

Inicialmente, estas ferramentas estatísticas foram desenvolvidas para analisar uma sequência de dados coletados ao longo do tempo ( $t$ ), contudo, para uma série de dados coletados ao longo do espaço ( $x$ ) também são válidas, somente substituindo  $t$  por  $x$ . Sendo assim, ferramentas estatísticas como: autocorrelogramos, crosscorrelogramos, análise espectral, modelos autoregressivos (AR), modelos de média móvel (MA), modelo autoregressivo média móvel (ARMA), modelo autoregressivo integrado média móvel (ARIMA), modelos de espaço de estados, têm sido usadas para estudar a variabilidade espacial dos atributos do solo, e podem, potencialmente, conduzir a práticas de manejo que permitam um melhor entendimento do processo de interação entre o sistema solo-água-planta-atmosfera (WENDROTH et al., 2001; TIMM et al., 2003; OGUNWOLE et al., 2014; SHE et al., 2014).

Si (2008), apresenta uma revisão sobre ferramentas estatísticas que têm sido usadas para analisar a escala de variabilidade espacial de atributos do solo. Dentre elas, menciona a análise em *Wavelets*, que tem sido incorporada para estudar a variabilidade espacial de atributos do solo e possibilita a análise de uma série espacial simultânea tanto no domínio do tempo (ou espaço) como no domínio da frequência. Aplicações desta ferramenta neste intuito têm sido publicadas na literatura, dentre elas pode-se citar: Biswas e Si (2011) e Biswas et al. (2013).

### **4.2.1. A função de autocorrelação**

Uma das ferramentas estatísticas utilizadas para estimar a dependência linear espacial ou temporal de amostras vizinhas é a função de autocorrelação. De acordo com Nielsen e Wendoroth (2003), a função de autocorrelação é o principal diagnóstico de medida que indica se é possível obter uma interpretação

espacial ou temporal dos dados no local amostrado permitindo uma interpretação entre os processos espacial ou temporalmente correlacionados. A função é denominada de autocorrelação porque é uma correlação entre a mesma variável em posições diferentes. As coordenadas de amostragem não entram na sua análise, mas sua posição na transeção e sua ordenação são importantes (REICHARDT; TIMM, 2020). O grau de correlação linear entre os pares de valores, da variável aleatória discreta  $x$ , separados por uma dada distância, que é comumente chamado de *lag*, é obtido a partir da função de autocorrelação Equação 1 e 2.

$$C(j) = \frac{1}{(n - 1 - j)} \left[ \sum_{i=1}^{n-j} (x_i - \bar{x})(x_{i+j} - \bar{x}) \right] \quad (1)$$

$$\rho(j) = \frac{C(j)}{s^2} \quad (2)$$

Em que  $C(j)$  é a função de covariância entre o pares de valores defasados por  $j$ , que é chamado *lag*,  $\rho(j)$  o coeficiente de autocorrelação,  $n$  é o número de observações da variável,  $s^2$  a variância amostral e  $\bar{x}$  é o valor médio da variável aleatória  $x$ . O valor de  $\rho(j)$  é um número adimensional e está compreendido no intervalo [-1;1]. Para  $\rho(j)>0$ , significa que o passado influencia positivamente o futuro. Já quando  $\rho(j)<0$ , o passado influencia negativamente o futuro, fazendo estes eventos tomarem decisões opostas às do passado. Quando  $\rho(j)=0$  dizemos que não existe correlação linear entre o passado e o futuro, caracterizando um processo estocástico. O gráfico de  $\rho(j)$  em função de  $j$  é denominado autocorrelograma e expressa, portanto, a variação do coeficiente de autocorrelação em função da distância  $j$  que separa os eventos. Quando estes são fracamente correlacionados,  $\rho(j)$  decresce rapidamente para zero com o aumento de  $j$ . Já quando os eventos são fortemente correlacionados,  $\rho(j)$  decresce lentamente com o aumento de  $j$ .

Uma forma de calcular o intervalo de confiança (IC) para o coeficiente de autocorrelação é usar a função de probabilidade acumulada (Equação 3) p (p.e.,

$\pm 1,96$  para 95% de probabilidade) para a função de distribuição normalizada (DAVIS, 1986) e o número de observações (n):

$$IC = \pm \frac{p}{\sqrt{n}} \quad (3)$$

#### 4.2.2. A função de correlação cruzada (crosscorrelation)

A autocorrelação considera a relação de uma variável com ela mesma e a correlação cruzada é a relação entre duas variáveis aleatórias diferentes. Enquanto cada tipo de variável manifesta o seu próprio comportamento na autocorrelação espacial ou temporal, na correlação cruzada é revelada a distância no espaço ou no tempo em que duas variáveis estão relacionadas (NIELSEN; WENDROTH, 2003).

A função de correlação cruzada permite calcular a correlação entre duas variáveis aleatórias  $x$  e  $y$  em posições diferentes, isto é, correlação  $x_i$  com  $y_{i+j}$ , conforme Equação 4 (REICHARDT; TIMM, 2016)

$$\rho_c(j) = C(x_i, y_{i+j}) \left( \sqrt{s_x^2 \cdot s_y^2} \right)^{-1} \quad (4)$$

Cabe ressaltar que a função de covariância  $C(x_i, y_{i+j})$  é calculada da mesma forma como apresentada na equação 1, somente substituindo  $x_{i+j}$  por  $y_{i+j}$ , porque neste caso são envolvidas duas variáveis e não somente uma. Plotando-se os valores de  $\rho_c(j)$  em função da distância  $j$  ("lag") é construído o crosscorrelograma entre as variáveis  $x$  e  $y$ . A partir do IC (equação 3) é identificada a faixa de correlação espacial entre as variáveis.

#### 4.2.3. Modelos em Espaço de Estados

O modelo em espaço de estados de um processo estocástico estacionário ou não é baseado na propriedade de sistemas Markovianos, que estabelece a independência do futuro do processo em relação ao seu passado, dado o estado

presente. Um sistema linear (ou não) envolve uma população de observações  $Y_j(x_i)$ , onde  $j = 1, 2, \dots, k$  representa o número de variáveis estudadas (por exemplo: condutividade hidráulica de solo saturado, % argila, matéria orgânica), medidas ao longo de uma transeção x dividida em pontos  $i = 1, 2, \dots, n$ , equidistantes entre si de 1 "lag" (distância que separa as observações adjacentes). Ele pode ser representado na forma de espaço de estados por meio de um sistema de duas equações (SHUMWAY, 1988), como segue:

1<sup>a</sup>) – Equação que define a forma pela qual o vetor das observações  $Y_j(x_i)$  do processo é gerado como uma função do vetor de estados  $Z_j(x_i)$ ; (Equação 5 das observações ou de medida), e

2<sup>a</sup>) – Equação da evolução dinâmica do vetor de estado não-observado  $Z_j(x_i)$ ; (Equação 6 do sistema ou do estado).

Matematicamente, este sistema pode ser representado por:

$$Y_j(x_i) = M_{jj}(x_i)Z_j(x_i) + v_{Y_j}(x_i) \quad \text{Equação de observação} \quad (5)$$

$$Z_j(x_i) = \phi_{jj} Z_j(x_{i-1}) + u_{Z_j}(x_i) \quad \text{Equação de estado} \quad (6)$$

O vetor de observação  $Y_j(x_i)$  é relacionado ao vetor de estado não-observável  $Z_j(x_i)$  por meio da matriz de observação  $M_{jj}$  e pelo erro de observação  $v_{Y_j}(x_i)$  (equação 5). Por outro lado, o vetor de estados  $Z_j(x_i)$ , na posição  $i$ , é relacionado ao mesmo vetor na posição  $i-1$ , por meio da matriz dos coeficientes de estado  $\phi_{jj}$  (matriz de transição), e por um erro associado ao estado  $u_{Z_j}(x_i)$  com a estrutura de um modelo autoregressivo de primeira ordem, neste caso (equação 6). Além da suposição de que  $v_{Y_j}(x_i)$  e  $u_{Z_j}(x_i)$  sejam normalmente distribuídos e independentes (ruído branco).

Tendo ciência de que os parâmetros envolvidos neste estudo apresentam um grau de incerteza provocada por ruídos, dentro da modelagem de espaço de estados tem-se a aplicação do filtro de Kalman. Este é um método matemático que se aplica à estimativa do estado de um sistema dinâmico linear discretizado no tempo. Esse sistema a qual o filtro se aplica deve ser modelado em uma

cadeia de Markov com operadores lineares perturbados por distribuições normais.

O algoritmo do filtro consegue estimar todos os estados do sistema, e oferece uma estimativa do valor da grandeza com um grau maior de confiabilidade. Uma vez que se aceita que as propriedades estudadas não apresentam o valor real da grandeza analisada sem ruído, o filtro realiza uma média ponderada entre o valor predito por ele e o valor medido, produzindo assim, um valor com menor incerteza. O funcionamento do algoritmo é dividido em duas partes, a de previsão e a de correção. Sendo assim, na primeira etapa, o algoritmo estima o valor dos estados a partir da Equação 7,

$$\widehat{x}_k = \phi \widehat{x}_{k-1} + u_{k-1}, \quad (7)$$

onde,  $\widehat{x}_k$  é a estimativa do estado no instante  $k$  a partir do valor do estado anterior  $\widehat{x}_{k-1}$ ,  $\phi$  é a matriz de transição que descreve o sistema analisado e  $u_k$  é um erro ou ruído associado ao estado.

Na etapa de previsão, outra matriz que também é atualizada é a matriz de covariância do erro a priori ( $P_{\bar{k}}$ ). Essa matriz serve como uma estimativa da confiabilidade do cálculo da matriz de ganho  $K$ , que se utiliza para minimizar o erro no estado estimado. Essa matriz é obtida pela Equação 8.

$$P_{\bar{k}} = \phi P_{k-1} \phi^T + Q \quad (8)$$

onde  $P_{\bar{k}}$  é a matriz de covariância do erro a priori calculada com base na matriz de covariância do estado anterior  $P_{k-1}$ ,  $\phi$  é a matriz de transição que descreve o sistema analisado e  $Q$  é a matriz de covariância do sistema. A matriz  $P_{\bar{k}}$  também pode ser compreendida como a adição da incerteza relativa ao processo  $Q$  devido a ação de estimar estados.

Durante a etapa de correção, o estado é atualizado com os valores obtidos por novas medições, essa etapa também é conhecida como estimativa a

posteriori. Nessa etapa é realizada uma combinação linear entre a estimativa feita na primeira etapa e o valor real medido pela Equação 9.

$$\widehat{x}_k = \widehat{x}_{\bar{k}} + K(y_k - A\widehat{x}_{\bar{k}}) \quad (9)$$

onde  $y_k$  é a medição feita e  $A$  é a matriz de observação de estados. A matriz  $K$ , tem dimensão: número de estados x número de saídas, e é conhecido como a matriz de ganhos de Kalman. A matriz  $K$  (Equação 10) deve ser definida de maneira que a covariância do erro seja mínima.

$$K_k = P_{\bar{k}} A^T (A P_{\bar{k}} A^T + R)^{-1} \quad (10)$$

A Equação (9) nos fornece a estimativa a posteriori através da estimativa a priori e das medições feitas ( $y_k$ ), e por meio da matriz de ganho  $K$ , pode controlar a confiança das medições ou do modelo.

#### **4.2.4. Séries e Transformadas de Fourier e Análise em Wavelets**

Com relação ao referencial matemático descrito abaixo cabe destacar que este, foi realizado tendo como base as seguintes referências: Torrence e Compo (1998) e Bolzan (2014 e 2006), Hubbard (1998), James (2011), Percival e Walden (2008), Lathi (2014), Addison (2016), Tolstov (2013), Biswas (2018), Biswas e Si (2011) e Graps (1995).

##### **4.2.4.1. Funções periódicas**

Para se ter uma melhor compreensão das séries de Fourier é importante entender que uma função periódica de período  $T$  é tal que  $f(x)=f(x + T)$ , para todo  $x$  no domínio de  $f$ . Esse período  $T$  é um intervalo onde a curva se repete. Essa função periódica não precisa ser necessariamente contínua. Exemplos de funções periódicas contínuas são as funções seno e cosseno (Figura 1), ambas com período  $2\pi$ .

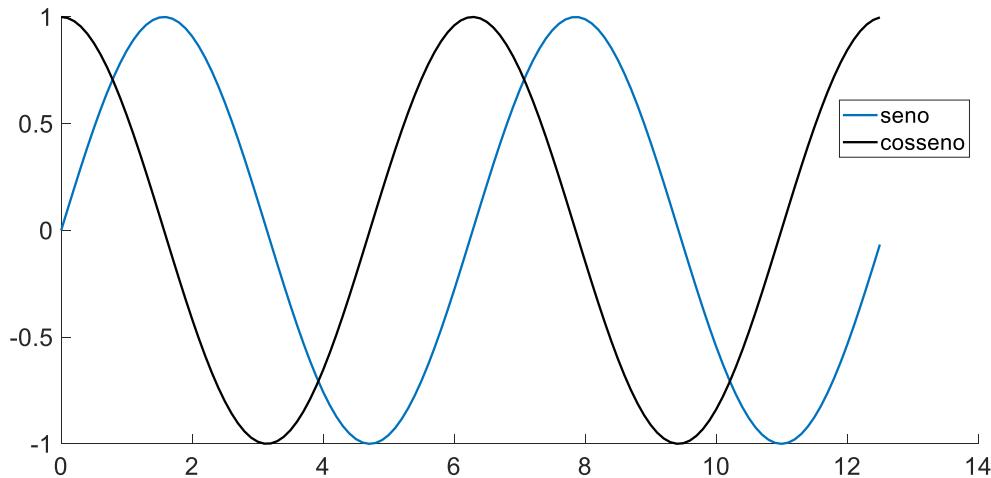


Figura 1 - Seno e cosseno possuem período  $2\pi$ .

#### 4.2.4.2. Series de Fourier

As séries de Fourier podem ser descritas como ferramentas matemáticas empregadas para análise de funções periódicas arbitrárias. Na série de Fourier, é realizada a decomposição da função periódica em uma soma de funções senos e cossenos mais simples, sendo que estas distinguem-se entre si, apenas em amplitude, frequência e fase. A análise aplica-se a vários propósitos, dentre eles é facilitar a manipulação analítica e gráfica da função original.

Em síntese define-se as séries de Fourier como um sinal representado pela soma de componentes em uma base de funções ortogonais, que são as funções senos, cossenos e exponenciais. Uma função periódica  $f(t)$  qualquer (contínua ou não), de período  $T$ , pode ser escrita em termos de uma série infinita de termos de funções senos e cossenos, que é conhecida como expansão em séries de Fourier, que é dado pela Equação 11.

$$f(t) = \frac{1}{2} a_0 + \sum_{n=1}^{\infty} [a_n \cos(n\omega_0 t) + b_n \sin(n\omega_0 t)] \quad (11)$$

Onde  $\omega_0 = \frac{2\pi}{T}$  é a frequência angular fundamental e  $T$  é o período da função. Por conseguinte,  $a_0$ ,  $a_n$  e  $b_n$  são amplitudes de ondas, conhecidas como coeficientes de Fourier, definidos como:  $a_n = \frac{2}{T} \int_{-T/2}^{T/2} f(t) \cos(n\omega_0 t) dt$ ,  $b_n =$

$\frac{2}{T} \int_{-T/2}^{T/2} f(t) \sin(n\omega_0 t) dt$  e  $a_0 = \frac{2}{T} \int_{-T/2}^{T/2} f(t) dt$ . Esses coeficientes são obtidos usando o fato que as funções senos e cossenos são ortogonais (Equação 12).

$$\begin{aligned} \int_{-T/2}^{T/2} \cos(n\omega_0 t) \cdot \cos(m\omega_0 t) dt &= \int_{-T/2}^{T/2} \sin(n\omega_0 t) \cdot \sin(m\omega_0 t) dt \\ &= \begin{cases} \frac{T}{2}, & n = m \\ 0, & n \neq m. \end{cases} \end{aligned} \quad (12)$$

E quando for termos cruzados  $\int_{-T/2}^{T/2} \sin(n\omega_0 t) \cdot \cos(m\omega_0 t) dt = 0$  para quaisquer valores de  $n$  e  $m$ .

#### 4.2.4.3. Forma Exponencial das séries de Fourier

Os termos da série de Fourier podem ser representados por funções exponenciais complexas, a partir da identidade de Euler  $e^{i\theta} = \cos(\theta) + i \cdot \sin(\theta)$ , com  $i = \sqrt{-1}$ . As funções  $\cos(n\omega_0 t)$  e  $\sin(n\omega_0 t)$ , podem agora ser escritas como  $\cos(n\omega_0 t) = \frac{e^{i\omega_0 nt} + e^{-i\omega_0 nt}}{2}$  e  $\sin(n\omega_0 t) = \frac{e^{i\omega_0 nt} - e^{-i\omega_0 nt}}{2i}$ . Os coeficientes tornam-se  $c_n = \frac{1}{T} \int_{-T/2}^{T/2} f(t) e^{-in\omega_0 t} dt = \frac{1}{2} (a_n - ib_n)$ . Substituindo na forma normal da série obtém-se  $f(t) = C_0 + \sum_{n=1}^{\infty} C_n e^{in\omega_0 t} + \sum_{n=1}^{\infty} C_{-n} e^{-in\omega_0 t}$ , que pode ser escrito como um único somatório, em uma forma mais compacta (Equação 13).

$$f(t) = \sum_{n=0}^{\infty} C_n e^{in\omega_0 t} \quad (13)$$

cujos coeficientes passam a ser  $C_n = \frac{1}{T} \int_{-T/2}^{T/2} f(t) e^{-in\omega_0 t} dt$ . Estes são diretamente obtidos usando a ortogonalidade  $\int_{-T/2}^{T/2} e^{in\omega_0 t} e^{-im\omega_0 t} dt =$

$$\begin{cases} T, & n = m \\ 0, & n \neq m. \end{cases}$$

#### 4.2.4.4. Transformada de Fourier

A série de Fourier é uma ferramenta utilizada para representar funções periódicas, contudo quando o interesse é representar funções não periódicas, utiliza-se a transformada de Fourier (TF), admitindo que essa função possui um período infinito. A TF é uma ferramenta útil que possibilita determinar a contribuição que cada função, seno e cosseno, presente em um sinal. Uma função  $f(t)$  real ou complexa, tem como transformada de Fourier a Equação 14.

$$F(\omega) = \mathcal{F}\{f(t)\} = \int_{-\infty}^{\infty} f(t)e^{-i\omega t} dt \quad (14)$$

Vale ressalta que a transformada de Fourier transforma uma função temporal, por exemplo  $f(t)$ , para o domínio da frequência  $F(\omega)$  (espaço recíproco). O caminho inverso também é verdade, ou seja, a função  $f(t)$  pode ser obtida, através da função  $F(\omega)$ , pela transformada inversa de Fourier (Equação 15).

$$f(t) = \mathcal{F}^{-1}\{F(\omega)\} = \frac{1}{2\pi} \int_{-\infty}^{\infty} F(\omega)e^{i\omega t} d\omega \quad (15)$$

Para funções discretas, que é o caso de séries temporais discretas e também todas as séries experimentais, aplica-se a transformada discreta de Fourier. Quando o comprimento da série é um múltiplo inteiro de potência de 2 ( $2^n$ ,  $n=1,2,3,\dots$ qualquer número inteiro positivo), aplica-se a transformada rápida de Fourier, fft abreviação do inglês (fast fourier transform), por exitir um algoritmo que executa a transformação de forma bem rápida.

#### 4.2.4.5. Transformada Janelada de Fourier

As Equações (14 e 15) apresentam uma deficiênciia, quando relaciona a decomposição das várias frequências de um sinal com a sua localização no tempo. Gabor ciente de que grande parte dos fenômenos naturais, são séries temporais não estacionárias modificou a TF, objetivando à melhor representatividade deste tipo de séries temporais. Para aplicação desta, as

séries temporais são divididas em vários segmentos de períodos fixos e em seguida aplicada a TF, em cada um desses intervalos, este método ficou conhecido como a Transformada Janelada de Fourier (TJF).

Na Figura 2a tem-se a série temporal do gráfico dividida em cinco segmentos com intervalos iguais de tempo, onde cada segmento possui três segundos de duração. Em seguida foi aplicada a TF em cada um deles. A Figura 3b mostra o resultado dessa aplicação, conhecida como TJF.

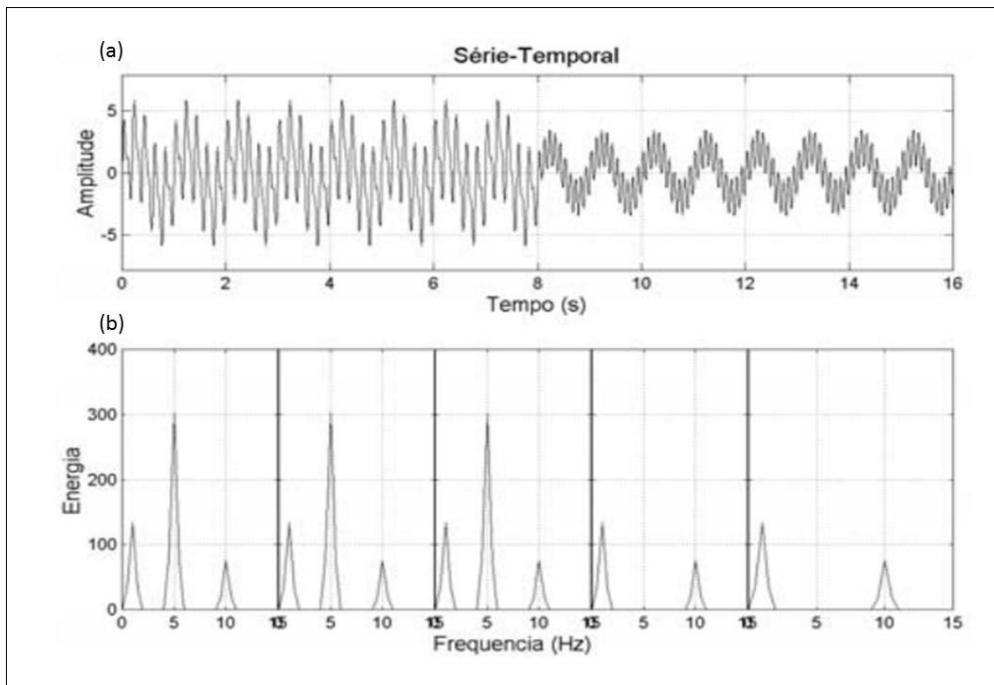


Figura 2: Transformada de Fourier aplicada em cada segmento da série temporal. (a) Série temporal qualquer. (b) Aplicação da transformada de Fourier em cada parte do seguimento da série.

Observa-se a presença das distintas frequências de cada argumento determinado na função seno, em função de sua localização. Ou seja, nos primeiros oito segundos aparecem as três frequências, enquanto nos oito últimos segundos a frequência de 5 Hz não está presente. Contudo há duas limitações, a janela temporal permanece fixa, não viabilizando sua modificação em relação ao tamanho, após iniciar-se a aplicação da TJF, na série analisada. E as funções trigonométricas possuem energia infinita.

Contudo, antes de apresentar métodos capazes de contornar os problemas supracitados, explanar-se-á sobre algumas das aplicabilidades da transformada de Fourier e suas modificações até então incorporadas neste estudo.

#### **4.2.4.6. Funções de Auto e Crosscorrelação a partir da Convolução**

Antes de definir as funções de autocorrelação e correlação cruzada é pertinente termos ciência da definição de convolução de duas funções. Entende-se por convolução todas as transformações lineares que são invariantes por translação. Frente a isso a função de autocorrelação é uma função similar à de convolução, apenas com o segundo termo invertido no tempo, sendo obtida pela Equação 16.

$$R(\tau) = \int_{-\infty}^{\infty} g(t) \cdot g(t + \tau) dt \quad (16)$$

Se o sinal  $g(t)$  a ser representado está no domínio do tempo, necessita-se assim da convolução para obter a função de autocorrelação, porém esta convolução talvez seja muito complexa de ser realizada. Uma alternativa a ser testada para solucionar o problema é passar o sinal  $g(t)$  do domínio do tempo para a frequência  $G(w) = \mathcal{F}\{g(t)\}$  via transformada de Fourier. Assim, a função de autocorrelação é obtida multiplicando-se o sinal no domínio da frequência por ele mesmo e realizando a transformada inversa de Fourier do resultado obtido (Equação 17).

$$R(\tau) = \mathcal{F}^{-1}\{G(w) * G(w)\} \quad (17)$$

Este é o chamado *teorema da convolução*. Para se obter a correlação cruzada entre dois sinais distintos, dados pela Equação 18,

$$C(\tau) = \int_{-\infty}^{\infty} g(t) \cdot h(t + \tau) dt \quad (18)$$

segundo o mesmo princípio da autocorrelação, ou seja, os sinais são passados do domínio do tempo para o domínio da frequência, através da transformada de Fourier ( $G(w) = \mathcal{F}\{g(t)\}$  e  $H(w) = \mathcal{F}\{h(t)\}$ ) e após os sinais estarem no domínio da frequência multiplica-se um pelo outro. Do resultado obtido pelo produto, aplica-se a transformada inversa de Fourier para ser obter a convolução ou a correlação cruzada (Equação 19)

$$C(\tau) = \mathcal{F}^{-1}\{G(w) * H(w)\} \quad (19)$$

#### 4.2.4.7. Função Delta de Dirac

Ao descrever-se os fenômenos naturais observa-se que os mesmos exigem a representação de uma força grande em um curto intervalo de tempo. A função delta de Dirac, também denominada *função impulso*, pode representar estes fenômenos, uma vez que esta é uma função com uma distribuição reta de valor. Sendo assim onde há uma mudança abrupta, tem-se um impulso e ela tende ao infinito naquele ponto. Essa função é definida pela Equação 20.

$$\delta(t - a) = \begin{cases} \infty, & t = a \\ 0, & t \neq a. \end{cases} \quad (20)$$

Duas das principais propriedades da função são: I)  $\int_{-\infty}^{\infty} \delta(t - a) dt = 1$  (área unitária) e II)  $\int_{-\infty}^{\infty} \delta(t - a) f(t) dt = f(a)$ . Portanto, da propriedade I, a função delta Dirac  $\delta$  é na verdade uma *densidade* de largura ‘zero’ e altura ‘infinita’, cuja largura multiplicada pela altura é igual a um, conforme exemplificado na Figura 3, para  $a=0$ . Em resumo, a função delta de Dirac só possui significado físico quando empregada na definição II (dentro de uma integral).

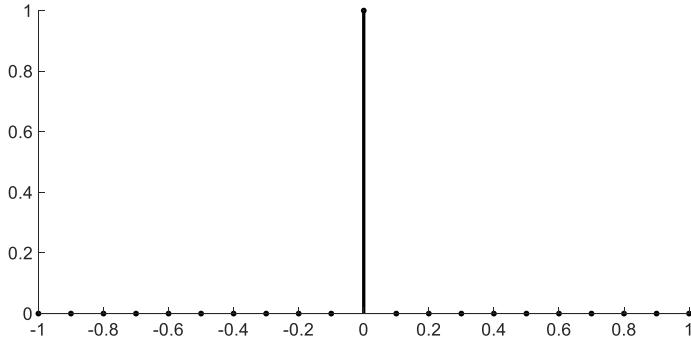


Figura 3: Exemplo da função delta de Dirac, com um fenômeno que sofreu uma mudança abrupta.

#### 4.2.4.8. Densidade do espectro de potência

A densidade do espectro de potência (PSD: *Power Spectral Density*) é uma função real positiva, que pode representar como a energia de um sinal está distribuída de acordo com a frequência (Equação 21).

$$\phi(w) = \left| \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} f(t) e^{-i\omega t} dt \right|^2 = \frac{F(w)F^*(w)}{2\pi} \quad (21)$$

onde  $w$  é frequência angular,  $F(w)$  transformada de Fourier de  $f(t)$  e  $F^*(w)$  é o complexo conjugado da transformada de Fourier. Sendo assim, a PSD (Equação 22) pode ser descrita, através da TF da função de autocorrelação  $p(\tau)$ , que é dado pelo Teorema de *Wiener-Khinchin*.

$$PSD(w) = F[p(\tau)] = \int_{-\infty}^{\infty} p(\tau) e^{i\omega\tau} d\tau \quad (22)$$

Tendo ciência de que através da Transformada de Fourier da função de autocorrelação pode-se calcular a PSD, quando aplicada a transformada inversa da densidade espectral obtém-se a função de autocorrelação (Equação 23).

$$p(\tau) = F^{-1}[PSD(w)] = \frac{1}{2\pi} \int_{-\infty}^{\infty} PSD(w) e^{-i\omega\tau} dw \quad (23)$$

O comprimento (alcance) da autocorrelação pode ser determinado através da Equação 24.

$$L = \int_{-\infty}^{\infty} \tau \cdot p(\tau) d\tau \quad (24)$$

Se  $p(\tau) = ae^{-b\tau}$  (para  $\tau \geq 0$  e  $p(\tau) = 0$  para  $\tau < 0$ ), substituindo na Equação 24, obtém-se  $L = \frac{1}{b}$ , que é o chamado comprimento característico, que sempre vai existir (finito) para sistemas que possuem correlação de curto alcance. A PSD, quando  $p(\tau) = ae^{-b\tau}$ , no limite assinótico para  $\omega=2\pi f$ , é dada por  $PSD \sim \frac{1}{f^2}$ , ou seja, a PSD decresce seguindo uma lei de potência com expoente 2.

Após a apresentação da transformada de Fourier e suas aplicabilidades observa-se que a TF bem como a TJF são capazes de descrever as diferentes frequências contidas em um sinal, mas não podem descrever a localização espacial destas frequências, então surge a limitação ao uso destas ferramentas. Em meados de 1982, Jean Morlet e Alex Grossman cientes das limitações supracitadas ao aplicar-se a TJF em séries temporais, notaram a necessidade de se desenvolver uma função matemática base  $\psi$  que possuísse energia finita, e que fosse totalmente capaz de dilatar ou comprimir, eliminando assim o problema da janela temporal da TJF ser fixa, uniram-se então na busca de funções matemáticas base que possuíssem características de pequenas ondas.

Sendo assim, criaram as bases matemáticas da teoria em Wavelet, com ênfase nas representações de sinais por “blocos construtivos”, os quais Grossman e Morlet chamaram de “ondelette”, referindo-se às “pequenas ondas”; daí teve origem o termo em inglês “Wavelets”, assim como o termo “onduletas” em português.

#### 4.2.4.9. Transformadas de Wavelets

A Wavelet é uma função capaz de decompor e assim descrever ou representar outra função (ou uma série de dados) originalmente descrita no domínio do tempo (ou espaço), de forma a poder-se analisar esta outra função em diferentes escalas de frequência e de tempo. Quando se decompõem uma função através das Wavelets, têm-se a transformada de Wavelet (sigla em inglês WT), bem como suas variantes contínuas e discretas. Matematicamente falando, a transformada em Wavelet é uma convolução, ou seja, uma multiplicação da função chamada Wavelet com o sinal a ser estudado.

Estas decomposições são propriedades de translação e escalamento, contidas em um único protótipo de uma função Wavelet geradora  $\psi_{j,k}(t)$ , denominada do inglês como “Wavelet *mother*”, de onde se obtêm as denominadas funções “Wavelets mães”, pela variação de  $k$  e  $j$  ( $j > 0$ ). Sendo assim, pode-se compreender Wavelets como um conjunto de funções com forma de pequenas ondas geradas por translações  $\psi(t) \rightarrow \psi(t + k)$  e escalamentos  $\psi(t) \rightarrow \psi(t/j)$  de uma função Wavelet simples (Wavelet *mother*) que resulta na Equação 25.

$$\psi_{j,k}(t) = \frac{1}{\sqrt{j}} \Psi_0 \left( \frac{t - k}{j} \right) \quad (25)$$

onde “ $j$ ” é denominado fator de escalonamento (contração  $j > 1$  e dilatação  $j < 1$ ) sendo “ $k$ ” o fator de translação. A função  $\psi_{j,k}(t)$  é chamada de Wavelets filhas e são geradas a partir das Wavelets mãe  $\Psi_0$ . O fator  $\frac{1}{\sqrt{j}}$  é chamado de constante de normalização da energia de cada Wavelet filha de forma a manter a mesma energia da Wavelet mãe, ou seja, a soma das energias de todas as Wavelet filhas, oriundas da Equação (25) resulta na energia total da transformada. Contudo para que uma função possa ser candidata a uma Wavelet mãe (representada por  $\Psi_0$ ), ela deve satisfazer a duas propriedades distintas, a saber:

- I) A integral dessa função deve ser zero (Equação 26).

$$\int_{-\infty}^{+\infty} \Psi_0(t) dt = 0 \quad (26)$$

Essa condição é conhecida como condição de “admissibilidade”. Isto garante a transformada Inversa da função.

II) A função *Wavelet mãe* deve possuir *energia finita* (Equação 27).

$$\int_{-\infty}^{+\infty} |\Psi_0(t)|^2 dt < \infty \quad (27)$$

Esta propriedade é equivalente dizer que  $\Psi_0(t)$  é quadraticamente integrável. As funções bases senos e cossenos satisfazem a propriedade (I), mas a (II) não.

A transformada Wavelet foi descrita como uma forma de analisar os sinais aperiódicos, ruidosos, intermitentes, transitórios, capaz de examinar o sinal simultaneamente em relação ao tempo e frequência ou a escala e posição, independentemente do tamanho e da intensidade da frequência. Conclui-se assim que a análise *Wavelet* é realizada através da aplicação sucessiva da transformada Wavelet a diversos valores de  $k$  e  $j$ , o que representa a decomposição do sinal original da série temporal em diversos componentes localizados no tempo (parâmetro de translação  $k$ ) e frequência (parâmetro de escala  $j$ ). De certa forma, cada tipo de *Wavelet mãe* possui uma melhor ou pior localização nos domínios da frequência e/ou do tempo; desta maneira torna-se necessário a escolha de uma *Wavelet mãe* conveniente, de acordo com o sinal estudado e os objetivos almejados. Dentre as Wavelets mais conhecidas e aplicadas, são elas:

1. Wavelet gaussiana - Muito empregada devido a sua elevada regularidade, sendo está uma derivada de ordem  $n$  da função gaussiana, definida pela Equação 28.

$$\psi(t) = \frac{\partial^n}{\partial t^n} e^{-\frac{t^2}{2}} \quad (28)$$

2. Wavelet Chapéu Mexicano - É a segunda derivada da função gaussiana, comumente empregada com o intuito de se economizar tempo (Equação 29).

$$\psi(t) = (1 - t^2)e^{\frac{-t^2}{2}} \quad (29)$$

Na Figura 4 tem-se a representação gráfica desta Wavelet.

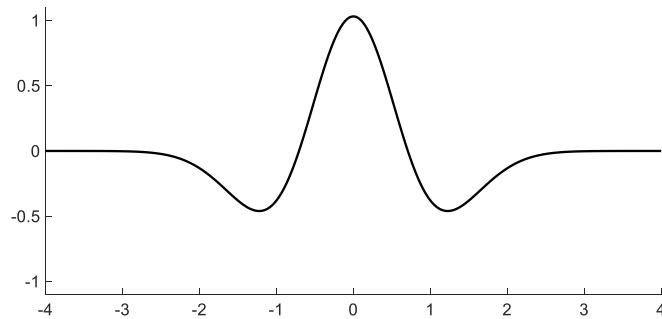


Figura 4: Representação do sinal da Wavelet Chapéu Mexicano.

3. Wavelet Haar - É a primeira e mais simples base Wavelet conhecida. Basicamente é uma sequência de funções quadradas que foram reescalonadas, contudo possui a desvantagem de não ser continua sendo assim é utilizada para reconhecimentos de padrões, e para compactação de imagens, definida pelo sistema abaixo.

$$\psi(t) = \begin{cases} 1 & 0 \leq t < \frac{1}{2} \\ -1 & \frac{1}{2} \leq t < 1 \\ 0 & \text{para outros casos} \end{cases}$$

Cuja representação gráfica é mostrada na Figura 5.

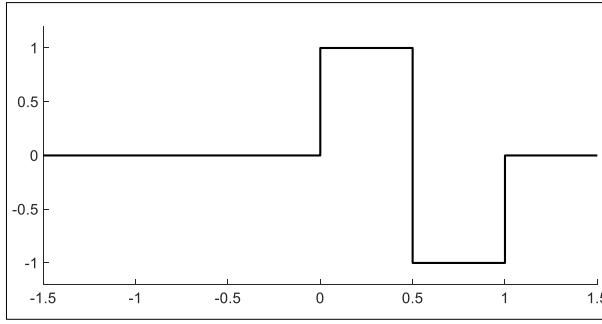


Figura 5: Representação do sinal de uma Wavelet de Haar.

4. Wavelet Daubechies: a transformação de Daubechies possui quatro coeficientes de função Wavelet e escala:  $h_0 = \frac{1+\sqrt{3}}{4\sqrt{2}}$  ,  $h_1 = \frac{3+\sqrt{3}}{4\sqrt{2}}$  ,  $h_2 = \frac{3-\sqrt{3}}{4\sqrt{2}}$  e  $h_3 = \frac{1-\sqrt{3}}{4\sqrt{2}}$ . Os coeficientes  $h$  são para a função de escala, para a função de Wavelet os coeficientes são de acordo com:  $g_0 = h_3$ ,  $g_1 = -h_2$ ,  $g_2 = h_1$ , e  $g_3 = -h_0$ .

As funções de escalonamento e Wavelet são calculadas incorporando o produto interno dos coeficientes e quatro valores de dados, conforme as seguintes Equações (41 à 44). A função escalada de Daubechies D4 é escrita como  $a_i = h_0s_{2i} + h_1s_{2i+1} + h_0s_{2i+2} + h_3s_{2i+3}$  e  $a[i] = h_0s[2i] + h_1s[2i+1] + h_2s[2i+2] + h_3s[2i+3]$ .

A função Wavelet de Daubechies D4 é escrita como  $c_i = g_0s_{2i} + g_1s_{2i+1} + g_0s_{2i+2} + g_3s_{2i+3}$  e  $c[i] = g_0s[2i] + g_1s[2i+1] + g_2s[2i+2] + g_3s[2i+3]$ .

Cada iteração na etapa de transformação Wavelet calcula um valor de função de escala e um valor de função Wavelet. O índice  $i$  é incrementado por dois a cada iteração, e novos valores de função de escala e Wavelet são calculados.

A Figura 6 mostra um sinal da função escala de Daubechies.

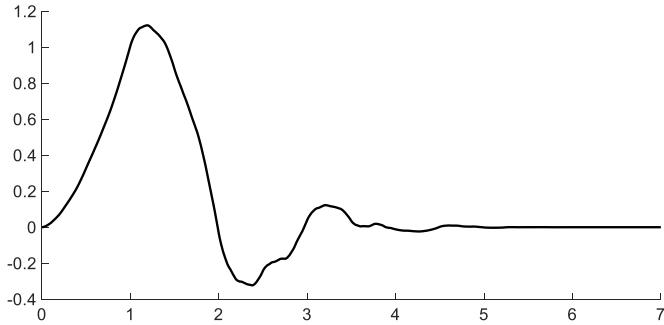


Figura 6: Sinal de uma função escala de Daubechies.

A Figura 7 mostra um sinal da função Wavelet de Daubechies.

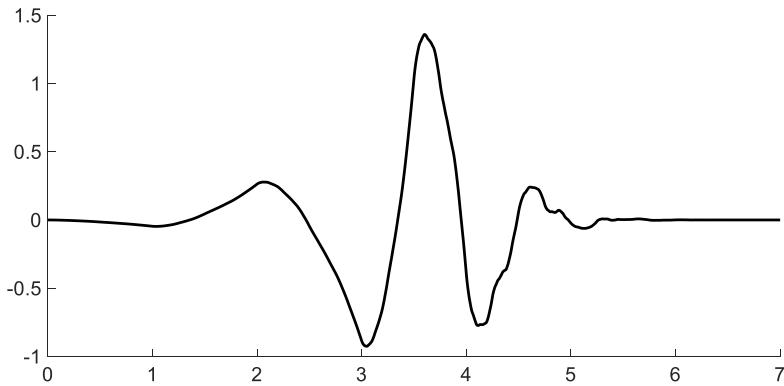


Figura 7: Sinal da Wavelet de Daubechies.

5. Wavelet de Morlet - É composta por uma exponencial complexa (seno e cosseno) atenuada por uma amplitude gaussiana. Esta é a Wavelet mais utilizada decorrente de sua flexibilidade e aplicabilidade (Equação 30).

$$\psi(t) = \pi^{-\frac{1}{4}} e^{-i\omega_0 t} e^{-\frac{t^2}{2}}, \quad (30)$$

onde  $\omega_0$  é a frequência fundamental/base da Wavelet mãe. Na Figura 8 tem-se a representação gráfica de uma Wavelet de Morlet.

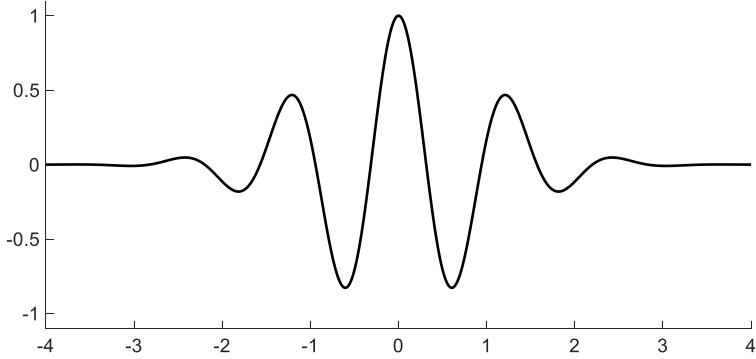


Figura 8: Representação de um sinal da Wavelet Morlet.

#### 4.2.4.10. Wavelet de Morlet

Tendo ciência de que esta pesquisa abarca o interesse em mudanças de amplitude e fase, a Wavelets de Morlet foi a escolhida para ser aplicada nas análises realizadas neste trabalho. Sua definição é dada pela Equação 43.

$$\Psi_0(t) = \pi^{-\frac{1}{4}} \left( e^{i\omega_0 t} - e^{\frac{(\omega_0)^2}{2}} \right) e^{-\frac{t^2}{2}}, \quad (31)$$

onde  $\omega_0$  é a frequência central (ou fundamental) da Wavelet mãe. O fator  $\pi^{-\frac{1}{4}}$  é a constante de normalização. O termo  $e^{-\frac{t^2}{2}}$  é o pacote gaussiano que confina as Wavelet de Morlet. O segundo termo entre parêntesis é conhecido como o termo de correção, pois corrige a média quando esta não resulta em zero do senoidal complexo do primeiro termo. Na prática, esse valor torna-se insignificante para valores de  $f_0$  não muito grandes e pode ser ignorado, gerando a Equação 44.

$$\Psi_0(t) = \pi^{-\frac{1}{4}} e^{i\omega_0 t} e^{-\frac{t^2}{2}} \quad (32)$$

#### 4.2.4.11. Espectro de Energia das Wavelets

Pode-se compreender a energia da Wavelet contínua como  $|W_n^X(s)|^2$ . A exponencial da função Wavelet *mother*, pode ser interpretada como a fase local. Ressaltasse, entretanto, que decorrente da transformada em Wavelet não ser completamente localizada no tempo, o resultado final possui efeitos de bordas. Por este fato, tem-se a necessidade de utilizar o Cone de Influência (COI), e assim desprezar os efeitos de borda.

Para a análise da significância estatística de um pico no espectro de Wavelets, pode-se utilizar a ‘hipótese nula’. Esse método considera o sinal como ruído vermelho, com dado ‘Espectro de Energia de Fundo’ sendo este calculado em função da autocorrelação da série temporal analisada.

Adotando-se o nível de confiança estatística de 95% no espectro de energia da Wavelets, significa que esta energia tem que ser aproximadamente 3 vezes maior que o seu espectro de fundo de ruído vermelho, para ser considerada significante. O ruído vermelho está associado aos erros. Sendo assim é possível verificar com a transformada de Wavelet, no tempo, que parte do sinal analisado transporta energia significativa e em quais frequências (escalas) isso acontece.

#### 4.2.4.12. Transformada cruzada em Wavelets

A transformada cruzada em Wavelet apresenta a covariabilidade da energia entre duas séries temporais e revela informações sobre a relação entre as fases das mesmas, sendo assim o espectro de energia das Wavelets é ampliado para se analisar duas séries temporais  $X_n$  e  $Y_n$ .

A distribuição teórica do espectro cruzado de energia de fundo das Wavelets de duas séries temporais  $P_K^X$  e  $P_K^Y$  definida através da Equação 45.

$$D \left( \frac{|W_n^X(s)W_n^{Y*}(s)|}{\sqrt{P_k^X P_k^Y}} < p \right) = \frac{Z_v(p)}{\sqrt{v}} \sqrt{P_k^X P_k^Y} \quad (33)$$

Dessa forma  $Z_v(p)$  é o nível de confiança associado com a probabilidade  $p$ , para uma Função de Densidade de Probabilidade (PDF - *Probability Density Function*), definida pela raiz quadrada do produto de duas distribuições  $\chi^2$  (Qui-quadrado).

#### 4.2.4.13. Ângulo de Fase

O conhecimento da diferença de fase entre duas séries temporais é de grande importância para quantificar e qualificar a relação entre elas, em termos de propagação de seus ciclos de oscilação. Para isso, é necessário estimar a média e o intervalo de confiança da diferença de fase entre as séries, o que significa, usar a média circular da fase sobre regiões com significância estatística maiores que 5% e, que estejam fora do COI, o que quantificará a relação de fase. Entende-se que 5% de significância estatística equivalem a 95% de confiança estatística.

A Figura 9A representa a mecânica da transformada de Wavelet. A Wavelet de escala  $a$  está centralizada na localização  $b$  no eixo do tempo e é sobreposta ao topo de um sinal arbitrário. Como exemplos: se nos segmentos de tempo em que a Wavelet e o sinal resultam valores positivos, tem-se uma contribuição positiva. Os segmentos de tempo onde a Wavelet e o sinal são resultados negativos, tem-se uma contribuição positiva para o integral (região 11B). Regiões onde o sinal e a Wavelet são opostos resulta em contribuições negativas para a integral, por exemplo regiões C, D e E na figura 9.

A Figura 9b apresenta uma Wavelet de dilatação fixa em quatro locais em um sinal. A primeira localização,  $b_1$ , a Wavelet está localizada em um segmento do sinal em que as partes positivas e negativas do sinal são razoavelmente coincidentes com as da Wavelet. Isto resulta em um valor positivo relativamente grande de  $T(a, b)$ . Na localização  $b_2$ , encontram-se contribuições positivas e negativas para a integral o que faz cancelar um ao outro, resultando em um valor próximo de zero. Na localização  $b_3$ , o sinal e a Wavelet estão essencialmente fora de fase resultando em um grande valor negativo para  $T(a, b)$ . No local  $b_4$  a Wavelet e o sinal estão novamente fora de fase, semelhante ao local  $b_3$ , no entanto, a porção de sinal na vizinhança da Wavelet contém um largo componente médio local, neste caso é fácil observar que o componente médio contribui igualmente para o positivo e o negativo, sendo assim, apenas o recurso de sinal local é destacado pela Wavelet.

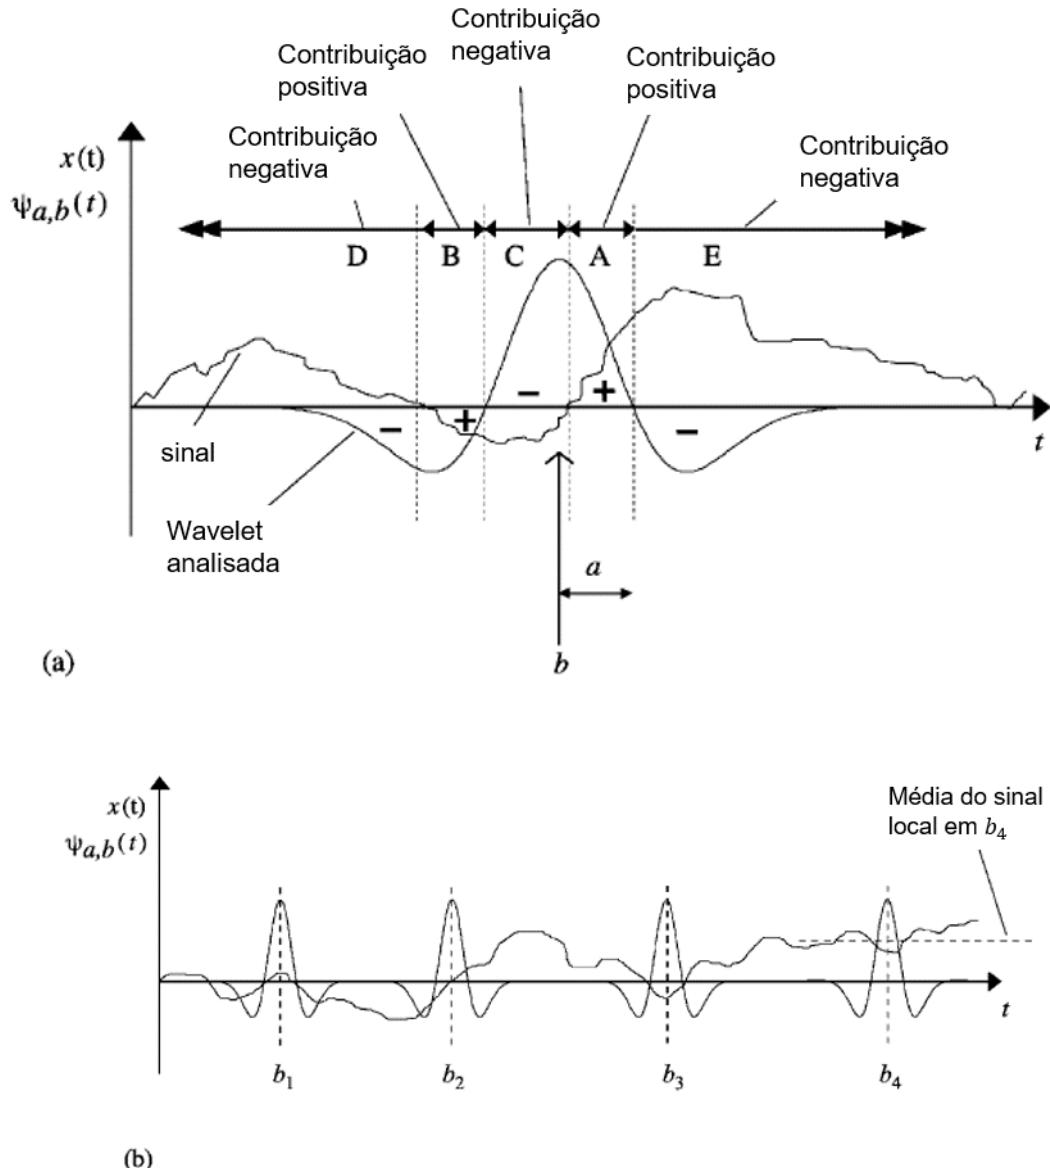


Figura 9. A identificação de estruturas coerentes em Wavelet do sinal.

Sendo que (a) A Wavelet de dilatação específica e localização no sinal. As regiões que dão contribuições positivas e negativas para a integral são delineadas em o esboço e marcado com '+' e '-' respectivamente. (b) Uma Wavelet de dilatação fixa em quatro localizações no sinal. Um largo valor positivo de  $T(a, b)$  é retornado no local  $b_1$ . Um valor próximo de zero de  $T(a, b)$  é retornado em  $b_2$  e um largo valor negativo de  $T(a, b)$  é retornado em  $b_3$ . Na  $b_4$  um local mínimo no sinal, correspondente com a parte positiva da Wavelet e relativamente na maior parte do sinal correspondem às partes negativas da Wavelet. Isso combina para dar um largo valor negativo de  $T(a, b)$ .

Em síntese é através deste processo que a transformada de Wavelet seleciona estruturas coerentes em um sinal de tempo em várias escalas. Sendo que por movimento dos sinais, são identificadas as escalas específicas na Wavelet ao longo do sinal (ampliando b). Este processo é repetido ao longo de um intervalo de escalas até todas as estruturas coerentes dentro do sinal, do maior para o menor, serem distinguidas.

#### **4.3. Estado da arte dos assuntos abordados neste estudo**

A condutividade hidráulica saturada do solo ( $K_{sat}$ ), é uma das propriedades hidráulicas do solo que se apresenta como fator chave, para se compreender muitos dos processos hidrológicos. Entretanto a sua mensuração é onerosa, decorrente de sua alta variabilidade espacial, frente a isto, a  $K_{sat}$  vem sendo mensurada através de fatores secundários, como por exemplo: por meio de atributos físicos do solo de fácil mensuração, dados topográficos e uso do solo.

Corroborando com o descrito assim, no estudo de Baiamonte et al. (2016), os autores explicaram a variabilidade espacial da  $K_{sat}$  com base nos atributos: físicos do solo, topográficos e uso do solo, sendo os atributos texturais e topográficos do solo, os mais importantes, uma vez que os maiores valores de  $K_{sat}$ , foram encontrados em locais onde o teor de argila era baixo, mas onde a altimétrica e declividade eram acentuadas.

Já Neij et al. (2004), incorporaram em seu estudo além dos atributos físicos do solo os topográficos, pois os autores destacam que estes são de fácil obtenção, através do modelo digital de elevação, para a previsão de propriedades hidráulicas do solo, e encontraram como resultado a elevação do terreno, como o atributo que apresentou a melhor correlação com as propriedades hidráulicas do solo, quando aplicada às redes neurais.

Assim como no estudo de Baiamonte et al. (2016), no estudo de Picciafuocoa et al. (2019), os autores utilizaram de atributos: físicos do solo, topográficos e uso do solo, para estimar a  $K_{sat}$ . E encontraram que esta foi fortemente influenciada pelo uso do solo, entretanto no trabalho de Baiamonte et al. (2016), os teores de argila, altimétrica e declividade, foram os principais na

estimativa. Roa-Gracia et al. (2011), reafirmam o descrito no estudo de Picciafuocoa et al. (2019) ao analisar o papel do uso do solo na regulação do escoamento da água em pequenas bacias hidrográficas.

Em contrapartida, Papanicolaou et al. (2015), colocaram em seu estudo como fator preditivo, além de propriedades físicas do solo, o uso do solo para avaliar, a variabilidade espacial da condutividade hidráulica de solo saturado, com o intuito de compreender o papel do manejo e uso do solo e seus efeitos nos processos erosivos.

Por fim, Bonell et al. (2010), reforçam a importância de se analisar o uso do solo ao discretizarem o impacto do uso de floresta e reflorestamento na condutividade hidráulica do solo.

Com relação aos modelos de espaço de estado, pouco se têm encontrado com aplicação para prever a condutividade hidráulica de solo saturado, ao contrário da previsão do carbono orgânico do solo. Contudo, quando estes são descritos em pesquisas, possuem sempre a mesma abordagem, onde os autores trazem uma estatística básica dos dados em análise, seguidos de teste de normalidade, e posteriormente análises de auto e crosscorrelação, sendo estas, para se analisar as correlações espaciais e por fim as previsões por meio dos modelos de espaço de estado.

Observa-se também, que atualmente têm se empregando a análise de correlação de *Pearson* e *Spermam*, na tentativa de encontrar correlações existentes entre os parâmetros, porém, correlações estas, não espaciais. Outros fatores nesta linha de publicação que vem ganhando espaço é a utilização de fatores topográficos e do uso do solo, como variáveis secundárias nas previsões dos modelos de espaço de estado, conforme pode-se observar nos estudos descritos a seguir.

Duan, Huang e Zhang (2016), por exemplo, avaliaram os efeitos das propriedades topográficas e das propriedades físicas do solo no armazenamento da água no solo, através da abordagem de espaço de estados, sendo que o diferencial deste estudo foram as coletas de amostras, que foram determinadas em várias profundidades. Neste estudo os autores encontraram a melhor abordagem do espaço de estado com uma variação total de 98,8% sendo o modelo composto pela elevação e o teor de argila.

Por conseguinte, Li, Shao e Zhao (2019), tiveram como objetos de seu estudo os parâmetros chaves da curva de retenção de água no solo, ou seja, a capacidade de campo e o ponto de murcha permanente. O objetivo principal da pesquisa de Li, Shao e Zhao (2019), foi empregar a modelagem de espaço de estados para criarem modelos capazes de prever os parâmetros supracitados, considerando as correlações espaciais entre as propriedades físicas do solo.

As variáveis secundárias selecionadas pelos autores supracitados foram: a elevação, densidade, textura, carbono orgânico e uso do solo. Como resultado os autores encontraram auto e crosscorrelação significativas a aproximadamente 40 m. Ademais, quando empregado os modelos de espaço de estado, obtiveram melhor desempenho na estimativa da capacidade de campo e do ponto de murcha permanente através de equações bivariadas baseadas em silte e no uso do solo.

Em contrapartida Rienze et al. (2016), incorporaram em seu estudo apenas atributos físicos-químicos do solo. Esta modelagem tinha o objetivo de integrar as informações espaciais e modelar o conteúdo de água no solo em um transecto estabelecido em Buenos Aires, na Argentina. Sendo que, dentre os modelos obtidos os que continham a densidade do solo e carbono orgânico, foram descritos como os melhores.

Já Zhang et al. (2017), utilizaram as variáveis uso do solo, propriedades físicas e topográficas do solo, bem como a biomassa de raízes finas de uma encosta no Platô De Loess, para estimar o carbono orgânico do solo e como resultados, encontraram como melhor modelo o que explicou mais de 96% das variações nas quantidades de carbono orgânico do solo, o que incluiu os atributos uso do solo, biomassa de raízes finas, pH e nitrogênio total. Contudo, o uso do solo foi o fator dominante na variância do modelo escolhido.

Luo et al. (2013), além de abordarem a modelagem de espaço de estado, trazem afirmações sobre fatores que influenciam as propriedades físicas do solo, uma vez que, afirmam que em áreas com heterogeneidade topográfica, a mudança no uso do solo é espacialmente variável e influenciada pelo clima, propriedades físicas do solo e pela topografia. Frente a isto, os autores constroem, conforme denominado por eles, indicadores para determinar as características da mudança de uso do solo, através dos modelos de espaço de estado.

Por fim, She et al. (2014), incorporaram apenas variáveis topográficas na modelagem de espaço de estados para estimar a variação do carbono orgânico do solo, sendo elas: elevação, declividade, aspecto e curvatura. Os autores declararam que a curvatura, foi identificada como uma das mais eficazes para estimar o carbono orgânico do solo, explicando 94,5% da variação total.

Com relação às transformadas em Wavelets, os primeiros trabalhos desenvolvidos na física do solo se deram como forma de revisões bibliográficas e suas possíveis aplicações práticas. Seguidos de aplicações reais em pequenas áreas agrícolas, através de Wavelet e Wavelet coerência.

Cabe destacar que como esta ferramenta viabiliza a empregabilidade em dados não estacionários, são encontradas algumas aplicações na condutividade hidráulica de solo saturado e seu relacionamento com os demais fatores de influência anteriormente descritos.

Dentre as revisões bibliográficas encontra-se a de Graps (1995), na qual o autor conceitua o termo, como sendo funções matemáticas que abrem os dados em diferentes componentes de frequência e, assim torna possível sua apresentação em cada componente, com uma resolução compatível com a sua escala. O autor relata que este método tem vantagens sobre os métodos tradicionais de Fourier na análise de situações físicas em que o sinal contém descontinuidades. Além de trazer parte da formulação matemática, o autor descreve a história das Wavelets, e de suas propriedades, contudo suas aplicações são estritamente matemáticas.

Já Si (2008), apresentou e ilustrou uma revisão bibliográfica sobre a metodologia das Wavelets, sob a ótica da aplicabilidade em propriedades físicas do solo em escala espacial. O autor utilizou dentre outras variáveis a condutividade hidráulica do solo, coletadas ao longo de um transecto em Saskatchewan, Canadá.

Uma outra abordagem teórica foi a de Lark (2016), que realizou uma comparação entre a transformada Wavelet e o modelo linear misto com suavização espectral, por meio de uma aplicação em um único conjunto de dados de uma propriedade física do solo, e constatou a superioridade das Wavelets sobre o modelo linear misto.

Com relação às aplicações reais, o estudo pioneiro foi o de Si e Zeleke (2005), que objetivaram compreender as relações entre a ksat com algumas

propriedades do solo. E chegaram à conclusão, por meio da aplicação da Wavelet coerência que as relações entre a Ksat e a areia, bem como da Ksat com o carbono orgânico não são apenas dependentes da escala, mas também dependentes da localização.

Wu, Guo e Li (2018), corroboraram com a afirmativa dos autores supracitados, pois identificaram as correlações entre padrão de paisagem e topografia em várias escalas, usando a análise de correlação de Pearson e o método de Wavelet.

Por conseguinte, Zhu et al. (2018) realizaram a previsão do carbono orgânico com base em suas relações específicas de escala através das transformadas Wavelets, e destacaram que a aplicação desta ferramenta gerou novas compreensões na estimativa das propriedades do solo, além de terem determinado as relações de múltiplas escalas das propriedades do solo com fatores de influência.

Uma aplicação distinta das descritas foi a realizada por Samadianfard et al. (2018), que incorporaram as Wavelets em uma rede neural, como um dos métodos para estimar a temperatura do solo em diferentes profundidades em uma estação de monitoramento localizada no Irã. Dentre os métodos aplicados a Wavelet se mostrou superior aos demais métodos, uma vez que dentro da rede neural a Wavelet serviu como uma espécie de filtro.

Já Zhao et al. (2018), foi um dos poucos trabalhos com uma abordagem de múltiplas coerências de Wavelets, para encontrar escalas significativas dominantes. Em seu estudo a Wavelet foi aplicada dois transectos na China, sendo seu alvo de pesquisa a matéria orgânica do solo. Guo et al. (2018) também tiveram como objeto de pesquisa a matéria orgânica do solo, e analisaram a variabilidade espacial de um transecto em uma pequena área agrícola, através da combinação da análise de anisotropia, geoestatística, que teve como intuito extrair as direções dominantes, e a aplicação da transformada discreta de Wavelets para encontrar as escalas específicas em que esta frequência estava ocorrendo.

Seguindo esta linha Biswas e Si (2011), também estudaram a correlação entre o armazenamento de água no solo e seus fatores de controle em diferentes escalas e locais em uma Área Nacional de Vida Selvagem de St. Denis, Saskatchewan, Canadá, usando Wavelet coerência. Constataram coerência

significativas de Wavelets em escala e localização específicas entre o armazenamento da água no solo e a elevação do terreno, indicando um controle dominante da elevação no armazenamento de água no solo na área estudada, mostrando novamente a importância da incorporação de fatores topográficos sob o movimento de água no solo.

Cabe destacar que Hu e Si (2016), trazem, em seu estudo uma abordagem não aplicada, mas de desenvolvimento de um método de múltipla coerência de Wavelets, para examinar relações multivariadas específicas de escala e localização. Os resultados mostraram que a coerência espectral múltipla é incapaz de identificar relações multivariadas localizadas e subestima as relações multivariadas específicas de escala para processos não estacionários.

Já Biswas (2018) em seu estudo realizou uma revisão de literatura com aplicações de um comparativo entre a transformada Wavelet contínua (CWT) e a transformada de Hilbert-Huang (HHT). E com sua base algorítmica, o HHT foi capaz de identificar os componentes da escala presente na série espacial de forma mais flexível, enquanto a redundância na CWT identificou uma banda espalhada de escalas, contudo sua aplicação foi tendenciosa, uma vez que se utilizou de uma forma fixa de Wavelet em suas análises.

Ademais, vêm sendo incorporadas ferramentas estatísticas como os modelos de decomposição empíricos, porém, em mínimas proporções conforme descritas abaixo. O estudo de Huang et al. (1998), objetivou uma adaptação de um novo método para analisar dados não-lineares e não-estacionários. Sendo que, a parte principal desta adaptação é a viabilidade de "decomposição em modo empírico", com o qual qualquer conjunto de dados pode ser decomposto em um número finito e muitas vezes pequeno de "funções de modo intrínseco" que se comporta parecido com a transformada Hilbert.

Na revisão bibliográfica de Flandrin e Gonçalvés (2004), os autores descreveram sobre os modelos de decomposição do modo empírico, baseados nas transformações de Huang (1998) apresentando a ferramenta de maneira geral, bem como sua formulação matemática e gráfica, traçando um paralelo da aplicabilidade deste, versus as Wavelets. She et al. (2015) realizaram dois estudos contendo aplicação prática deste modelo. No primeiro investigaram a consistência, no período e na escala específica da distribuição da curva de

retenção de água no solo em dois transectos, sendo estes compostos de diferentes solos e cobertura vegetal, utilizando para isto, a decomposição em modo empírico multivariado, com a análise de correlação de Spearman.

E no segundo estudo She et al. (2017), examinaram as correlações em diversas escalas entre duas propriedades hidráulicas do solo, dois atributos topográficos e três fatores do solo. Para isto a série de dados multivariados, foi dividida em seis funções do modo intrínseco, onde constatou-se que as relações específicas entre as propriedades hidráulicas do solo e os fatores associados variavam de acordo com a escala, ou seja, que os fatores associados exerceram influência nas propriedades hidráulicas do solo em suas próprias escalas dominantes.

Por fim, Yang et al. (2019), tiveram como objeto principal avaliar a condutividade hidráulica saturada, frente a decomposição do modo empírico multivariado, assistido por ruído (NA-MEMD) para assim conseguir caracterizar a variabilidade de condutividade hidráulica saturada e descrever suas relações dependentes da escala, com diferentes propriedades do solo e fatores ambientais.

Em síntese com base nos estudos supracitados pode-se observar uma tendência a incorporação de fatores de fácil obtenção, como dos atributos topográficos do solo. Observa-se também a importância de se analisar a variável de interesse incorporando o uso do solo.

Com relação a modelagem de espaço de estado, tendo como objeto de estudo a condutividade hidráulica de solo saturado a aplicação ainda é escassa, já quando incorporando ferramentas como Wavelets e os modelos de decomposição empíricos, a Ksat já é mais encontrada em estudos, porém com aplicações em pequenas áreas.

## 5. Material e Métodos

### 5.1. Bacia hidrográfica envolvida no estudo

Foi selecionada a bacia hidrográfica do Arroio Fragata em virtude da importância econômica e social para a região sul do Rio Grande do Sul. Para este estudo foi considerada a área de drenagem à montante da seção de controle Passo dos Carros pertencente à bacia do Arroio Fragata (BHAF-PC) (Figura 10).

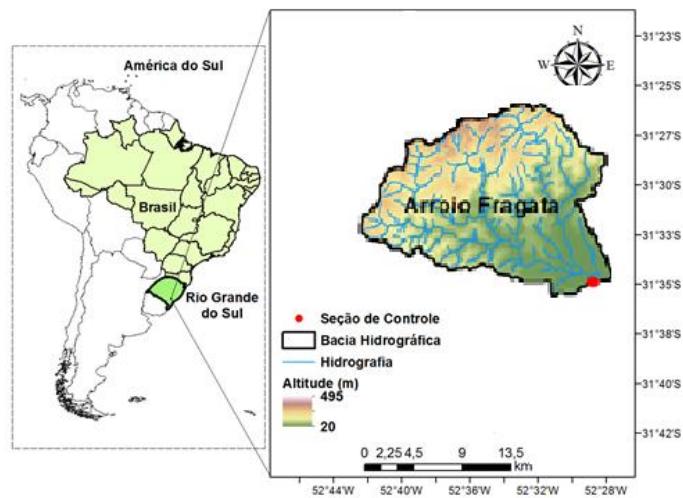


Figura 10: Localização da bacia hidrográfica do arroio Fragata (BHAF), à montante da seção de Passo dos Carros (BHAF-PC).

### 5.2. Levantamento e processamento de dados básicos da BHAF

Foi realizado um levantamento de informações básicas, para a BHAF, as quais servirão de apoio ao presente estudo, tais como: relevo, hidrografia e tipos de solos.

Com relação ao relevo, foram extraídas informações da base cartográfica de Hasenack e Weber (2010), que contempla todo o estado do Rio Grande do Sul, na escala de 1:50.000, no formato do SIG-ArcGIS. Foram utilizados desta base os seguintes planos de informação: curvas de nível e pontos cotados e hidrografia vetorizada. Os planos de informação foram usados como informações de entrada no SIG-ArcGIS. Foi empregada uma ferramenta específica, no ambiente do referido SIG, para elaborar o modelo digital de elevação (MDE) da BHAF, ou seja, um mapa contínuo contendo a informação sobre o relevo. O MDE foi corrigido, usando a ferramenta Fill, para eliminar as

depressões espúrias do terreno, permitindo a elaboração de um modelo digital de elevação hidrologicamente consistente (MDEHC). A partir do MDEHC foi determinado, de forma distribuída da bacia, a direção de fluxo, acúmulo de fluxo e rede de drenagem numérica.

O mapa de classificação de solos foi obtido a partir do levantamento realizado por Brasil (1973). A partir da utilização do mapa de solos e da delimitação da bacia hidrográfica, foi demarcada uma transeção de 15 km na BHAF-PC, a partir da seção de controle da Ponte do Passo dos Carros. O critério adotado para a demarcação da transeção foi o de selecionar a maior distância possível partindo da seção de controle e ao mesmo tempo fosse contemplado o maior número possível de classes de solos. O mapa de solo extraído para a bacia bem como a transeção estabelecida são encontrados na Figura 11.

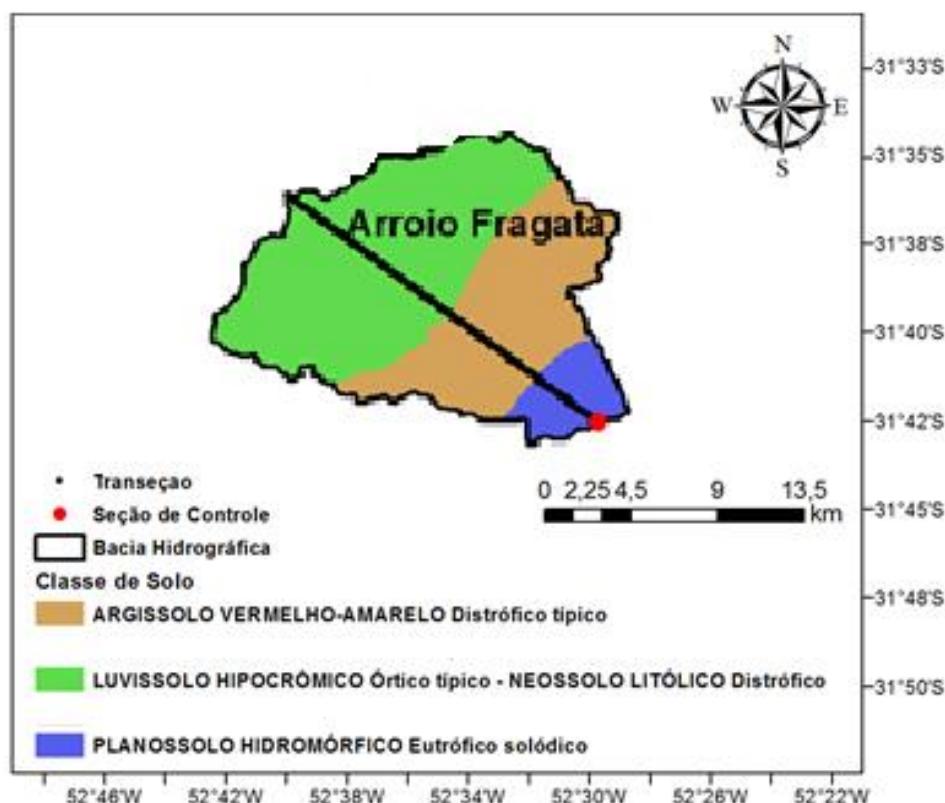


Figura 11: Mapa das classes de solos e ilustração da transeção espacial construída para amostragem de solo na bacia do Arroio Fragata (BHAF-PC).

### **5.3. Amostragem de solo ao longo da transeção espacial e atributos físico-hídricos determinados**

A partir das transeções espaciais 15 km na BHAF-PC (Figura 12) foram demarcados 100 pontos amostrais equidistantes entre si de 150 m, respectivamente, ao longo da transeção.

Em cada ponto da transeção foram coletadas amostras de solo deformadas, na camada representativa de 0,00 a 0,20 m, para determinar as frações texturais (argila, areia e silte) e o teor de carbono orgânico seguindo metodologias descritas, respectivamente, em Gee e Bauder (1986) e Tedesco et al. (1995). Também foram coletadas, em cada ponto da transeção e nessa mesma camada de solo, amostras com estrutura preservada em anéis com dimensões de 0,05 m x 0,047 m de altura e diâmetro, respectivamente, para determinar a densidade do solo, porosidade total e macro, de acordo com metodologias descritas em Embrapa (1997), totalizando 300 amostras (100 pontos x 1 bacias hidrográficas x 3 repetições). Nas mesmas amostras preservadas e em cada ponto amostral foi determinada a condutividade hidráulica do solo saturado pelo método do permeâmetro de carga constante, seguindo metodologia descrita em Libardi (2012).

### **5.4. Atributos topográficos obtidos em cada ponto amostral da transeção espacial**

De posse do MDEHC da BHAF foram obtidos os seguintes atributos topográficos em cada ponto amostral demarcado ao longo da transeção espacial: altitude, declividade, aspecto, curvatura, plano e perfil de curvatura.

### **5.5. Análises estatísticas**

#### **5.5.1. Caracterização e identificação da estrutura de variabilidade espacial de cada atributo estudado**

Primeiramente, a estatística clássica foi aplicada aos atributos do solo e aos topográficos para a obtenção das medidas de posição (média, mediana, etc.), de dispersão (amplitude total, desvio padrão, variância e coeficiente de variação) e da forma da dispersão (simetria e curtose). Também foi aplicado o teste de Kolmogorov-Smirnov para verificar a normalidade de cada conjunto de dados.

Para caracterizar e identificar a estrutura de variabilidade espacial de cada atributo ao longo de cada transeção espacial, foram calculadas as funções de autocorrelação e espectral de cada série espacial com o objetivo de identificar a correlação que existe entre observações adjacentes de uma determinada variável. A possível correlação espacial que existe entre observações de duas variáveis foi calculada por meio das funções de crosscorrelação.

A partir da análise das funções acima descritas, pode-se verificar o potencial uso da abordagem de espaço de estados para descrever a distribuição espacial das observações ao longo do espaço bem como o relacionamento entre os atributos do solo e os topográficos. A partir disto, verificou-se o comportamento local de uma variável de interesse (por exemplo, a condutividade hidráulica do solo saturado, o conteúdo de água retido na tensão de 10kPa, etc.) em função do comportamento local das outras variáveis que estão sendo estudadas e assim separar as causas de variação devida à equação de observação e de estado, usando um modelo autoregressivo de espaço de estados descrito em maiores detalhes em Shumway (1988), Shumway e Stoffer (2011) e Reichardt e Timm (2016).

### **5.5.2. Comparação do desempenho dos modelos de espaço de estados e dos modelos de regressão múltipla**

Os desempenhos dos modelos de espaço de estados (modelos locais) foram comparados com os dos modelos de regressão estatística múltipla (modelos globais) envolvendo o mesmo conjunto de variáveis físico-hídricas do solo e topográficas. O coeficiente de determinação ( $r^2$ ) foi utilizado para avaliar e comparar o desempenho dos modelos construídos.

### **5.5.3. Caracterização e quantificação das correlações multi-espaciais entre os atributos do solo e os topográficos usando análises em Wavelets**

A caracterização e quantificação das possíveis correlações multi-espaciais entre os atributos físico-hídricos do solo e os atributos topográficos ao longo das transeções foram avaliadas usando as transformadas de Wavelets univariada bivariada e multivariada.

## **6. Resultados e Discussão**

### **6.1. Artigo 1**

Artigo publicado: Journal Catena

Doi: <https://doi.org/10.1016/j.catena.2020.104583>

### **Identifying regionalized co-variate driving factors to assess spatial distributions of saturated soil hydraulic conductivity using multivariate and state-space analyses**

Luana Nunes Centeno<sup>1</sup>, Luís Carlos Timm<sup>2\*</sup>, Klaus Reichardt<sup>3</sup>, Samuel Beskow<sup>4</sup>, Tamara Leitzke Caldeira<sup>5</sup>, Luciana Montebello de Oliveira<sup>6</sup> and Ole Wendoroth<sup>7</sup>

#### **Abstract**

Saturated soil hydraulic conductivity ( $K_{sat}$ ) is a key factor in hydrological management projects and its variability along the landscape hinders its correct use in the formulation of such projects.  $K_{sat}$  varies under different climatic and

---

<sup>1</sup>PhD student at Water Resources Post-Graduate Program, Center of Technological Development, Federal University of Pelotas, Campus Porto, Rua Gomes Carneiro, n. 01, CEP: 96010-610, Pelotas, Rio Grande do Sul, Brazil. luananunescenteno@gmail.com

<sup>2</sup>Department of Rural Engineering, Faculty of Agronomy, Federal University of Pelotas, Campus Universitário s/n, CEP: 96010-900, Capão do Leão, Rio Grande do Sul, Brazil.

Corresponding author: lctimm@ufpel.edu.br

<sup>3</sup>Soil Physics Laboratory, CENA, University of São Paulo, Piracicaba, São Paulo, Brazil. nikolaus.rei@gmail.com

<sup>4</sup>Center of Technological Development, Federal University of Pelotas, Pelotas, Rio Grande do Sul, Brazil. samuelbeskow@gmail.com

<sup>5</sup>Engineering Center, Federal University of Pelotas, Pelotas, Rio Grande do Sul, Brazil. tamaraleitzkecaldeira@gmail.com

<sup>6</sup>Master Science, Piracicaba, São Paulo, Brazil. lu.montebello@gmail.com

<sup>7</sup>Department of Plant and Soil Sciences, University of Kentucky, Lexington, Kentucky, USA. owendroth@uky.edu

hydrological conditions at spatial scales as reported in several studies. However, co-regionalization of K<sub>sat</sub> remains a challenging aspect with regard to identifying supportive co-variates and suitable spatial models. The objectives of this study were to (i) identify factors that relate K<sub>sat</sub> with soil and topographic attributes and land-use systems along a 15-km transect using principal component analysis, and (ii) describe the spatial continuum of K<sub>sat</sub> across the transect through co-regionalization with autoregressive state-space models. The transect was established in the Fragata River Watershed (FRW), Southern Brazil. One hundred soil sampling points were distributed along the transect at equal distances (150 m). Clay and sand fractions, soil organic carbon content, soil bulk density, soil macroporosity, K<sub>sat</sub>, and the soil water retention curve were determined for the 0-20 cm layer at each point. Topographic attributes were derived from the digital elevation model and a land-use map was derived from satellite images. The highest and lowest spatial variabilities were exhibited by K<sub>sat</sub> and soil organic carbon content, respectively. Applying the state-space approach, spatial relationships among K<sub>sat</sub> and soil and topographic attributes, and land-use systems along the transect, could be found. Principal component analysis used jointly with state-space showed that macroporosity could be used as a proxy to estimate the spatial variation of K<sub>sat</sub> in the FRW watershed, assessing surface and subsurface runoff potentials at areas of different land-use. Further studies should be carried out to investigate the use of the type of land-use system as a soil structural predictor of the spatial variations of K<sub>sat</sub> at the watershed scale since it is nowadays an “easy-to-measure” variable from satellite images.

Keywords: Ksat, soil and topographic attributes, spatial variability, land-use system

## Introduction

Saturated soil hydraulic conductivity (Ksat) is a key hydro-physical attribute used to describe the soil water processes in soil and land surface hydrological models. Therefore, the accurate estimation of Ksat is essential to assess the effects of different land-use systems and managements on soil water dynamics (Arnold et al., 1998; Taskinen et al., 2008; Hu et al., 2015; Morbidelli et al., 2017; Qiao et al., 2018).

Ksat is highly variable in space as reported by Wang et al. (2013), Papanicolaou et al. (2015), and She et al. (2017). In view of this, many studies have focused on characterizing the spatial variability of this parameter under various climatic and hydrologic conditions and also at different spatial scales (Zimmerman et al., 2006; Hasller et al., 2014; Zhao et al., 2016; Baiamonte et al., 2017). Ksat can typically vary by more than two orders of magnitude in catchments as small as  $0.1 \text{ km}^2$  (Loague and Gander, 1990; Picciafuoco et al., 2019). Its variability can be associated to differences in soil material, relief and topography (intrinsic factors) as well as differences in land cover and soil management practices (extrinsic factors). Most of the statistical tools used to estimate and evaluate the spatial variability of Ksat at different scales are based on linear and multiple linear regressions (called Pedotransfer Functions - PTFs), in which Ksat is estimated by using more easily available soil attributes (for example, soil texture, soil bulk density and soil organic carbon). However, most of the PTFs described in the literature ignore the spatial dependence of Ksat and

its influencing factors since they are based on the assumption that the data sets manifest a constant mean along the study area (for instance, Vereecken et al., 1990; Schaap et al., 2001; Ottoni et al., 2019; among others). When the sampling location coordinates and the spatial covariance of K<sub>sat</sub> and its influencing factors in the field are not taken into account in the calculations, erroneous interpretation of the outputs can be obtained (Nielsen and Alemi, 1989), as for instance in analyzing the effects of K<sub>sat</sub> variability on runoff simulations as well as total and peak discharges at a watershed scale.

The K<sub>sat</sub> spatial pattern is affected by the variation of soil textural fractions and of the pore space geometry (Papanicolaou et al., 2015; Baiamonte et al., 2017), topography (Leij et al., 2004; Wang et al., 2013), land management (Price et al., 2010; Salemi et al., 2013) and scale (Kvaernø and Stolte, 2012; Picciafuoco et al., 2019). Multivariate statistical tools like principal component analysis (PCA) and state-space models (SSM) are promising methods to identify the influence of each factor that resumes the principal sources of data variation and to assess the spatial relationships among K<sub>sat</sub> and its underlying factors (Timm et al., 2003; Wendoroth et al., 2003; Oldoni et al., 2019, Reichardt and Timm, 2020). SSM take into account the spatial correlation between variables under study, in which all variables are included in a state vector, and their relationships in the neighborhood are quantified. For this reason, SSM are called space-dependent or local models.

State-space models have successfully been applied in many studies mainly at small scales (Awe et al., 2015; Aquino et al., 2015; Duan et al., 2016; Zhang et al., 2017; Zhang et al., 2019). Very few, if any, studies have addressed the combined performance of SSM and PC analyses in describing the spatial

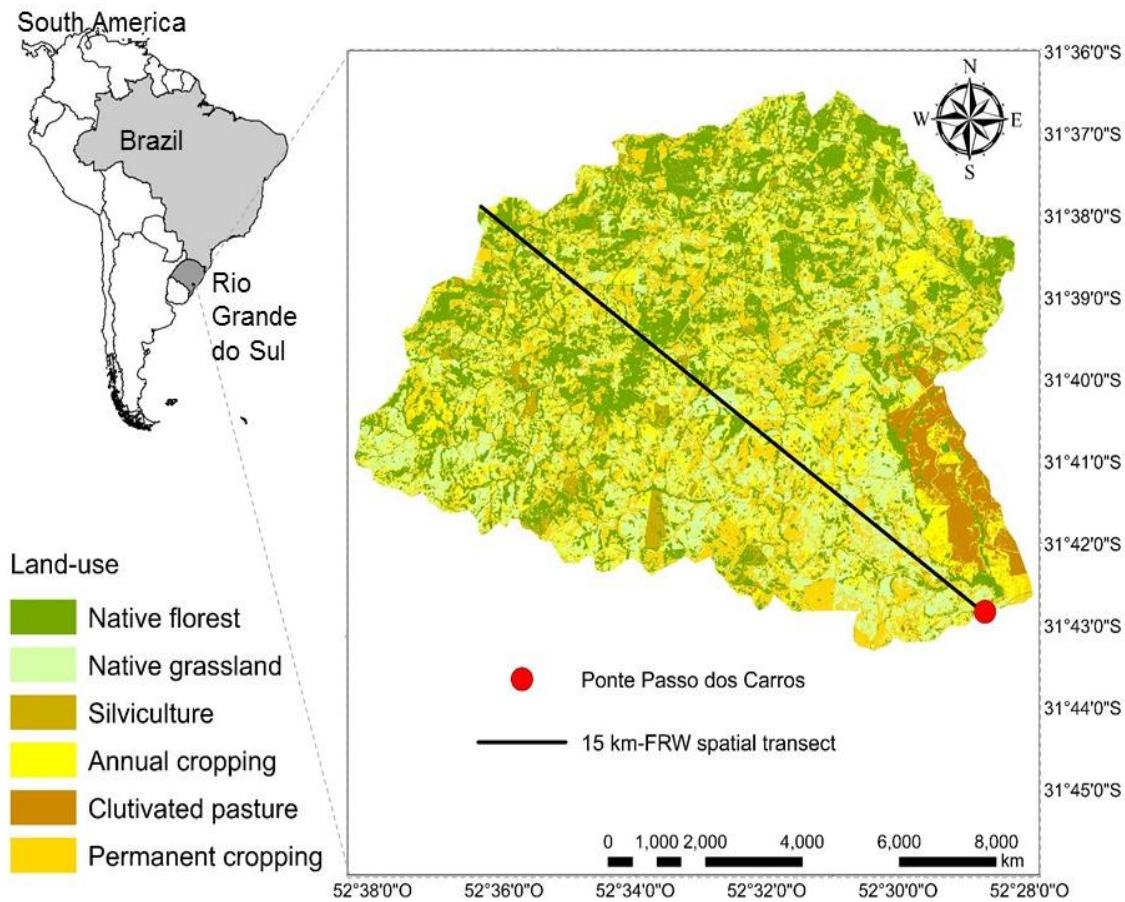
association of Ksat and factors that influence its magnitude and distribution and their quantitative spatial relationships as well. Therefore, we understand that the response of the watershed to Ksat spatial variability is essential since it is a sensitive input parameter for distributed hydrological models (Wang et al., 2013; Hu et al., 2015).

The development of the Fragata River watershed (FRW) is strategic for south Rio Grande do Sul (RS), Brazil. It has to be taken into account that the main river is a tributary to the São Gonçalo channel, with drinking water supply for the state population of almost 200,000 inhabitants, being also an important waterway connecting the Patos and the Mirim lagoons. The FRW suffers from the impact of human activities and is vulnerable to water erosion and floods, causing soil losses with economic and social damage, especially in the surroundings of the city of Pelotas and its 328,000 inhabitants near to the watershed outlet (Beskow et al., 2016). Soil hydro-physical properties (e.g., Ksat) are key factors to understand processes of the hydrological cycle and are critical parameters for the application of hydrological models to support decisions on water resource management (Beskow et al., 2016; She et al., 2017). Among them, Ksat is a sensitive model input parameter (Wang et al., 2013; Hu et al., 2015). Therefore, this study aimed to: (i) identify factors that influence the relationships of Ksat with soil parameters (soil texture, soil bulk density, macroporosity, and soil organic carbon), topography (elevation and slope) and land-use systems across a 15-km transect established in the FRW using principal component analysis, and (ii) describe Ksat distribution across the transect through co-regionalization with state-space analysis and to compare with multiple linear regression models.

## **Materials and methods**

### **Characterization of the area**

The FRW is located in the south of Brazil, Rio Grande do Sul (RS) State (Fig. 1). The portion of the FRW considered in this study is oriented upstream from the watershed outlet, “Ponte Passo dos Carros (PC)”, an area of about 132 km<sup>2</sup>. Köppen’s climate classification indicates that the climate type is Cfa (Kuinchtner and Buriol, 2001), i.e., wet subtropical with an average air temperature of the hottest month of over 22°C. Average annual temperature and rainfall are 17.8°C and 1,366.9 mm, respectively. The main soil types in FRW were classified as Typic Hapludult-Typic Hapludalf Association (37%), Typic Hapludult-Typic Udorthent-Rock Outcrop Association (27%), Typic Albaqualf-Typic Natraqualf-Umblic Endoaqualf Association Albaqualf-Aquic Hapludalf Association (12%) and Typic Udorthent-Typic Hapludult-Rock Outcrop Association (10%) following the US Soil Taxonomy (Soil Survey Staff, 2010).



**Fig. 1 –** Location of the study area in the South America, Brazil and Rio Grande do Sul state maps, land-use system map and the 15 km-spatial transect established in the Fragata River Watershed (FRW), outlet “Passo dos Carros”.

Beginning at the Ponte Passo dos Carros (PC) outlet, and continuing through the watershed in a north-west direction, a 15-km spatial transect through the FRW was created (Fig. 1). One hundred soil sampling points were equidistantly spaced (150 m) along the transect, the coordinates of which were recorded using a portable GPS (Global Positioning System) instrument and identified on the watershed map using ArcGIS (Environmental Systems Research Institute. Redlands, CA).

### **Soil and topographic attributes**

At each sampling location mentioned above, soil samples were collected in the 0 -0.20 m soil layer, for sand (using the Sieving method) and clay (using the Pipette method) textural fraction determinations according to the methodology described in Gee and Bauder (1986). Soil organic carbon content (SOC) was measured using the Walkley-Black method (Nelson and Sommers, 1982). Soil cores were also sampled at each point (in triplicate) from the center of the 0.20 m layer using volumetric rings (0.05 m in diameter and 0.03 m in depth). The samples were used to evaluate soil bulk density (Bd) (Blake and Hartge, 1986), saturated soil hydraulic conductivity (Ksat) using the constant head method (Klute and Dirksen, 1986) and soil water retention curve (soil water contents at matric potentials of 0; -1; -6; -10; -33; -100 and -1,500 kPa) (Klute 1986). The soil water content difference between saturation and -6 kPa of pressure head was taken as soil macroporosity (Macro).

Utilizing a cartographic database of the region (Hasenack and Weber, 2010), a watershed relief of the area in question was obtained, providing contour lines, points of known elevation and vectored hydrography at a scale of 1:50,000. This information was then used as the input into the GIS environment ArcGIS, in order to develop a hydrologically consistent digital elevation model (HCDDEM) for the FRW. Topographic features at each sampling point were evaluated for elevation (Ele) and soil slope (Slo) using ArcMap software (version 10.1). More details about how to estimate both topographic attributes are available in Moore et al. (1993) and Leij et al. (2004).

## Land-use map

A land-use map was constructed by accessing the website of the Brazilian Institute for Space Research (INPE) and accessing various Landsat satellite images. Specifically, Scenes 221\_81 and 222\_82 were utilized and were interpreted using the Environment for Visualizing Images (ENVI) software suggested by Perrotta (2005). Using a maximum-likelihood supervised classification method, the land use map was developed based on the interpretation of these satellite images, along with 100 training samples obtained in the FRW-PC with a portable GPS. These samples allowed the identification of the six main land-uses in the FRW-PC and the development of its land-use map, which resulted in the following distributions: cultivated pasture (59.0%), native forest (20.6%), silviculture (9.0%), annual cropping (6.5%), native grassland (4.5%) and permanent cropland (0.4%) (Fig. 1).

To identify the effects of the six main identified land-use systems (native grassland, annual cropping, permanent cropping, native forest, silviculture and cultivated pasture) on K<sub>sat</sub> variability along our spatial transect, we chose a Curve Number (CN) value for each combination of soil and land use (Table 1). These values were extracted from SCS (1986) and Huffman et al. (2011) for the Antecedent Soil Moisture II considering the Hydrologic Soil Groups proposed by Sartori et al. (2005) for application of the Soil Conservation Service-Curve Number method in Brazilian soils.

**Table 1** – Curve number values for existing combinations of soil and land-use in the FRW-PC

| Land-use type      | Soil classification |           |                       |
|--------------------|---------------------|-----------|-----------------------|
|                    | Albaqualf           | Paleudult | Hapludalf + Udorthent |
| Cultivated pasture | -                   | 74        | 80                    |
| Native forest      | 69                  | 62        | 69                    |
| Silviculture       | -                   | 70        | -                     |
| Annual cropping    | -                   | 84        | 88                    |
| Native grassland   | 78                  | 71        | 78                    |
| Permanent cropland | -                   | -         | 91                    |

### Descriptive statistics

Mean, standard deviation, maximum and minimum values, and coefficient of variation (CV) were calculated for each data set. The CVs were classified according to Wilding and Drees (1983):  $CV \leq 15\%$  - low variability of the data set around their mean;  $15\% < CV \leq 35\%$  - moderate variability; and  $CV > 35\%$  - high variability. All sets of data were submitted to the Kolmogorov-Smirnov (K-S) test (Massey, 1951), at the 5% significance level. A lognormal transformation was applied to those data sets that did not show normality. The Spearman rank correlation coefficient was calculated to evaluate the relationship among Ksat and the other variables. The R statistical software (R core Team, 2016) was used for these calculations.

### State-space approach

For each data set, the autocovariance function  $[C(j)]$  was estimated according to:

$$C(j) = \frac{1}{n} \sum_{i=1}^n [x_i - \bar{x}] [x_{i+j} - \bar{x}] \quad (\text{Eq. 1})$$

where  $\bar{x}$  is the average value of each data set,  $n$  is the total number of measurements and  $j$  is the lag distance between neighbors (Shumway, 1988). The evaluation of the spatial dependence between adjacent measurements, was made by the autocorrelation function  $r(j)$ :

$$r(j) = \frac{C(j)}{C(0)} \quad (\text{Eq. 2})$$

where  $C(j)$  is the covariance function (Eq. [1]) and  $C(0)$  is the variance of the data set.

The amplitude of the confidence interval (CI) for  $r(j)$  values, for each variable, was calculated as:

$$CI \equiv \pm \frac{p}{\sqrt{n}} \quad (\text{Eq. 3})$$

where  $p$  is the accumulated probability for the  $t$  test at 95% probability (Davis, 1986) and  $n$  equal to 100 sampled points.

Crosscorrelation functions between variables were also estimated using Eq. 4, where  $K_{sat}$  was taken as the response variable. The crosscorrelation [ $r_c(j)$ ] between  $K_{sat}$  and all other explanatory variables, was calculated only when the auto-correlation revealed spatial structure (Eqs. 1 and 2).

$$r_c(j) = \frac{C(x_i, y_{i+j})}{s_x \cdot s_y} \quad (\text{Eq. 4})$$

where  $C(x_i, y_{i+j})$  is the covariance between  $x$  and  $y$  with a separation distance  $j$ , and  $s_x$  and  $s_y$  are the standard deviations of  $x$  and  $y$ , respectively. The significance range of  $[r_c(j)]$  was also calculated by Eq. 3. Values of  $r(j)$  (Eq. 2) and  $r_c(j)$  (Eq. 4) can be affected by the path chosen through the spatial transect (Fig. 1). Therefore, data sets were also arranged from the west-north direction along the 15-km spatial transect (i.e., from location 100 to location 1) and the direction with the largest values of  $r(j)$  and  $r_c(j)$  was chosen implying that this direction was used to assess the performance of the state-space analysis.

Based on the analysis of the auto-correlations (Eqs. 2 and 3) and cross-correlations (Eqs. 3 and 4) we identified the variables to be used in the SSM. To have the same order of magnitude, original data were scaled according to Eq. 5 (Hui et al., 1998):

$$y(x_i) = \frac{Y(x_i) - (\bar{Y} - 2s)}{4s} \quad (\text{Eq. 5})$$

where  $y(x_i)$  is scaled,  $Y(x_i)$  measured,  $\bar{Y}$  the average of  $Y$ , and  $s$  is the standard deviation.

The state-space methodology is represented as a dynamic linear system of two vector equations (Shumway, 1988; Nielsen and Wendoroth, 2003):

$$Y(x_i) = M_{pp} \cdot Z(x_i) + v_Y(x_i) \quad (\text{Eq. 6})$$

$$Z(x_i) = \varphi_{pp} \cdot Z(x_{i-1}) + w_Z(x_i) \quad (\text{Eq. 7})$$

The measurement vector  $Y(x_i)$  has a relation to the non-measurable state vector  $Z(x_i)$  through a measurement matrix  $M_{pp}$  and the associated measurement error  $v_Y(x_i)$  (Eq. 6 – the observation equation). The state vector  $Z(x_i)$  has a relation to the same vector at position  $i-1$  with  $\varphi_{pp}$ , the state coefficient matrix (called the transition matrix) and through a state error  $w_Z(x_i)$  of a first order auto-regressive model (Eq. 7 – the state equation).  $v_Y(x_i)$  and  $w_Z(x_i)$  are assumed to be normally distributed, independent and not correlated between themselves for all lags. The ASTSA (Applied Statistical Time Series Analysis software, Shumway, 1988) was applied to run the state-space approach.

The performance of the SSM in describing the local spatial relationships of Ksat with the other selected soil and topographic attributes and land-use systems was evaluated for all combinations between them. Based on the resulting spatial estimations, the SSM of Ksat was evaluated using the coefficient of determination ( $r^2$ ) calculated through linear regression between measured and estimated values of Ksat for each combination of variables. Furthermore, each SSM of Ksat was compared with its equivalent multiple linear regression model (MLRM).

### **Multivariate statistical analysis**

Before applying the multivariate statistical analysis, each data set was scaled using Eq. 5 to have data in the same order of magnitude. As we were interested in relative variability, scaling makes variables comparable and this implies, necessarily, that the variance and covariance matrixes are equal to the correlation matrix.

To reduce the dimension of soil data sets, the principal component analysis (PCA) was used (Jolliffe, 2002). PCA is a dimension reduction technique

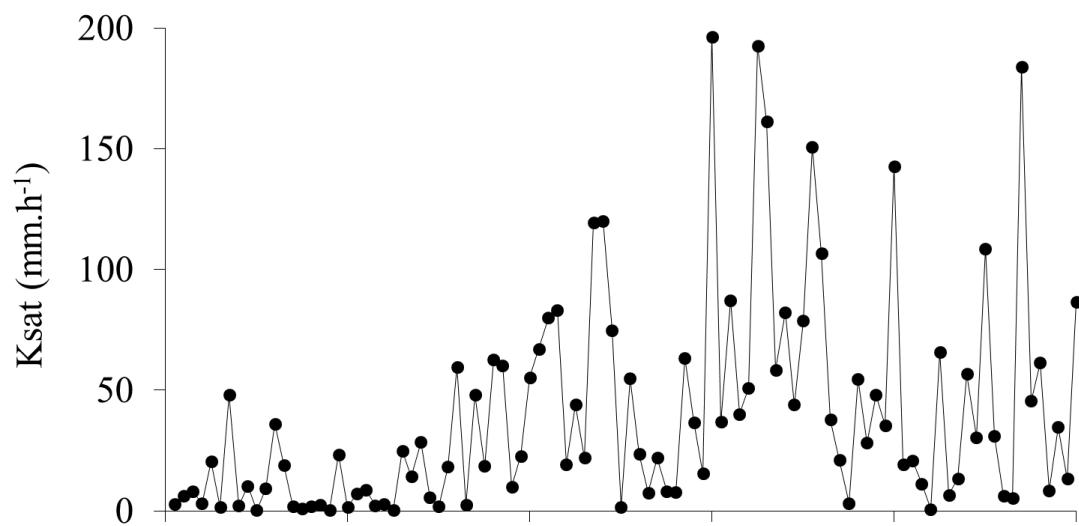
that identifies orthogonal linear recombinations that resume the main sources of variation of the data (Xin-Zhong et al., 2009). A correlation matrix of chosen variables corresponds to an input for analysis *in lieu* of a covariance matrix, result being a normalized PCA. In most cases, the first or second components explain the major part of the total variance of the data. Here, only PCs that explain at least 70% of the total variance were selected and those for which each calculated eigenvalue was  $>1.0$  (Jolliffe, 2002). After this, the factorial coordinates were extracted from the decomposition of the correlation matrix. It contains the factor loadings (FL) for each variable on each PC. Loading values show the degree of correspondence between the variable and the factor. High loadings make a variable representative of the factor, and therefore FLs can interpret the role that each variable plays in the definition of each factor (Hair et al., 2009). The factor loading values were used to identify in which principal component each selected soil data set was included. Then, factorial coefficients (100 values) were extracted for each selected principal component. The “base” R code was used in the multivariate analysis (R Core Team, 2016).

## **Results and Discussion**

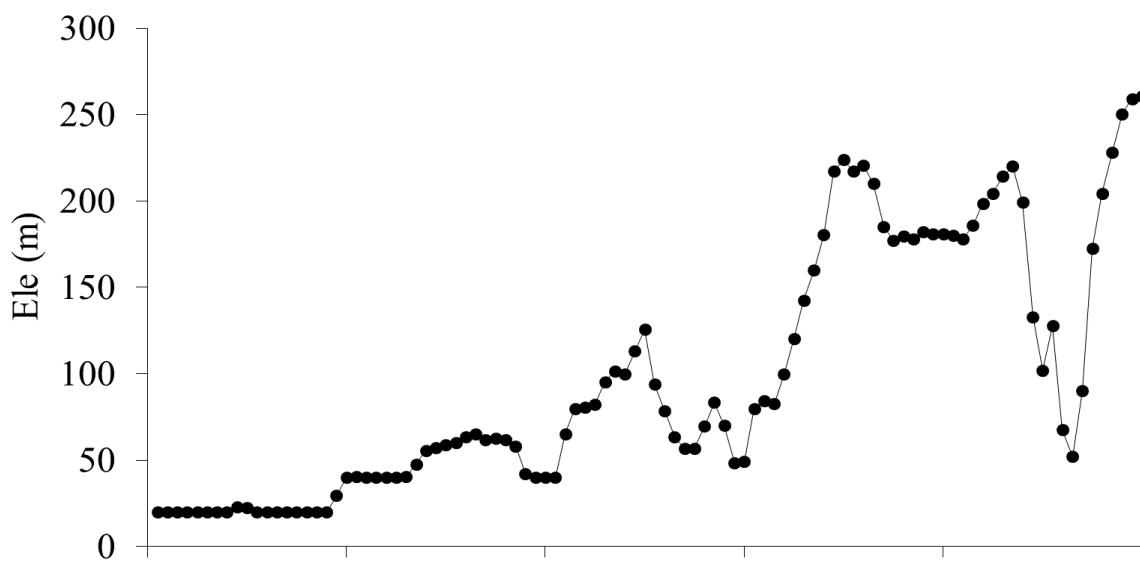
The Ksat values distributed along the 15 km-spatial transect indicate a range of magnitude from  $0.27 \text{ mm.h}^{-1}$  (minimum value 1.5 km from the watershed outlet) to  $196.38 \text{ mm.h}^{-1}$  (maximum value at the distance of 9.0 km from the watershed outlet). The mean Ksat value ( $39.93 \text{ mm.h}^{-1}$ ) in the FRW-PC can be considered to potentially generate surface runoff according to the Ksat classification proposed by Pruski et al. (1997) for Brazilian soils, aiming at hydrological studies. Data also show a small point-to-point fluctuation of Ksat,

from the origin of the transect until 4.95 km, changing to large point-to-point fluctuations until the end of the transect (Fig. 2A). Elevation ranged from 20 to 261 m along the 15 km-spatial transect, with an arithmetic mean value of 98 m (Fig. 2B) while the soil slope ranged from 3% to 45% (Fig. 2C). The distribution of SOC ranged from 1.89% (1.5 km from the origin of the transect) to 3.02% (7.5 km from the origin) along the transect, with a mean of 2.21% (Fig. 2D). The soil organic carbon distribution showed a relative spatial stability along the transect. Clay content values exhibited large oscillation from the middle to the end of the transect (Fig. 2E), ranging from 10 to 39%. Sand content values ranged from 22% (minimum value) to 84% (maximum value), with an arithmetic mean value of 65% along the 15 km-spatial transect (Fig. 2F). Macroporosity values ranged from a minimum value of 2.5% to a maximum of 33.4% with an arithmetic mean value of 13% (Fig. 2G). There is a clear trend of an increase of soil macroporosity values along the transect, presenting a great oscillation from the middle to the end of the transect. An opposite trend is observed for the distribution of Bd (Fig. 2H), with a mean value of 1.47 g.cm<sup>-3</sup> ranging from 1.02 g.cm<sup>-3</sup> to 1.74 g.cm<sup>-3</sup>.

A

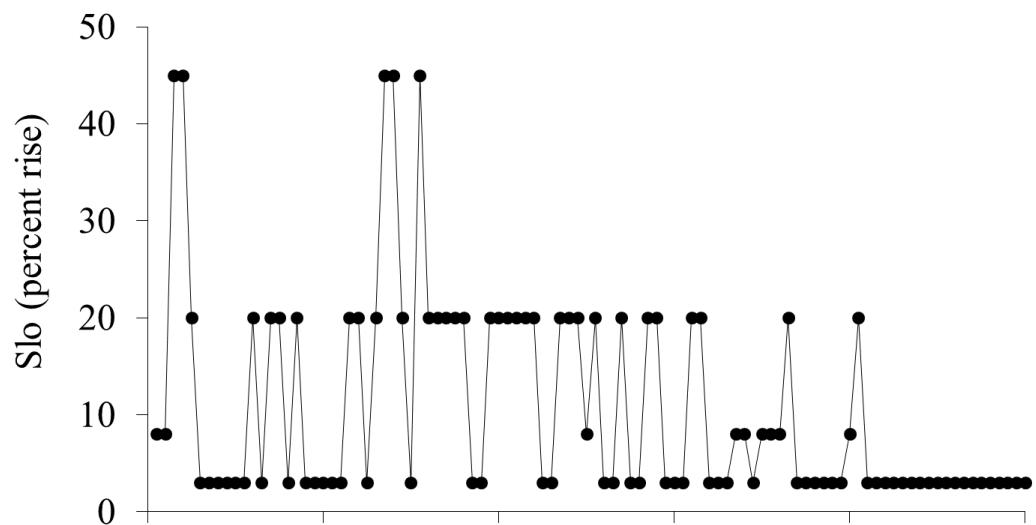


B

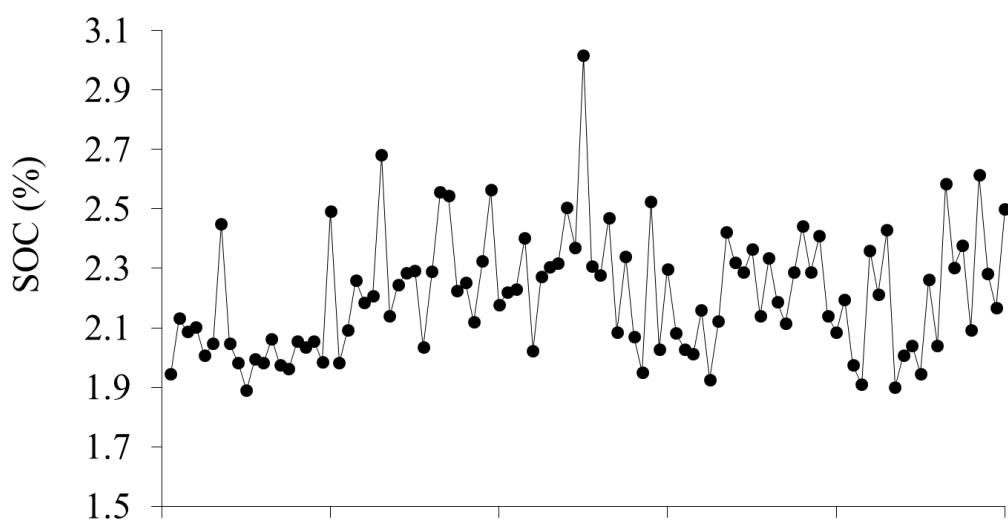


**Fig. 2** – Spatial distribution along the 15 km-spatial transect for: (A) saturated soil hydraulic conductivity, K<sub>sat</sub> and (B) elevation, Ele.

C

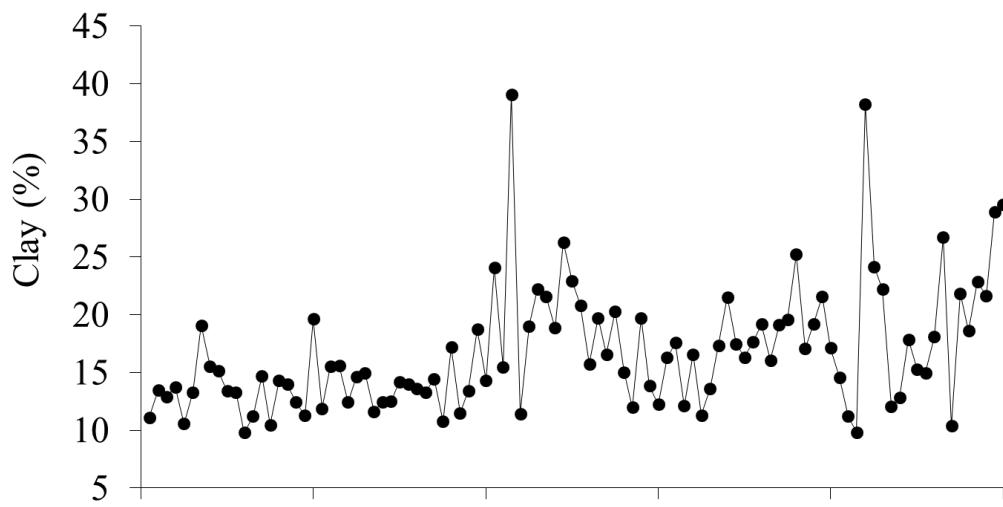


D

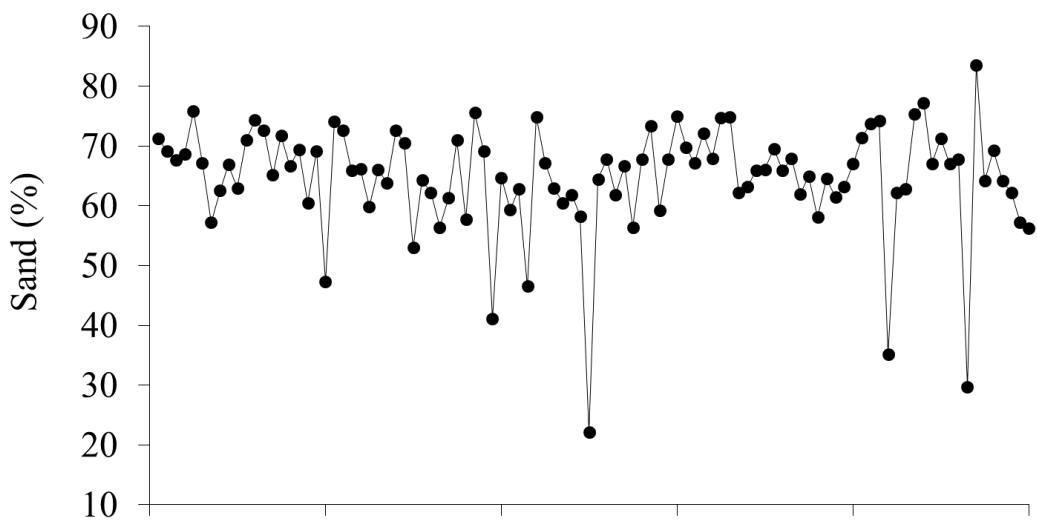


**Fig. 2** – Spatial distribution along the 15 km-spatial transect for: (C) soil slope, Slo and (D) soil organic carbon content, SOC.

E

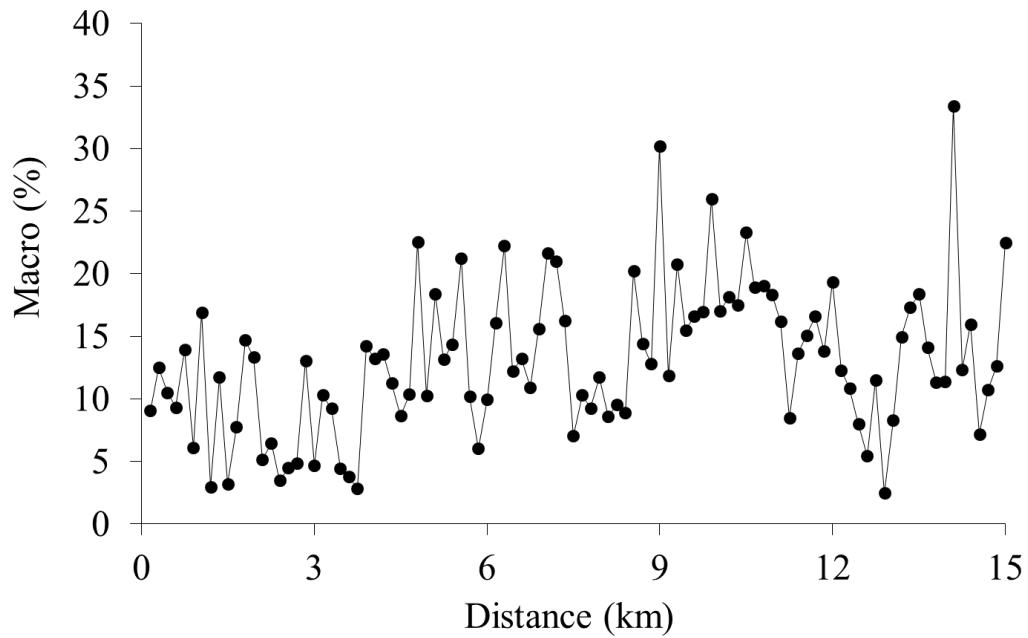


F

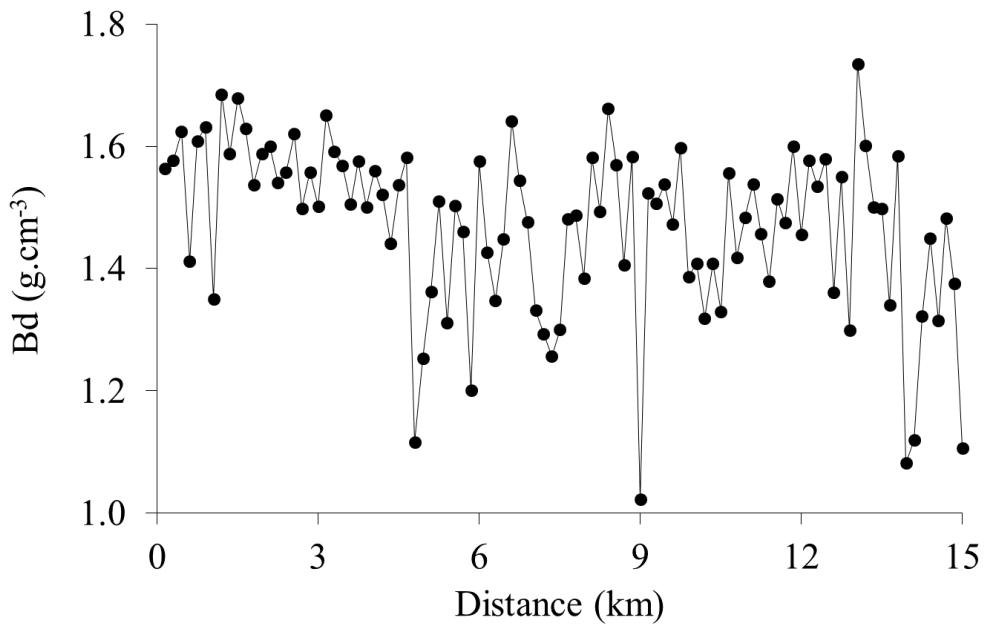


**Fig. 2** – Spatial distribution along the 15 km-spatial transect for: (E) Clay and (F) Sand.

G



H



**Fig. 2 –** Spatial distribution along the 15 km-spatial transect for: (G) soil macroporosity, Macro; and (H) soil bulk density, Bd.

The increasing tendency of Ksat (Fig 2A), SOC (Fig 2D) and Macro (Fig 2G) along the transect and decreasing tendency for Bd (Fig 2H), suggests that there could be a relationship between these soil attributes and Ele (Fig 2B). Clay (Fig. 2E) and sand (Fig. 2F) content values did not show a clear trend along the 15 km-spatial transect. This observation suggests that soil texture is not directly statistically related with Ksat. Similar results were also found by Picciafuoco et al. (2019).

The CV values for all studied data sets ranged from 9% to 112% (Table 2). The lowest CV was obtained for the SOC data set and the highest one for Ksat along the transect. The high spatial variability of Ksat is well-known regardless of the measurement methodology, geographical location, land use, soil type or scale (Papanicolaou et al., 2015; Baiamonte et al., 2017; Picciafuoco et al., 2019). The distributions of Ksat, Ele, Slo and Macro exhibited high variability ( $CV > 35\%$ ) while those of SOC, Sand and Bd showed low variability ( $CV \leq 15\%$ ) along the transect, by Wilding and Drees' (1983) CV classification. The distribution of clay content values showed moderate variability along the transect ( $15\% < CV \leq 35\%$ ). At the sampling scale applied in this study, the measurements of SOC, clay and sand contents, Macro and Bd, and topographic (Ele and Slo) attributes could be considered as potential explanatory variables of the spatial behavior of the response soil hydro-physical variable (Ksat) along the 15 km-transect. Strong relationships have been published among Ksat and topographic and soil attributes in other studies (Leij et al., 2004; Salemi et al., 2013; Zimmerman et al., 2013; Wang et al., 2013; She et al., 2017).

**Table 2 – Descriptive statistics and the non-parametric Kolmogorov-Smirnov test for all values of saturated soil hydraulic conductivity and the other soil and topographic attributes and land-use systems along the 15 km-Fragata River Watershed spatial transect**

| Variables                       | Mean  | SD     | Min  | Max    | CV                    | K-S       |
|---------------------------------|-------|--------|------|--------|-----------------------|-----------|
|                                 |       |        |      |        | Wilding and Drees (%) | p-value   |
| <b>Ksat (mm.h<sup>-1</sup>)</b> |       |        |      |        |                       |           |
| 1)                              | 39.93 | 44.74  | 0.27 | 196.38 | 112                   | 1.75E-03  |
| Elev (m)                        | 98    | 71.779 | 20   | 261    | 73                    | 6.49E-03  |
| Slope (%)                       | 11    | 10.958 | 3    | 45     | 101                   | 2.20E-16  |
| SOC (%)                         | 2.21  | 0.204  | 1.89 | 3.02   | 9                     | 3.37E-01* |
| Clay (%)                        | 17    | 5.401  | 10   | 39     | 32                    | 1.33E-01* |
| Sand (%)                        | 65    | 9.225  | 22   | 84     | 14                    | 1.62E-02  |
| Macro (%)                       | 13    | 5.926  | 2.5  | 33.4   | 46                    | 9.12E-01* |
| Bd (g.cm <sup>-3</sup> )        | 1.47  | 0.14   | 1.02 | 1.74   | 10                    | 9.66E-02* |
| Land-use <sup>†</sup>           | 76    | 6.03   | 62   | 91     | 9                     | 2.75E-07  |

Ksat: saturated soil hydraulic conductivity; Elev: Elevation; Slope: soil slope; SOC: soil organic carbon content; Clay and Sand: clay and sand contents; Macro: soil macroporosity; Bd: soil bulk density; <sup>†</sup>Land-use classification was derivable from the runoff curve number (CN) tables (USDA-NRCS); CV: coefficient of variation. SD: standard deviation; Min and Max: minimum and maximum values, respectively; CV: coefficient of variation; K-S = p values of the Kolmogorov-Smirnov test; \*normal distribution data considering p = 0.05.

The relationships between Ksat and the other variables were examined by calculating the Spearman correlation coefficient at 5% of significance level (p-value = 5%) (Table 3). Ele, Slo and Macro exhibited a significant ( $p < 0.05$ ) positive correlation with Ksat, while Bd was significantly negatively correlated. Such results were also found by Baiamonte et al. (2017). Bd mainly affects the macro-structure of the soil, which directly affects Ksat. SOC, clay and sand had low and not significant correlations with Ksat ( $p > 0.05$ ).

**Table 3 –** Spearman's correlation coefficient values among saturated soil hydraulic conductivity and the other soil and topographic attributes and land-use systems along the 15 km-Fragata River Watershed spatial transect

| Attribute                             | Spearman correlation coefficient | p-value   |
|---------------------------------------|----------------------------------|-----------|
| Saturated soil hydraulic conductivity | 1                                | -         |
| Elevation                             | 0.481*                           | 4.10E-04  |
| Soil slope                            | 0.455*                           | 2.03E-03  |
| Aspect                                | 0.138                            | 1.70E-01  |
| Organic Carbon content                | 0.166                            | 9.87E-02  |
| Clay                                  | 0.193                            | 5.47E-02  |
| Sand                                  | 0.101                            | 3.19E-01  |
| Macroporosity                         | 0.858*                           | < 2.2E-16 |
| Soil bulk density                     | -0.389*                          | 6.20E-04  |
| Land-use                              | -0.008                           | 9.36E-01  |

\*significant Spearman correlation coefficient at p value = 5% of probability level.

Several studies have shown that land-use systems affect the Ksat values and thereby their spatial variation in a watershed (Zimmermann et al., 2006; Taskinen et al., 2008; Bonell et al., 2010; Price et al., 2010; Salemi et al., 2013). For instance: Leij et al. (2004) examined the relation between Ksat, soil properties and topographic attributes along a 5 km-spatial transect in Basilicata, Southern Italy. These authors found no correlation between Ksat and other basic soil properties and interpreted this results being a consequence of soil sampling close the surface, where Ksat is mostly affected by different land-use systems and biological activity; Picciafuoco et al. (2019), in a small Austrian catchment, also suggested that soil texture does not have a direct effect on Ksat, since a wider Ksat variation was related to lower variability of sand and clay contents. Therefore, the authors mentioned that a wider variation of Ksat may be caused by the characteristics of each land-use system, rather than by a direct dependency of Ksat on soil textural composition. For instance, Picciafuoco et al.

(2019) observed that minimum and maximum Ksat values in arable lands were significantly larger by more than 50% than those obtained in pasture plots. However, Table 3 shows that there exists a very weak association of land-use system, as expressed in terms of CN-values, and Ksat in our study when analyzed by the magnitude of the Spearman correlation coefficient between them being negative and no significant at the 5% of probability level. It is worth to emphasize that in the calculus of the Spearman correlation coefficient the coordinates of the data in the field are disregarded.

Mean values of Ksat, SOC, Macro, BD, clay and sand contents of each land-use system are presented in Table 4. Data indicate that there exists a relationship among values of Ksat, SOC, Macro and BD, and the six main different land-use systems, conversely which was found in Table 3. Native forests provide higher values of Ksat, SOC and Macro and lower values of Bd when compared to the other land-use systems. On average, native forest soils had Ksat values approximately 3.9 and 2.4 times greater than those found under permanent cropping and cultivated pasture soils in our study, respectively. Cultivated soils under native vegetation (e.g., native forest) when compared with soils impacted by agricultural land-use (e.g., cultivated pasture) generally presented lower Bd and higher Ksat and Macro as a result of ample organic inputs and abundant burrowing fauna (Viola et al., 2013).

**Table 4 –** Mean values of saturated soil hydraulic conductivity, soil organic carbon, macroporosity, soil bulk density, clay and sand contents at each land-use system identified along the 15 km-Fragata River Watershed spatial transect

| Land-use classes   | Ksat (mm.h <sup>-1</sup> ) | SOC (%) | Macro (%) | Bd (g.cm <sup>-3</sup> ) | Clay (%) | Sand (%) |
|--------------------|----------------------------|---------|-----------|--------------------------|----------|----------|
| Permanent cropping | 13.0                       | 2.23    | 16.1      | 1.47                     | 20       | 63       |
| Cultivated pasture | 21.6                       | 2.31    | 15.1      | 1.44                     | 15       | 66       |
| Native grassland   | 39.0                       | 2.17    | 11.3      | 1.51                     | 16       | 66       |
| Annual cropping    | 47.6                       | 2.23    | 17.6      | 1.42                     | 20       | 63       |
| Silviculture       | 50.0                       | 2.35    | 11.8      | 1.41                     | 12       | 60       |
| Native forest      | 51.2                       | 2.38    | 19.6      | 1.26                     | 19       | 61       |

Ksat = saturated soil hydraulic conductivity; SOC = soil organic carbon; Macro = soil macroporosity; Bd = soil bulk density; Clay and Sand = clay and sand contents, respectively

All studied variables exhibited point-to-point fluctuations along the 15 km-spatial transect (Figs. 2A-H), a result of local feature and, therefore, may be more correctly analyzed by a local statistical model (e.g., state-space model), which allows expressing the soil spatial variability. Before applying the state-space analysis, the autocorrelation (ACF) and crosscorrelation (CCF) functions were calculated to evaluate the spatial correlation of the observations of each data set and that one between Ksat and other variables. To evaluate the effect of the path chosen along the 15 km-spatial transect, data sets were arranged in the north-west (from location 1 to location 100) and in the west-north (from location 100 to location 1) directions. Table 5 reveals that, in general, point-to-point fluctuations

of Ksat and other variables presented similar values of autocorrelation (Eq. 2) and crosscorrelation (Eq. 4) when comparing both arrangements. However, we chose to arrange data sets in the north-west path (from location 1 to location 100) since at practical point of view we think that it is easier to carry out field campaigns from the watershed outlet.

**Table 5 – (A)** Autocorrelation [ $r(j)$ ] and (B) crosscorrelation [ $r_c(j)$ ] values for Ksat and all co-variables that compose the study along the 15 km-spatial transect. Data sets were arranged in the north-west (from location 1 to location 100) and in the west-north (from location 100 to location 1) directions

(A)

| Data sets arranged in the north-west direction |          |         |         |       |       |          |       |       |        |  |
|--|----------|---------|---------|-------|-------|----------|-------|-------|--------|--|
| Lag  | log Ksat | log Ele | log Slo | SOC   | Clay  | log Sand | Macro | Bd    | log LU |  |
| 1  | 0.322    | 0.952   | 0.411   | 0.186 | 0.218 | -0.044   | 0.308 | 0.204 | 0.258  |  |
| 2  | 0.395    | 0.887   | 0.156   | 0.265 | 0.286 | -0.009   | 0.328 | 0.252 | 0.196  |  |
| 3  | 0.257    | 0.830   | 0.194   | 0.220 | 0.136 | -0.013   | 0.135 | 0.167 | 0.348  |  |
| 4  | 0.318    | 0.774   | 0.137   | 0.096 | 0.208 | -0.019   | 0.216 | 0.098 | 0.153  |  |
| 5  | 0.387    | 0.718   | 0.191   | 0.132 | 0.137 | -0.035   | 0.269 | 0.051 | 0.201  |  |

| Data sets arranged in the west-north direction |          |         |         |       |       |          |       |       |        |  |
|--|----------|---------|---------|-------|-------|----------|-------|-------|--------|--|
| Lag  | log Ksat | log Ele | log Slo | SOC   | Clay  | log Sand | Macro | Bd    | log LU |  |
| 1  | 0.322    | 0.953   | 0.412   | 0.183 | 0.218 | -0.020   | 0.308 | 0.204 | 0.255  |  |
| 2  | 0.393    | 0.903   | 0.282   | 0.264 | 0.286 | -0.020   | 0.328 | 0.253 | 0.193  |  |
| 3  | 0.259    | 0.856   | 0.344   | 0.220 | 0.137 | -0.061   | 0.135 | 0.167 | 0.346  |  |
| 4  | 0.313    | 0.816   | 0.157   | 0.093 | 0.208 | 0.007    | 0.215 | 0.098 | 0.151  |  |
| 5  | 0.390    | 0.779   | 0.120   | 0.131 | 0.137 | -0.060   | 0.269 | 0.051 | 0.198  |  |

(B)

| Data sets arranged in the north-west direction |         |         |       |       |          |       |        |        |  |
|--|---------|---------|-------|-------|----------|-------|--------|--------|--|
| log Ksat                                       |         |         |       |       |          |       |        |        |  |
| Lag  | log Ele | log Slo | SOC   | Clay  | log Sand | Macro | Bd     | log LU |  |
| -5   | 0.450   | 0.008   | 0.112 | 0.263 | -0.087   | 0.306 | -0.223 | 0.131  |  |
| -4   | 0.454   | -0.161  | 0.214 | 0.373 | -0.136   | 0.262 | -0.275 | 0.159  |  |
| -3   | 0.452   | -0.065  | 0.126 | 0.226 | -0.126   | 0.189 | -0.182 | 0.111  |  |
| -2   | 0.469   | -0.050  | 0.139 | 0.253 | -0.103   | 0.351 | -0.202 | 0.026  |  |
| -1   | 0.492   | -0.018  | 0.167 | 0.195 | -0.042   | 0.300 | -0.225 | 0.068  |  |
| 0  | 0.486   | 0.093   | 0.081 | 0.105 | 0.268    | 0.826 | -0.329 | -0.007 |  |
| 1  | 0.433   | -0.098  | 0.226 | 0.242 | -0.191   | 0.332 | -0.237 | -0.057 |  |
| 2  | 0.411   | -0.114  | 0.232 | 0.197 | -0.082   | 0.368 | -0.254 | 0.089  |  |
| 3  | 0.406   | -0.055  | 0.118 | 0.135 | -0.015   | 0.176 | -0.185 | 0.063  |  |
| 4  | 0.377   | 0.045   | 0.180 | 0.200 | -0.078   | 0.246 | -0.248 | -0.098 |  |
| 5  | 0.366   | -0.002  | 0.130 | 0.188 | -0.013   | 0.328 | -0.276 | -0.134 |  |
| Data sets arranged in the west-north direction |         |         |       |       |          |       |        |        |  |
| Ksat   |         |         |       |       |          |       |        |        |  |
| Lag  | log Ele | log Slo | SOC   | Clay  | log Sand | Macro | Bd     | log LU |  |
| -5   | 0.361   | 0.198   | 0.129 | 0.186 | -0.042   | 0.326 | -0.275 | -0.135 |  |
| -4   | 0.386   | 0.212   | 0.179 | 0.200 | -0.039   | 0.244 | -0.246 | -0.098 |  |
| -3   | 0.398   | 0.027   | 0.117 | 0.134 | -0.083   | 0.176 | -0.184 | 0.063  |  |
| -2   | 0.436   | 0.148   | 0.233 | 0.196 | -0.077   | 0.365 | -0.253 | 0.089  |  |
| -1   | 0.446   | 0.070   | 0.223 | 0.240 | -0.168   | 0.330 | -0.235 | -0.057 |  |
| 0  | 0.498   | 0.050   | 0.087 | 0.108 | 0.269    | 0.824 | -0.330 | -0.006 |  |
| 1  | 0.486   | 0.211   | 0.167 | 0.197 | -0.040   | 0.299 | -0.227 | 0.068  |  |
| 2  | 0.470   | 0.218   | 0.142 | 0.254 | -0.117   | 0.351 | -0.205 | 0.026  |  |
| 3  | 0.454   | 0.300   | 0.126 | 0.228 | -0.141   | 0.191 | -0.180 | 0.111  |  |
| 4  | 0.457   | 0.246   | 0.216 | 0.376 | -0.167   | 0.259 | -0.278 | 0.159  |  |
| 5  | 0.446   | 0.213   | 0.113 | 0.264 | -0.096   | 0.309 | -0.227 | 0.131  |  |

Table 5A shows that adjacent observations of each data set manifested spatial dependence at least of one lag (in our study, 1 lag = 150 m) using a t test at the 5% probability, except for the Sand data set in which its adjacent observations were not spatially dependent, thus varying in a random way at the sampling scale. For instance, observations of Ksat were spatially dependent more than five lags in this study because ACF values were higher than 0.196, while Macro and Land-use were spatially dependent up to two and three lags, respectively, as shown in Table 5A.

The crosscorrelation (CCF) analysis can be used to measure the spatial correlation structure of two soil variables (Wendroth et al., 1997). In our case, it was used to calculate the spatial correlation range between log Ksat and: (i) log Ele; (ii) log Slo; (iii) SOC; (iv) Clay; (v) Macro; (vi) Bd; and (vii) log Land-use. The crosscorrelation between log Ksat and log Ele (Table 5B) showed a strong spatial correlation between them, with the t test at 5% probability level. On the other hand, the crosscorrelogram between log Ksat and log Slo indicated that the topographic attribute Slo was not spatially correlated with Ksat in our study. The crosscorrelogram between log Ksat and SOC showed a spatial dependence between them at 2 lags at one sense, i.e., pairs of  $[\log \text{Ksat}(x_i), \text{SOC}(x_{i+1})]$  were correlated only on one hand ( $j = +2$  lags) although the crosscorrelation coefficient value (0.167) was slightly lower than the confidence interval value (0.196) on the other hand ( $j = -1$  lag). A spatial dependence up to 2 lags was found between log Ksat and Clay. Among soil attributes, the strongest positive spatial correlation was found for log Ksat with Macro, while the strongest negative correlation was obtained for log Ksat with Bd (Table 5B). The crosscorrelogram between log Ksat

and log Land-use showed that they were not correlated at our sampling scale, at 5% of probability by using a t-test (Table 5B). However, we assumed here that the Land-use variable was adequate to be included in first order autoregressive SSM since it could be seen from Table 4 that there is a relation between data of Ksat and land-use systems, identified along the 15 km-spatial transect. As we mentioned before, strong and significant relations between Ksat and land-use systems have already been documented in the literature.

State-space equations of Ksat (expressed as  $\log_{10}$ ) and values of their coefficients of determination ( $r^2$ ) are presented in Table 6. Using all selected soil and topographic attributes and land-use systems, 96.4% of the total variability of log Ksat along the transect were explained by the SSM. The best six-variable SSM was obtained when using Ele, SOC, Clay, Macro and Bd variables as predictors of Ksat (Table 6). The performance of the six-variable SSM, which did not include Macro, was the worst to estimate log Ksat ( $r^2 = 0.898$ ) as compared to those ones. The worst five-variable SSM of log Ksat was found using Ele (expressed as  $\log_{10}$ ), SOC, Clay and Bd as explanatory variables ( $r^2 = 0.665$ , Table 6). Among the four-variable SSM the best performance was achieved by that one using Ele, SOC and Macro ( $r^2 = 0.999$ ) and the worst was that using Ele, Clay and Bd variables ( $r^2 = 0.307$ ). The best performance of a three-variable state-space models of Ksat was found when using SOC and Macro as explanatory variables ( $r^2 = 0.989$ ), while the worst one was found when using Ele and SOC ( $r^2 = 0.231$ ). The best performance of a two-variable state-space model was found when using the local variations of Macro across the transect to estimate the local variations of Ksat ( $r^2 = 0.800$ ). On the other hand, the worst performance of the bivariate state-space model was using the local variations of

$\text{Ele}$  across the transect to estimate  $K_{\text{sat}}$  ( $r^2 = 0.456$ ). Soil formation is a result of vegetation, parent material, microclimate, soil water conditions, and material transport, all of them being influenced by topography (Leij et al., 2004). Topographic features can be readily obtained from DEMs. Furthermore, if soil hydraulic properties can be accurately predicted replacing “difficult-to-measure” by “easy-to-measure” topographic features, labor and cost can be minimized (Si and Zeleke, 2005; She et al., 2015, 2017). The selected topographic attribute (elevation) appeared in all worst state-space model combinations indicating that it is not a good predictor to estimate  $K_{\text{sat}}$  in our study (Table 6).

**Table 6** – State-space equations of saturated soil hydraulic conductivity ( $K_{\text{sat}}$  expressed as  $\log_{10}$ ) using all combinations of selected soil and topographic attributes and land-use systems, and  $r^2$  values from linear regression between estimated and measured values of  $\log K_{\text{sat}}$

| All variables  | $r^2$ |
|--|-------|
| $(\log K_{\text{sat}})_i = -0.036(\log K_{\text{sat}})_{i-1} + 0.151(\log \text{Ele})_{i-1} + 0.207(\text{SOC})_{i-1} - 0.109(\text{Clay})_{i-1} + 0.077(\text{Macro})_{i-1} + 0.214(\text{Bd})_{i-1} + 0.489(\log \text{LU})_{i-1} + w_i$ | 0.964 |
| 6 Variables  | $r^2$ |
| $(\log K_{\text{sat}})_i = -0.077(\log K_{\text{sat}})_{i-1} + 0.421(\log \text{Ele})_{i-1} + 0.408(\text{SOC})_{i-1} - 0.233(\text{Clay})_{i-1} + 0.3122(\text{Macro})_{i-1} + 0.179(\text{Bd})_{i-1} + w_i$                              | 0.999 |
| $(\log K_{\text{sat}})_i = 0.085(\log K_{\text{sat}})_{i-1} - 0.060(\log \text{Ele})_{i-1} + 0.151(\text{SOC})_{i-1} + 0.032(\text{Clay})_{i-1} + 0.053(\text{Macro})_{i-1} + 0.737(\log \text{LU})_{i-1} + w_i$                           | 0.969 |
| $(\log K_{\text{sat}})_i = 0.088(\log K_{\text{sat}})_{i-1} + 0.076(\log \text{Ele})_{i-1} + 0.188(\text{SOC})_{i-1} - 0.084(\text{Clay})_{i-1} + 0.141(\text{Bd})_{i-1} + 0.584(\log \text{LU})_{i-1} + w_i$                              | 0.898 |
| $(\log K_{\text{sat}})_i = 0.046(\log K_{\text{sat}})_{i-1} + 0.064(\log \text{Ele})_{i-1} + 0.143(\text{SOC})_{i-1} + 0.024(\text{Macro})_{i-1} + 0.146(\text{Bd})_{i-1} + 0.570(\log \text{LU})_{i-1} + w_i$                             | 0.962 |
| $(\log K_{\text{sat}})_i = -0.084(\log K_{\text{sat}})_{i-1} + 0.186(\log \text{Ele})_{i-1} + 0.105(\text{Clay})_{i-1} + 0.166(\text{Macro})_{i-1} + 0.359(\text{Bd})_{i-1} + 0.264(\log \text{LU})_{i-1} + w_i$                           | 0.968 |
| $(\log K_{\text{sat}})_i = 0.051(\log K_{\text{sat}})_{i-1} + 0.133(\text{SOC})_{i-1} + 0.013(\text{Clay})_{i-1} + 0.049(\text{Macro})_{i-1} + 0.066(\text{Bd})_{i-1} + 0.683(\log \text{LU})_{i-1} + w_i$                                 | 0.926 |
| 5 Variables  | $r^2$ |

|   |                      |
|---|----------------------|
| <b>(log Ksat)<sub>i</sub></b> = -0.269(log Ksat) <sub>i-1</sub> + 0.279(log Ele) <sub>i-1</sub> + 0.926(SOC) <sub>i-1</sub> - 0.397(Clay) <sub>i-1</sub> + 0.482(Macro) <sub>i-1</sub> + w <sub>i</sub> | <b>0.998</b>         |
| (log Ksat) <sub>i</sub> = 0.307(log Ksat) <sub>i-1</sub> + 0.451(log Ele) <sub>i-1</sub> + 0.630(SOC) <sub>i-1</sub> - 0.595(Clay) <sub>i-1</sub> + 0.211(Bd) <sub>i-1</sub> + w <sub>i</sub>           | 0.665                |
| (log Ksat) <sub>i</sub> = 0.119(log Ksat) <sub>i-1</sub> - 0.042(log Ele) <sub>i-1</sub> + 0.119(SOC) <sub>i-1</sub> + 0.047(Clay) <sub>i-1</sub> + 0.752(log LU) <sub>i-1</sub> + w <sub>i</sub>       | 0.790                |
| (log Ksat) <sub>i</sub> = 0.663(log Ksat) <sub>i-1</sub> + 0.209(log Ele) <sub>i-1</sub> + 0.239(SOC) <sub>i-1</sub> - 0.239(Macro) <sub>i-1</sub> + 0.135(Bd) <sub>i-1</sub> + w <sub>i</sub>          | 0.814                |
| (log Ksat) <sub>i</sub> = 0.081(log Ksat) <sub>i-1</sub> - 0.039(log Ele) <sub>i-1</sub> + 0.173(SOC) <sub>i-1</sub> + 0.038(Macro) <sub>i-1</sub> + 0.741(log LU) <sub>i-1</sub> + w <sub>i</sub>      | 0.971                |
| (log Ksat) <sub>i</sub> = 0.090(log Ksat) <sub>i-1</sub> + 0.023(Log Ele) <sub>i-1</sub> + 0.141(SOC) <sub>i-1</sub> + 0.096(Bd) <sub>i-1</sub> + 0.643(log LU) <sub>i-1</sub> + w <sub>i</sub>         | 0.896                |
| (log Ksat) <sub>i</sub> = -0.167(log Ksat) <sub>i-1</sub> + 0.280(log Ele) <sub>i-1</sub> + 0.297(Clay) <sub>i-1</sub> + 0.478(Macro) <sub>i-1</sub> + 0.120(Bd) <sub>i-1</sub> + w <sub>i</sub>        | 0.994                |
| (log Ksat) <sub>i</sub> = 0.126(log Ksat) <sub>i-1</sub> - 0.075(log Ele) <sub>i-1</sub> + 0.165(Clay) <sub>i-1</sub> + 0.051(Macro) <sub>i-1</sub> + 0.728(log LU) <sub>i-1</sub> + w <sub>i</sub>     | 0.963                |
| (log Ksat) <sub>i</sub> = 0.148(log Ksat) <sub>i-1</sub> + 0.074(log Ele) <sub>i-1</sub> + 0.094(Clay) <sub>i-1</sub> + 0.227(Bd) <sub>i-1</sub> + 0.452(log LU) <sub>i-1</sub> + w <sub>i</sub>        | 0.862                |
| (log Ksat) <sub>i</sub> = -0.066(log Ksat) <sub>i-1</sub> + 0.234(log Ele) <sub>i-1</sub> + 0.149(Macro) <sub>i-1</sub> + 0.371(Bd) <sub>i-1</sub> + 0.305(log LU) <sub>i-1</sub> + w <sub>i</sub>      | 0.972                |
| <b>(log Ksat)<sub>i</sub></b> = 0.075(log Ksat) <sub>i-1</sub> + 0.414(SOC) <sub>i-1</sub> + 0.395(Clay) <sub>i-1</sub> - 0.212(Macro) <sub>i-1</sub> + 0.178(Bd) <sub>i-1</sub> + w <sub>i</sub>       | <b>0.998</b>         |
| (log Ksat) <sub>i</sub> = 0.079(log Ksat) <sub>i-1</sub> + 0.124(SOC) <sub>i-1</sub> + 0.032(Clay) <sub>i-1</sub> + 0.048(Macro) <sub>i-1</sub> + 0.715(log LU) <sub>i-1</sub> + w <sub>i</sub>         | 0.955                |
| (log Ksat) <sub>i</sub> = 0.156(log Ksat) <sub>i-1</sub> + 0.142(SOC) <sub>i-1</sub> - 0.039(Clay) <sub>i-1</sub> + 0.048(Bd) <sub>i-1</sub> + 0.686(log LU) <sub>i-1</sub> + w <sub>i</sub>            | 0.769                |
| (log Ksat) <sub>i</sub> = 0.052(log Ksat) <sub>i-1</sub> + 0.153(SOC) <sub>i-1</sub> + 0.052(Macro) <sub>i-1</sub> + 0.041(Bd) <sub>i-1</sub> + 0.696(log LU) <sub>i-1</sub> + w <sub>i</sub>           | 0.929                |
| (log Ksat) <sub>i</sub> = 0.021(log Ksat) <sub>i-1</sub> + 0.200(Clay) <sub>i-1</sub> + 0.114(Macro) <sub>i-1</sub> + 0.153(Bd) <sub>i-1</sub> + 0.509(log LU) <sub>i-1</sub> + w <sub>i</sub>          | 0.940                |
| <b>4 Variables</b>  |                      |
|   | <b>r<sup>2</sup></b> |
| (log Ksat) <sub>i</sub> = 0.446(log Ksat) <sub>i-1</sub> + 0.144(log Ele) <sub>i-1</sub> + 0.561(SOC) <sub>i-1</sub> - 0.145(Clay) <sub>i-1</sub> + w <sub>i</sub>                                      | 0.495                |
| <b>(log Ksat)<sub>i</sub></b> = 0.119(log Ksat) <sub>i-1</sub> + 0.131(log Ele) <sub>i-1</sub> + 0.685(SOC) <sub>i-1</sub> + 0.082(Macro) <sub>i-1</sub> + w <sub>i</sub>                               | <b>0.999</b>         |
| (log Ksat) <sub>i</sub> = 0.315(log Ksat) <sub>i-1</sub> + 0.266(log Ele) <sub>i-1</sub> + 0.255(SOC) <sub>i-1</sub> + 0.170(Bd) <sub>i-1</sub>   | 0.749                |
| (log Ksat) <sub>i</sub> = 0.097(log Ksat) <sub>i-1</sub> - 0.022(log Ele) <sub>i-1</sub> + 0.154(SOC) <sub>i-1</sub> + 0.764(log LU) <sub>i-1</sub> + w <sub>i</sub>                                    | 0.846                |
| (log Ksat) <sub>i</sub> = 0.062(log Ksat) <sub>i-1</sub> - 0.004(log Ele) <sub>i-1</sub> + 0.648(Clay) <sub>i-1</sub> + 0.311(Macro) <sub>i-1</sub> + w <sub>i</sub>                                    | 0.942                |
| (log Ksat) <sub>i</sub> = 0.304(log Ksat) <sub>i-1</sub> + 0.206(log Ele) <sub>i-1</sub> + 0.295(Clay) <sub>i-1</sub> + 0.163(Bd) <sub>i-1</sub> + w <sub>i</sub>                                       | 0.307                |

|  |                      |
|--|----------------------|
| $(\log K_{sat})_i = 0.185(\log K_{sat})_{i-1} - 0.061(\log Ele)_{i-1} + 0.110(Clay)_{i-1} + 0.759(\log LU)_{i-1} + w_i$  | 0.808                |
| $(\log K_{sat})_i = 0.309(\log K_{sat})_{i-1} + 0.387(\log Ele)_{i-1} - 0.004(Macro)_{i-1} + 0.340(Bd)_{i-1} + w_i$      | 0.941                |
| $(\log K_{sat})_i = 0.053(\log K_{sat})_{i-1} - 0.012(\log Ele)_{i-1} + 0.151(Macro)_{i-1} + 0.799(\log LU)_{i-1} + w_i$ | 0.962                |
| $(\log K_{sat})_i = 0.168(\log K_{sat})_{i-1} + 0.117(\log Ele)_{i-1} + 0.253(Bd)_{i-1} + 0.455(\log LU)_{i-1} + w_i$    | 0.784                |
| $(\log K_{sat})_i = -0.158(\log K_{sat})_{i-1} - 0.372(SOC)_{i-1} + 1.022(Clay)_{i-1} + 0.522(Macro)_{i-1} + w_i$        | 0.995                |
| $(\log K_{sat})_i = 0.657(\log K_{sat})_{i-1} - 0.018(SOC)_{i-1} + 0.339(Clay)_{i-1} + 0.032(Bd)_{i-1} + w_i$            | 0.694                |
| $(\log K_{sat})_i = 0.091(\log K_{sat})_{i-1} + 0.108(SOC)_{i-1} + 0.040(Clay)_{i-1} + 0.756(\log LU)_{i-1} + w_i$       | 0.727                |
| $(\log K_{sat})_i = 0.996(\log K_{sat})_{i-1} + 0.395(SOC)_{i-1} - 0.474(Macro)_{i-1} + 0.102(Bd)_{i-1} + w_i$           | 0.815                |
| $(\log K_{sat})_i = 0.078(\log K_{sat})_{i-1} + 0.138(SOC)_{i-1} + 0.040(Macro)_{i-1} + 0.738(\log LU)_{i-1} + w_i$      | 0.968                |
| $(\log K_{sat})_i = 0.120(\log K_{sat})_{i-1} + 0.144(SOC)_{i-1} + 0.044(Bd)_{i-1} + 0.686(\log LU)_{i-1} + w_i$         | 0.766                |
| $(\log K_{sat})_i = 0.634(\log K_{sat})_{i-1} + 0.499(Clay)_{i-1} - 0.151(Macro)_{i-1} + 0.028(Bd)_{i-1} + w_i$          | 0.826                |
| $(\log K_{sat})_i = 0.099(\log K_{sat})_{i-1} + 0.110(Clay)_{i-1} + 0.044(Macro)_{i-1} + 0.740(\log LU)_{i-1} + w_i$     | 0.961                |
| $(\log K_{sat})_i = 0.194(\log K_{sat})_{i-1} + 0.125(Clay)_{i-1} + 0.153(Bd)_{i-1} + 0.525(\log LU)_{i-1} + w_i$        | 0.762                |
| $(\log K_{sat})_i = 0.106(\log K_{sat})_{i-1} + 0.126(Macro)_{i-1} + 0.103(Bd)_{i-1} + 0.662(\log LU)_{i-1}$             | 0.939                |
| <b>3 Variables</b>   | <b>r<sup>2</sup></b> |
| $(\log K_{sat})_i = 0.377(\log K_{sat})_{i-1} + 0.099(\log Ele)_{i-1} + 0.534(SOC)_{i-1} + w_i$                          | 0.231                |
| $(\log K_{sat})_i = 0.487(\log K_{sat})_{i-1} - 0.091(\log Ele)_{i-1} + 0.618(Clay)_{i-1} + w_i$                         | 0.442                |
| $(\log K_{sat})_i = -2.068(\log K_{sat})_{i-1} + 0.717(\log Ele)_{i-1} + 2.330(Macro)_{i-1} + w_i$                       | 0.873                |
| $(\log K_{sat})_i = 0.393(\log K_{sat})_{i-1} + 0.350(\log Ele)_{i-1} + 0.252(Bd)_{i-1} + w_i$                           | 0.313                |
| $(\log K_{sat})_i = 0.227(\log K_{sat})_{i-1} - 0.036(\log Ele)_{i-1} + 0.800(\log LU)_{i-1} + w_i$                      | 0.738                |
| $(\log K_{sat})_i = 0.702(\log K_{sat})_{i-1} + 0.167(SOC)_{i-1} + 0.143(Clay)_{i-1} + w_i$                              | 0.520                |
| <b><math>(\log K_{sat})_i = 0.239(\log K_{sat})_{i-1} + 0.740(SOC)_{i-1} + 0.038(Macro)_{i-1} + w_i</math></b>           | <b>0.989</b>         |
| $(\log K_{sat})_i = 0.670(\log K_{sat})_{i-1} + 0.257(SOC)_{i-1} + 0.084(Bd)_{i-1} + w_i$                                | 0.752                |
| $(\log K_{sat})_i = 0.087(\log K_{sat})_{i-1} + 0.140(SOC)_{i-1} + 0.767(\log LU)_{i-1} + w_i$                           | 0.809                |

|  |                      |
|--|----------------------|
| $(\log K_{sat})_i = -0.518(\log K_{sat})_{i-1} + 0.734(\text{Clay})_{i-1} + 0.809(\text{Macro})_{i-1} + w_i$   | 0.975                |
| $(\log K_{sat})_i = 0.750(\log K_{sat})_{i-1} + 0.265(\text{Clay})_{i-1} - 0.013(\text{Bd})_{i-1} + w_i$   | 0.624                |
| $(\log K_{sat})_i = 0.146(\log K_{sat})_{i-1} + 0.069(\text{Clay})_{i-1} + 0.777(\log \text{LU})_{i-1} + w_i$  | 0.777                |
| $(\log K_{sat})_i = 1.797(\log K_{sat})_{i-1} - 1.011(\text{Macro})_{i-1} + 0.219(\text{Bd})_{i-1} + w_i$  | 0.772                |
| $(\log K_{sat})_i = 0.122(\log K_{sat})_{i-1} + 0.118(\text{Macro})_{i-1} + 0.757(\log \text{LU})_{i-1} + w_i$   | 0.934                |
| $(\log K_{sat})_i = 0.271(\log K_{sat})_{i-1} + 0.144(\text{Bd})_{i-1} + 0.581(\log \text{LU})_{i-1} + w_i$  | 0.598                |
| $(\log K_{sat})_i = 1.797(\log K_{sat})_{i-1} - 1.011(\text{Macro})_{i-1} + 0.219(\text{Bd})_{i-1} + w_i$  | 0.772                |
| <b>2 Variables</b>   | <b>r<sup>2</sup></b> |
| $(\log K_{sat})_i = 1.006(\log K_{sat})_{i-1} - 3.199(\log \text{Ele})_{i-1} + w_i$  | 0.456                |
| $(\log K_{sat})_i = 0.608(\log K_{sat})_{i-1} + 0.399(\text{SOC})_{i-1} + w_i$   | 0.766                |
| $(\log K_{sat})_i = 0.598(\log K_{sat})_{i-1} + 0.409(\text{Clay})_{i-1} + w_i$  | 0.764                |
| <b>(<math>\log K_{sat}</math>)<sub>i</sub> = 2.464(<math>\log K_{sat}</math>)<sub>i-1</sub> - 1.511(<math>\text{Macro}</math>)<sub>i-1</sub> + w<sub>i</sub></b> | <b>0.800</b>         |
| $(\log K_{sat})_i = 0.975(\log K_{sat})_{i-1} + 0.031(\text{Bd})_{i-1} + w_i$  | 0.476                |
| $(\log K_{sat})_i = 0.170(\log K_{sat})_{i-1} + 0.825(\log \text{LU})_{i-1} + w_i$   | 0.598                |

Studies have shown that human activities and land management have an added effect on soil properties and thereby on their spatial distribution (Taskinen et al., 2008; Lizaga et al., 2019). Therefore, the structural and textural surface properties, and hence their hydraulic properties, will change with different land-use systems. Wang et al. (2013) studied the variation of the saturated soil hydraulic conductivity through the entire Loess Plateau in China, and concluded that soil particle composition, bulk density (small-scale factors) and land-use type (large-scale factors) significantly contributed to the variation of topsoil Ksat values, whilst the extension of explained variation turned out distinct. When evaluating the individual effect of the type of land-use on the local variability of Ksat along our sampling transect, it had low predictive value to explain the local variations of Ksat ( $r^2 = 0.598$ ) as compared to those of Macro ( $r^2 = 0.800$ ), SOC

( $r^2 = 0.766$ ) and Clay ( $r^2 = 0.764$ ) (Table 6). If land-use and elevation are used as predictor, more accurate estimates of Ksat were found ( $r^2 = 0.738$ ). Adding basic soil properties (clay content, SOC, soil bulk density), the role of land-use as a Ksat predictor has improved ( $r^2 = 0.769$ ). Furthermore, if Macro is added as a predictor, more accurate estimates of Ksat were achieved ( $r^2 = 0.926$ , Table 6).

Multiple linear regression models have been widely used to predict Ksat and to assess its relationships with other soil properties. However, these models ignore the spatial distances between sampling locations (Zhang et al., 2019). All state-space models better described the spatial relationship between Ksat and soil properties (Clay, Bd, Macro and SOC), topography (elevation) and land-use systems across the 15-km transect (Table 6) when compared to all equivalent multiple linear regression models (Table 7). For example, Clay, Bd and SOC have been widely used to predict Ksat using multiple linear models (Wösten et al., 2001). Not surprisingly, the use of a multiple linear regression model considering SOC, Clay and Bd as predictors of Ksat poorly depicted their point-to-point fluctuations along the spatial transect ( $r^2 = 0.148$ , Table 7). When the spatial associations among Ksat, SOC, Clay and Bd were considered along the transect, around 70% of the variance of Ksat was explained (Table 6). In this study, the use of global or space-independent models (e.g. multiple regression) failed since they are based on the assumption that the sets manifest a constant mean along the entire transect. The use of SSM presupposes the dependence of observations among themselves and that the positions in the field are regarded (Aquino et al., 2015).

**Table 7** - Linear regression equations of saturated soil hydraulic conductivity ( $\text{Ksat}$  expressed as  $\log_{10}$ ) using all combinations of selected soil and topographic attributes and land-use systems, and  $r^2$  values from linear regression between estimated and measured values of  $\log \text{Ksat}$ .

| <b>All variables</b>    |   | <b><math>r^2</math></b> |
|-------------------------|---|-------------------------|
| ( $\log \text{Ksat}$ )= | $-2.721 + 0.715(\log \text{Ele}) + 0.260(\text{SOC}) + 0.033(\text{Clay}) + 0.221(\text{Macro}) + 2.387(\text{Bd}) - 1.728(\log \text{LU})$ | 0.715                   |
| <b>6 Variables</b>      |   | <b><math>r^2</math></b> |
| ( $\log \text{Ksat}$ )= | $-1.944 + 0.329(\log \text{Ele}) + 0.098(\text{SOC}) + 0.012(\text{Clay}) + 0.095(\text{Macro}) + 0.892(\text{Bd})$                         | 0.738                   |
| ( $\log \text{Ksat}$ )= | $1.301 + 0.744(\log \text{Ele}) - 0.646(\text{SOC}) + 0.025(\text{Clay}) + 0.196(\text{Macro}) - 0.714(\log \text{LU})$                     | 0.701                   |
| ( $\log \text{Ksat}$ )= | $14.761 + 2.189(\log \text{Ele}) - 1.911(\text{SOC}) - 0.038(\text{Clay}) - 3.906(\text{Bd}) - 2.850(\log \text{LU})$                       | 0.340                   |
| ( $\log \text{Ksat}$ )= | $-3.602 + 0.907(\log \text{Ele}) + 0.536(\text{SOC}) + 0.211(\text{Macro}) + 2.093(\text{Bd}) - 1.181(\log \text{LU})$                      | 0.710                   |
| ( $\log \text{Ksat}$ )= | $-1.480 + 0.728(\log \text{Ele}) - 0.036(\text{Clay}) + 0.218(\text{Macro}) + 2.140(\text{Bd}) - 1.906(\log \text{LU})$                     | 0.731                   |
| ( $\log \text{Ksat}$ )= | $-5.442 + 0.420(\text{SOC}) + 0.053(\text{Clay}) + 0.240(\text{Macro}) + 2.482(\text{Bd}) - 0.138(\log \text{LU})$                          | 0.700                   |
| <b>5 Variables</b>      |   | <b><math>r^2</math></b> |
| ( $\log \text{Ksat}$ )= | $0.287 + 0.364(\log \text{Ele}) - 0.264(\text{SOC}) - 0.009(\text{Clay}) + 0.085(\text{Macro})$   | 0.725                   |
| ( $\log \text{Ksat}$ )= | $5.022 + 0.926(\log \text{Ele}) - 0.851(\text{SOC}) - 0.018(\text{Clay}) - 1.985(\text{Bd})$  | 0.344                   |
| ( $\log \text{Ksat}$ )= | $9.940 + 2.501(\log \text{Ele}) - 0.372(\text{SOC}) - 0.036(\text{Clay}) - 5.480(\log \text{LU})$   | 0.247                   |
| ( $\log \text{Ksat}$ )= | $-1.876 + 0.405(\log \text{Ele}) + 0.190(\text{SOC}) + 0.091(\text{Macro}) + 0.781(\text{Bd})$  | 0.737                   |
| ( $\log \text{Ksat}$ )= | $0.250 + 0.887(\log \text{Ele}) - 0.350(\text{SOC}) + 0.191(\text{Macro}) - 0.393(\log \text{LU})$  | 0.699                   |
| ( $\log \text{Ksat}$ )= | $16.772 + 2.028(\log \text{Ele}) - 2.368(\text{SOC}) - 3.871(\text{Bd}) - 3.587(\log \text{LU})$  | 0.301                   |
| ( $\log \text{Ksat}$ )= | $-1.587 + 0.333(\log \text{Ele}) + 0.013(\text{Clay}) + 0.094(\text{Macro}) + 0.791(\text{Bd})$   | 0.738                   |
| ( $\log \text{Ksat}$ )= | $-1.906 + 0.705(\log \text{Ele}) + 0.013(\text{Clay}) + 0.195(\text{Macro}) + 0.385(\log \text{LU})$  | 0.699                   |
| ( $\log \text{Ksat}$ )= | $6.233 + 2.208(\log \text{Ele}) - 0.062(\text{Clay}) - 2.449(\text{Bd}) - 1.508(\log \text{LU})$  | 0.282                   |
| ( $\log \text{Ksat}$ )= | $-0.977 + 0.964(\log \text{Ele}) + 0.205(\text{Macro}) + 0.1501(\text{Bd}) - 1.497(\log \text{LU})$   | 0.711                   |
| ( $\log \text{Ksat}$ )= | $-1.988 + 0.161(\text{SOC}) + 0.022(\text{Clay}) + 0.103(\text{Macro}) + 1.047(\text{Bd})$  | 0.718                   |

|   |       |
|---|-------|
| $(\log K_{sat}) = -1.365 - 0.517(\text{SOC}) + 0.044(\text{Clay}) + 0.215(\text{Macro}) + 0.982(\log LU)$ | 0.685 |
| $(\log K_{sat}) = 10.319 - 2.021(\text{SOC}) + 0.011(\text{Clay}) - 5.608(\text{Bd}) + 2.716(\log LU)$    | 0.114 |
| $(\log K_{sat}) = -8.442 + 1.015(\text{SOC}) + 0.232(\text{Macro}) + 1.981(\text{Bd}) + 1.673(\log LU)$   | 0.680 |
| $(\log K_{sat}) = -3.493 + 0.057(\text{Clay}) + 0.237(\text{Macro}) + 2.082(\text{Bd}) - 0.383(\log LU)$  | 0.702 |
| <b>4 Variables</b>  |       |
| $(\log K_{sat}) = 0.129 + 0.418(\log Ele) - 0.161(\text{SOC}) + 0.083(\text{Macro})$                      | 0.723 |
| $(\log K_{sat}) = -0.021 + 1.014(\log Ele) + 0.028(\text{SOC}) - 0.018(\text{Clay})$                      | 0.252 |
| $(\log K_{sat}) = 5.322 + 0.837(\log Ele) - 1.059(\text{SOC}) - 1.972(\text{Bd})$                         | 0.330 |
| $(\log K_{sat}) = 11.889 + 2.345(\log Ele) - 0.819(\text{SOC}) - 6.156(\log LU)$                          | 0.245 |
| $(\log K_{sat}) = -0.195 + 0.364(\log Ele) + 0.036(\text{Clay}) + 0.084(\text{Macro})$                    | 0.721 |
| $(\log K_{sat}) = 2.247 + 0.943(\log Ele) - 0.028(\text{Clay}) - 1.284(\text{Bd})$                        | 0.313 |
| $(\log K_{sat}) = 8.066 + 2.474(\log Ele) - 0.043(\text{Clay}) - 4.833(\log LU)$                          | 0.254 |
| $(\log K_{sat}) = -1.133 + 0.423(\log Ele) + 0.089(\text{Macro}) - 0.559(\text{Bd})$                      | 0.731 |
| $(\log K_{sat}) = -1.631 + 0.810(\log Ele) + 0.192(\text{Macro}) + 0.265(\log LU)$                        | 0.700 |
| $(\log K_{sat}) = 6.177 + 1.907(\log Ele) - 1.709(\text{Bd}) - 2.309(\log LU)$                            | 0.254 |
| $(\log K_{sat}) = 0.676 - 0.263(\text{SOC}) + 0.019(\text{Clay}) + 0.093(\text{Macro})$                   | 0.700 |
| $(\log K_{sat}) = 7.123 - 0.743(\text{SOC}) + 0.006(\text{Clay}) - 2.384(\text{Bd})$                      | 0.148 |
| $(\log K_{sat}) = 1.968 + 0.310(\text{SOC}) + 0.024(\text{Clay}) - 0.094(\log LU)$                        | 0.018 |
| $(\log K_{sat}) = -1.851 + 0.402(\text{SOC}) + 0.100(\text{Macro}) + 0.875(\text{Bd})$                    | 0.694 |
| $(\log K_{sat}) = -4.689 + 0.165(\text{SOC}) + 0.213(\text{Macro}) + 2.361(\log LU)$                      | 0.671 |
| $(\log K_{sat}) = 9.587 - 1.881(\text{SOC}) - 5.659(\text{Bd}) + 3.075(\log LU)$                          | 0.122 |
| $(\log K_{sat}) = -1.397 + 0.024(\text{Clay}) + 0.102(\text{Macro}) + 0.885(\text{Bd})$                   | 0.716 |
| $(\log K_{sat}) = -3.844 + 0.034(\text{Clay}) + 0.214(\text{Macro}) + 1.799(\log LU)$                     | 0.685 |
| $(\log K_{sat}) = 1.251 - 0.014(\text{Clay}) - 4.081(\text{Bd}) + 4.188(\log LU)$                         | 0.090 |
| $(\log K_{sat}) = -3.787 + 0.222(\text{Macro}) + 0.782(\text{Bd}) + 1.401 (\log LU)$                      | 0.675 |
| <b>3 Variables</b>  |       |
| $(\log K_{sat}) = 0.297 + 0.928(\log Ele) - 0.176(\text{SOC})$  | 0.239 |
| $(\log K_{sat}) = 0.032 + 1.015(\log Ele) - 0.017(\text{Clay})$   | 0.252 |
| $(\log K_{sat}) = -0.179 + 0.393(\log Ele) + 0.083(\text{Macro})$   | 0.720 |
| $(\log K_{sat}) = 1.572 + 0.789(\log Ele) - 0.956(\text{Bd})$   | 0.274 |
| $(\log K_{sat}) = 7.601 + 2.183(\log Ele) - 4.677(\log LU)$   | 0.243 |
| $(\log K_{sat}) = 1.190 + 0.123(\text{SOC}) + 0.010(\text{Clay})$   | 0.012 |
| $(\log K_{sat}) = 0.407 + 0.014(\text{SOC}) + 0.092(\text{Macro})$  | 0.682 |
| $(\log K_{sat}) = 7.083 - 0.863(\text{SOC}) - 2.405(\text{Bd})$   | 0.146 |
| $(\log K_{sat}) = 0.116 + 0.680(\text{SOC}) + 0.672(\log LU)$   | 0.013 |

|                    |  |                      |
|--------------------|--|----------------------|
| (log Ksat)=        | $0.194 + 0.014(\text{Clay}) + 0.092(\text{Macro})$     | 0.695                |
| (log Ksat)=        | $4.083 - 0.004(\text{Clay}) - 1.612(\log \text{Bd})$   | 0.109                |
| (log Ksat)=        | $3.485 + 0.031(\text{Clay}) - 0.594(\log \text{LU})$   | 0.009                |
| (log Ksat)=        | $-0.194 + 0.096(\text{Macro}) + 0.392(\text{Bd})$      | 0.687                |
| (log Ksat)=        | $-3.903 + 0.213(\text{Macro}) + 2.134(\log \text{LU})$ | 0.674                |
| (log Ksat)=        | $1.410 - 3.834(\text{Bd}) + 3.783(\log \text{LU})$     | 0.097                |
| <b>2 Variables</b> |  | <b>r<sup>2</sup></b> |
| (log Ksat)=        | $-0.041 + 0.900(\log \text{Ele})$                      | 0.236                |
| (log Ksat)=        | $1.046 + 0.267(\text{SOC})$                            | 0.006                |
| (log Ksat)=        | $1.422 + 0.013(\text{Clay})$                           | 0.010                |
| (log Ksat)=        | $0.439 + 0.092(\text{Macro})$                          | 0.681                |
| (log Ksat)=        | $3.913 - 1.548(\text{Bd})$                             | 0.108                |
| (log Ksat)=        | $3.419 - 0.284(\log \text{LU})$                        | 0.010                |

To interpret the role that each selected soil variable plays in defining each factor (PC) and reduce the dimension of soil data sets, the PCA (Jolliffe, 2002) was used to selected soil attributes (Clay, SOC, Macro and Bd). The first two components (PC1 and PC2) presented eigenvalues > 1.0 and explained 82.4% of the total variance (Table 8). PC1 explained 54.6% of the total variance, which received largest positive influence of Bd (loading of 0.898) and greatest negative influences of Clay and SOC with loadings of -0.784 and -0.857, respectively (Table 8). Only Macro had a positive influence on PC2 since its loading was 0.856, which is higher than 0.70, commonly adopted loading threshold value in the literature (Hair et al., 2009).

The performance of SSMs obtained for Ksat and their respective r<sup>2</sup> coefficients using all combinations of the selected principal components (PC1 and PC2) and elevation and land-use systems is presented in Table 9, which shows that the best performance of the SSM of Ksat was found when PC2 was used as a predictor variable, independently of the evaluated combination.

**Table 8** - Results of the principal component analysis applied to the soil attributes (clay content soil organic matter, macroporosity and soil bulk density)

| Principal component                             | Eigenvalue    | % Variance    | Cumulative % |
|---|---------------|---------------|--------------|
| PC 1  | 2.183         | 54.586        | 54.586       |
| PC 2  | 1.111         | 27.779        | 82.365       |
| PC 3  | 0.496         | 12.404        | 94.768       |
| PC 4  | 0.209         | 5.232         | 100.000      |
| Principal component loadings for each attribute |               |               |              |
|   | Clay          | SOC           | Macro        |
| PC 1  | <b>-0.784</b> | <b>-0.857</b> | -0.420       |
| PC 2  | -0.508        | -0.258        | <b>0.856</b> |
|   |               |               | Bd           |
|   |               |               | -0.233       |

SOC: content soil organic matter (%); Macro: macroporosity (%) and Bd: soil bulk density ( $\text{g.cm}^{-3}$ ).

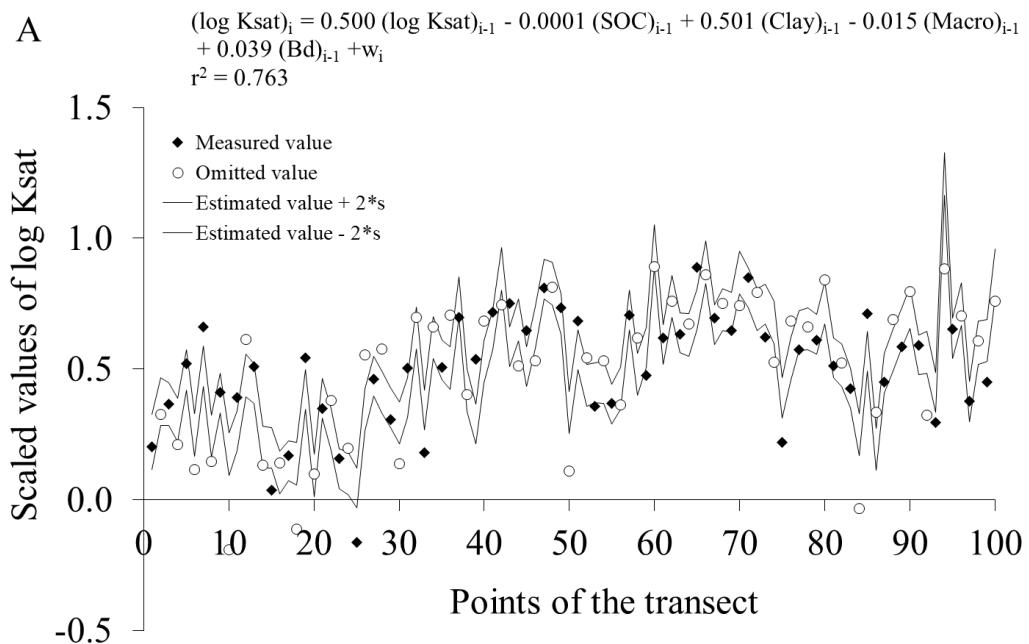
For example, the best performance of the two-variable state-space model was found when using the local variations of PC2 across the transect to estimate the local variations of Ksat ( $r^2 = 0.927$ ) (Table 9). It is worth to emphasize that when using the individual contributions of Clay, SOC, Macro and Bd, 99.8% of the variance of Ksat was explained from the use of the state-space analysis (Table 6). On the other hand, when using the PC2 contribution, around 93% of the variance of Ksat was explained by the use of the state-space analysis (Table 9). Macro had the higher and positive loading on PC2 when compared to the loading of the other soil variables indicating the largest degree of correspondence between this soil variable and PC2 (Table 8). Therefore, we can note its relative importance to describe the local Ksat variability as compared to the other soil variables.

**Table 9** - State-space equations of saturated soil hydraulic conductivity ( $K_{sat}$  expressed as  $\log_{10}$ ) using all combinations considering the selected topographic attribute, land-use systems and principal component data sets (PC1 and PC2), and  $r^2$  values from linear regression between estimated and measured values of  $\log K_{sat}$

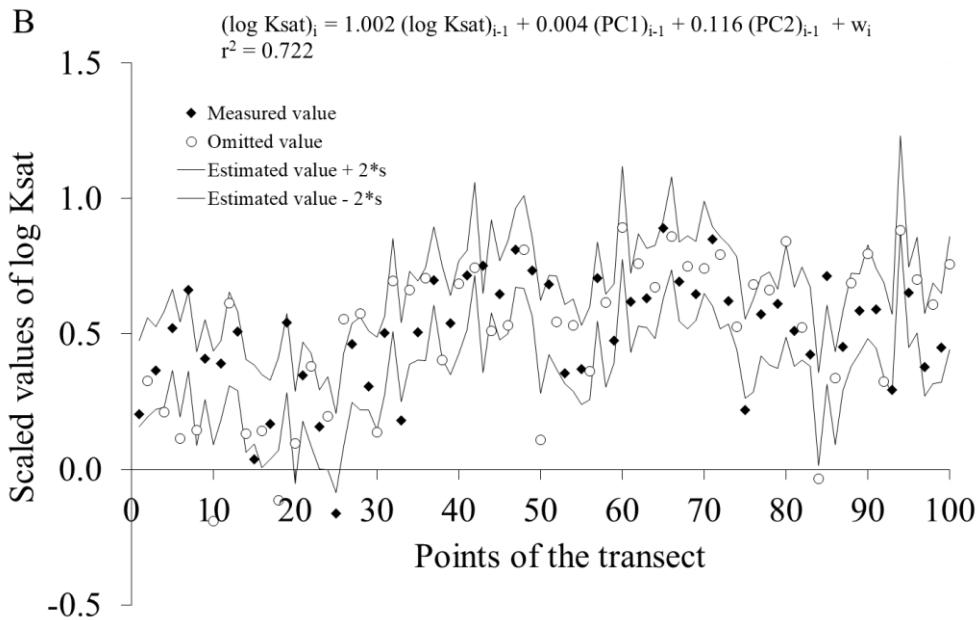
| <b>5 Variables</b>                               |  | $r^2$        |
|--|--|--------------|
| <b>(<math>\log K_{sat}</math>)<sub>i</sub> =</b> | <b>-0.108(<math>\log K_{sat}</math>)<sub>i-1</sub> + 0.245(PC1)<sub>i-1</sub> + 0.223(PC2)<sub>i-1</sub> + 0.261(<math>\log Ele</math>)<sub>i-1</sub> + 0.390(<math>\log LU</math>)<sub>i-1</sub> + <math>w_i</math></b> | <b>0.994</b> |
| <b>4 Variables</b>                               |  | $r^2$        |
| <b>(<math>\log K_{sat}</math>)<sub>i</sub> =</b> | 1.057( $\log K_{sat}$ ) <sub>i-1</sub> + 0.021(PC1) <sub>i-1</sub> + 0.186(PC2) <sub>i-1</sub> – 0.051( $\log Ele$ ) <sub>i-1</sub> + $w_i$  | 0.909        |
| <b>(<math>\log K_{sat}</math>)<sub>i</sub> =</b> | <b>-0.238(<math>\log K_{sat}</math>)<sub>i-1</sub> + 0.593(PC1)<sub>i-1</sub> + 0.173(PC2)<sub>i-1</sub> + 0.486(<math>\log LU</math>)<sub>i-1</sub> + <math>w_i</math></b>  | <b>0.994</b> |
| <b>(<math>\log K_{sat}</math>)<sub>i</sub> =</b> | - 0.336( $\log K_{sat}$ ) <sub>i-1</sub> + 0.735(PC1) <sub>i-1</sub> + 0.185( $\log Ele$ ) <sub>i-1</sub> + 0.410( $\log LU$ ) <sub>i-1</sub> + $w_i$  | 0.993        |
| <b>(<math>\log K_{sat}</math>)<sub>i</sub> =</b> | - 0.032( $\log K_{sat}$ ) <sub>i-1</sub> + 0.299(PC2) <sub>i-1</sub> + 0.330( $\log Ele$ ) <sub>i-1</sub> + 0.414( $\log LU$ ) <sub>i-1</sub> + $w_i$  | 0.993        |
| <b>3 Variables</b>                               |  | $r^2$        |
| <b>(<math>\log K_{sat}</math>)<sub>i</sub> =</b> | 0.227( $\log K_{sat}$ ) <sub>i-1</sub> – 0.036( $\log Ele$ ) <sub>i-1</sub> + 0.800( $\log LU$ ) <sub>i-1</sub> + $w_i$  | 0.738        |
| <b>(<math>\log K_{sat}</math>)<sub>i</sub> =</b> | 1.008( $\log K_{sat}$ ) <sub>i-1</sub> + 0.017(PC1) <sub>i-1</sub> + 0.177(PC2) <sub>i-1</sub> + $w_i$   | 0.911        |
| <b>(<math>\log K_{sat}</math>)<sub>i</sub> =</b> | 0.948( $\log K_{sat}$ ) <sub>i-1</sub> + 0.059(PC1) <sub>i-1</sub> – 0.022( $\log Ele$ ) <sub>i-1</sub> + $w_i$  | 0.495        |
| <b>(<math>\log K_{sat}</math>)<sub>i</sub> =</b> | <b>0.992(<math>\log K_{sat}</math>)<sub>i-1</sub> + 0.017(PC2)<sub>i-1</sub> + 0.182(<math>\log Ele</math>)<sub>i-1</sub> + <math>w_i</math></b>   | <b>0.940</b> |
| <b>(<math>\log K_{sat}</math>)<sub>i</sub> =</b> | 0.069( $\log K_{sat}$ ) <sub>i-1</sub> + 0.162(PC1) <sub>i-1</sub> + 0.762( $\log LU$ ) <sub>i-1</sub> + $w_i$   | 0.735        |
| <b>(<math>\log K_{sat}</math>)<sub>i</sub> =</b> | 0.179( $\log K_{sat}$ ) <sub>i-1</sub> + 0.106(PC2) <sub>i-1</sub> + 0.709( $\log LU$ ) <sub>i-1</sub> + $w_i$   | 0.911        |
| <b>2 Variables</b>                               |  | $r^2$        |
| <b>(<math>\log K_{sat}</math>)<sub>i</sub> =</b> | 1.006( $\log K_{sat}$ ) <sub>i-1</sub> - 3.199( $\log Ele$ ) <sub>i-1</sub> + $w_i$  | 0.456        |
| <b>(<math>\log K_{sat}</math>)<sub>i</sub> =</b> | 0.170( $\log K_{sat}$ ) <sub>i-1</sub> + 0.825( $\log LU$ ) <sub>i-1</sub> + $w_i$   | 0.598        |
| <b>(<math>\log K_{sat}</math>)<sub>i</sub> =</b> | 1.005( $\log K_{sat}$ ) <sub>i-1</sub> – 0.006(PC1) <sub>i-1</sub> + $w_i$   | 0.462        |
| <b>(<math>\log K_{sat}</math>)<sub>i</sub> =</b> | <b>1.011(<math>\log K_{sat}</math>)<sub>i-1</sub> + 0.180(PC2)<sub>i-1</sub> + <math>w_i</math></b>  | <b>0.927</b> |

We also investigated the use of the state-space method to assess the spatial relationships between  $K_{sat}$  and Clay, SOC, Macro and Bd data, from two different points of view. State-space models were run when 50% of  $K_{sat}$  observations were not considered in the estimation based on the processes

expressed in the selected co-variates from Tables 6 and 9. This analysis was conducted to see how close the spatial variation of alternate data of Ksat could be better described when based on processes expressed in the individual co-variates (Table 6) or in considering the selected principal components (Table 9). Fig. 3 shows measured and omitted values of Log Ksat based on underlying processes expressed in: (A) the individual values of SOC, Clay, Macro and Bd (Table 6); and (B) considering the selected principal component data sets (PC1 and PC2, Tables 8 and 9). They also show SSMs of log Ksat as well as their respective  $r^2$  coefficients. Upper and lower 95% confidence limits are also shown in these figures.



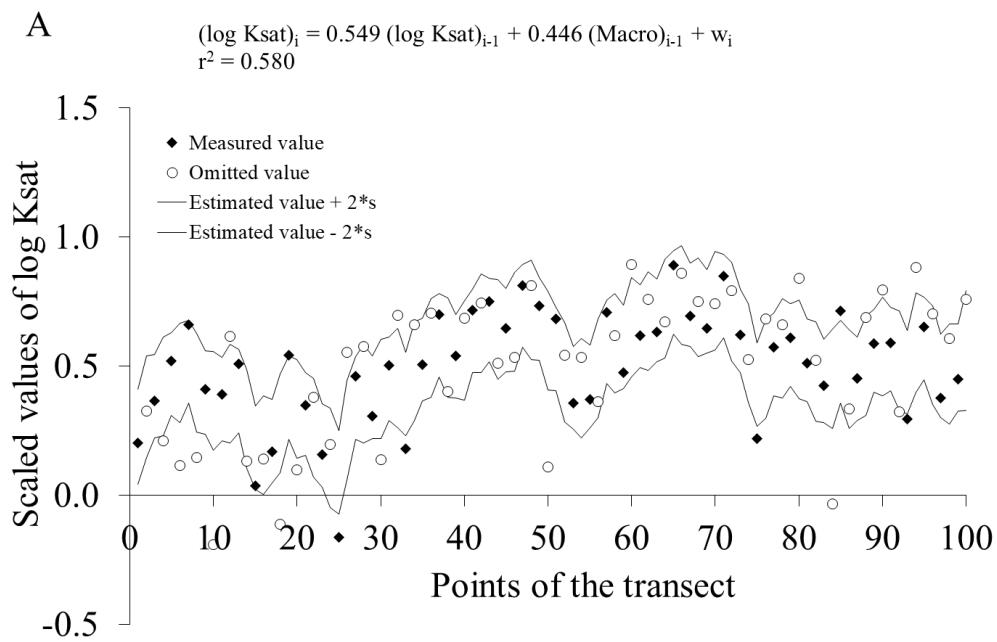
**Fig. 3 – State-space models for saturated soil hydraulic conductivity (log Ksat), when 50% of Ksat observations were not considered in the estimation, based on underlying processes manifested in: (A) the individual values of soil organic carbon (SOC), clay content (Clay), soil macroporosity (Macro) and soil bulk density (Bd) (Table 6).**



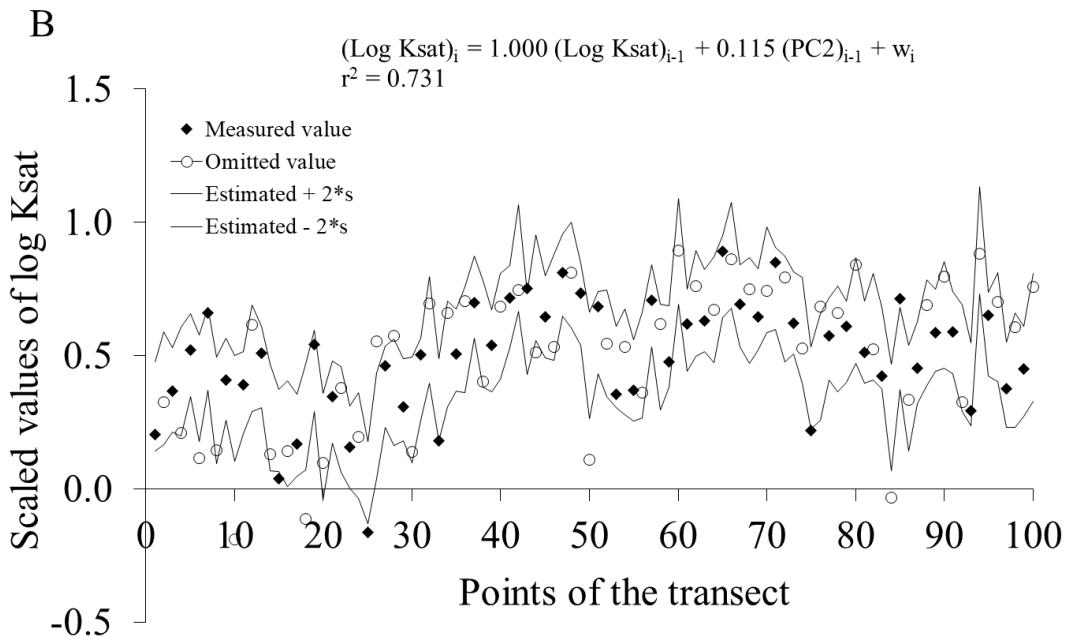
**Fig. 3 – State-space models for saturated soil hydraulic conductivity ( $\log K_{\text{sat}}$ ), when 50% of  $K_{\text{sat}}$  observations were not considered in the estimation, based on underlying processes manifested in: (B) considering the selected principal component data sets (PC1 and PC2, Tables 8 and 9).**

Updating became feasible only at every second position in the transect, when 50% of the observations of  $\log K_{\text{sat}}$  were made available for their estimation (Fig. 3). This caused an increase in the width of the confidence intervals when compared to the cases in which all observations of  $\log K_{\text{sat}}$  were used in the SSM. The ability of the SSM to estimate 50% of  $\log K_{\text{sat}}$  values based on processes expressed in the individual values of SOC, Clay, Macro and Bd when compared to the ability when all measurements are available, decreased  $r^2$  values from 0.998 (Table 6) to 0.763 (Fig. 3A). Considering all observations of the selected principal components (PC1 and PC2) to calculate 50% of measured values of  $\log K_{\text{sat}}$ , the performance of the SSM decreased from values of  $r^2$  of 0.911 (Table 9) to 0.722 (Fig. 3B). The ability of the SSM in estimating the

alternate observed values of log K<sub>sat</sub> considering the individual values mentioned above (Fig. 3A) is very little changed when compared to its ability we consider those ones of PC1 and PC2 (Fig. 3B). The SSM's potential to estimate 50% of observed values of log K<sub>sat</sub> considering the PC2 data set, increased in 26% as compared to that one considering the individual values of Macro ( $r^2$  value increased from 0.580 - Fig. 4A - to 0.731 - Fig. 4B, respectively).



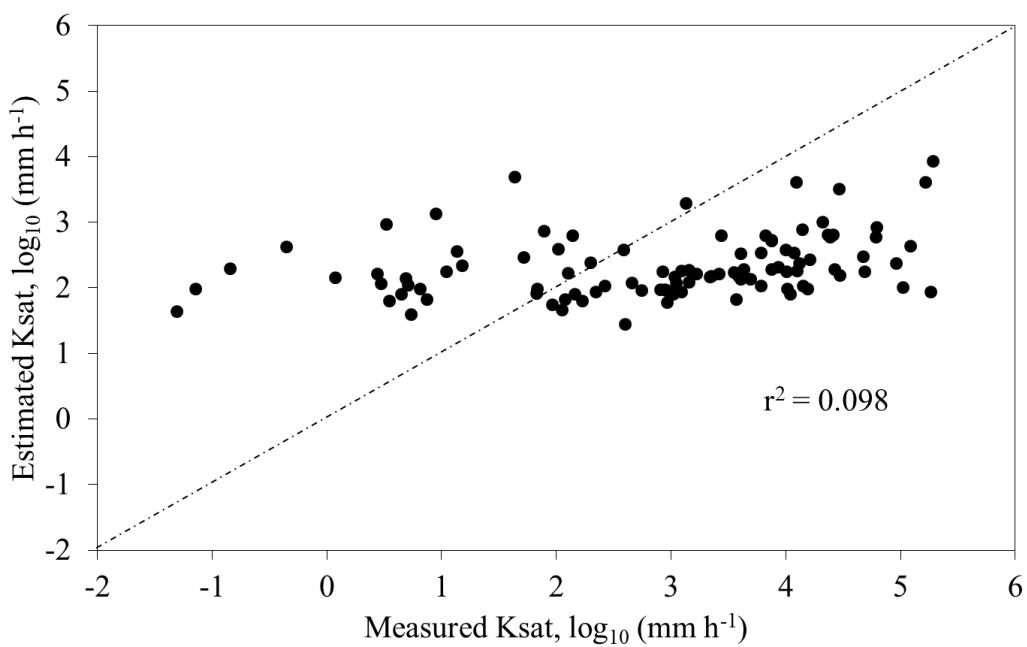
**Fig. 4** - State-space models for saturated soil hydraulic conductivity (log K<sub>sat</sub>), when 50% of K<sub>sat</sub> observations were not considered in the estimation, based on underlying processes manifested in: (A) the individual values of soil macroporosity (Macro) (Table 6).



**Fig. 4** - State-space models for saturated soil hydraulic conductivity (log Ksat), when 50% of Ksat observations were not considered in the estimation, based on underlying processes manifested in: (B) considering the PC2 data set (Tables 8 and 9).

Macroporosity was shown to have the best performance of each SSM to describe local variations of Ksat for each evaluated combination (Table 6). Macro is considered an indirect indicator for soil structure (Zhang et al., 2019) and a good indicator of the physical condition of soils (Ball et al., 2007). However, macroporosity (soil structural information) has not been included as a co-variate to estimate Ksat in the most developed multiple linear regression models (namely PTFs in the literature) since it is not an easily available soil property from soil databases. On the other hand, soil texture, Bd and SOC have been used as input variables in the most developed PTFs to estimate Ksat (Vereecken et al., 1990; Schaap et al., 2001; Zhang and Schaap, 2019). As an example, we assessed the

performance of the PTF developed by Vereecken et al. (1990) to estimate K<sub>sat</sub> in which sand and clay contents, soil bulk density and soil organic matter were used as predictor variables (Fig. 5). It can be seen that their PTF poorly depicted K<sub>sat</sub> values along the transect ( $r^2 = 0.098$ ) when compared to the performance of the similar SSM model ( $r^2 = 0.694$ , Table 6). The results indicate that Vereecken et al. (1990)-PTF, which is a space-independent multiple regression model, failed to estimate K<sub>sat</sub> values along the 15 km-spatial transect. The large deviations between PTF-estimates and measured K<sub>sat</sub> are caused by the conceptual approach of disregarding spatial covariances.



**Fig. 5** - Measured and estimated saturated soil hydraulic conductivity (log<sub>10</sub> K<sub>sat</sub>) for the pedotransfer function developed by Vereecken et al. (1990).

The individual effect of the land-use system, as expressed in terms of CN-values, on the local variability of K<sub>sat</sub> was lower ( $r^2 = 0.598$ ) as compared to that

of Macro ( $r^2 = 0.800$ ), SOC ( $r^2 = 0.766$ ) and Clay ( $r^2 = 0.766$ ) and higher as compared to that of Ele ( $r^2 = 0.456$ ) and Bd ( $r^2 = 0.476$ ) (Table 6). If land-use system is added to Clay and SOC (basic soil properties and easily available soil properties from soil databases) to estimate Ksat, more accurate estimates are achieved ( $r^2 = 0.727$ , Table 6) when compared to those of using SOC, Clay and Bd for estimating Ksat ( $r^2 = 0.694$ , Table 6), which are commonly found in developed PTFs. In this sense, our study suggests that the type of land-use system could be potentially used as a predictor of the spatial variations of Ksat at the watershed scale since it is nowadays an “easy-to-measure” variable from satellite images. From this, labor and cost of field campaigns can be saved. According to Vogel (2019), the land-use system is one of the key drivers for soil structure development and must be taken into account for developing new PTFs.

Ksat characterization plays a key role for the comprehension and quantification of several hydrological processes at the watershed scale, e.g. surface runoff, subsurface runoff and base flow. Rainfall-runoff hydrological models commonly require information on Ksat and other soil-related attributes to estimate afore mentioned hydrological processes, which exert influence on the watershed water balance over time. Ksat information might also be used to assess whether or not the calibration of different rainfall-runoff models provides results that are compatible with the physical reality of the watershed. It has also been often observed that in several cases soil databases are only available at undesirable scales and do not provide the soil-related attributes required by hydrological models (Caldeira et al., 2019). As a result, maps of soil classes made on coarse scales associated with related-soil attributes searched in the literature have been traditionally applied for purposes of hydrological modeling.

Pedotransfer functions used for estimating the spatial variation of K<sub>sat</sub> over watersheds, using attributes more easily determined in the field or laboratory, are expected to strongly contribute for the better use of hydrological models and the understanding of their outputs.

## **Conclusions**

The highest spatial variability along the 15-km spatial transect in the Fragata River Watershed, South Brazil, was observed on the saturated soil hydraulic conductivity data, presenting positive and significant correlations with elevation, soil slope and macroporosity and negative correlation with soil bulk density. The state-space approach identified different spatial relationship patterns along the transect showing the importance of various combinations of soil and topographic attributes, as well of land-use systems. The state-space approach proved to be an effective tool for better describing the spatial relationships between saturated soil hydraulic conductivity and all selected co-variates at the watershed scale when compared to the equivalent multiple linear regression models. Multivariate analysis coupled to the state-space approach identified that the local variation of K<sub>sat</sub> was dominantly revealed by the local variation of macroporosity at the sampling scale. However, macroporosity (soil structural information) is not an easily available soil property from soil databases. Therefore, our study suggests that the type of land-use system could be potentially used as a soil structural predictor of the spatial variations of K<sub>sat</sub> at the watershed scale since it is nowadays an “easy-to-measure” variable from satellite images.

The present study reinforces the use of Regional Variable Statistics in hydrologic studies of watersheds. Further studies should be carried out to

investigate the validity of the state-space methodology presented in this study in other environments. For example, if another variable is included or one variable is eliminated in the state-space analysis, the coefficients (in terms of magnitudes and signs) for the remaining variables may strongly shift.

### **Acknowledgments**

We acknowledge and are grateful for the financial support and scholarships provided by the Brazilian National Council for Scientific and Technological Development (CNPq) and the Coordination for the Improvement of Higher Education Personnel - Brazil (CAPES), Finance Code 001, for scholarships.

## References

- Aquino, L.S., Timm, L.C., Reichardt, K., Barbosa, E.P., Parfitt, J.M.B., Nebel, A.L.C., Penning, L.H., 2015. State-space approach to evaluate effects of land levelling on the spatial relationships of soil properties of a lowland area. *Soil Till. Res.* 145, 135-147.
- Arnold, J.G., Srinivasan, R., Muttiah, R.S., Williams, J.R., 1998. Large area hydrologic modeling and assessment: part I: model development. *J. Am. Water Resour. Assoc.* 34, 73–89.
- Awe, G.O., Reichert, J.M., Timm, L.C., Wendoroth, O., 2015. Temporal processes of soil water status in a sugarcane field under residue management. *Plant Soil* 387, 395-411.
- Baiamonte, G., Bagarello, V., D'Asaro, F., Palmeri, V., 2017. Factors influencing point measurement of near-surface saturated soil hydraulic conductivity in a small Sicilian basin. *Land Degrad. Dev.* 28, 970–982.
- Ball, B.C., Watson, C.A., Baddeley, J.A., 2007. Soil physical fertility, soil structure and rooting conditions after ploughing organically managed grass/clover swards. *Soil Use Manage.* 23, 20–27.
- Beskow, S., Timm, L.C., Tavares, V.E.Q., Caldeira, T.L., Aquino, L.S., 2016. Potential of the LASH model for water resources management in data-scarce

basins: a case study of the Fragata river basin, southern Brazil. *Hydrol. Sci. J.* 61, 2567–2578.

Blake, G.R., Hartge, K.H., 1986. Bulk density. In: Klute, A. (Ed.), *Methods of Soil Analysis. Part 1, 2nd ed. Agronomy Monograph*. ASA-SSSA, Madison, WI, pp. 363–382 vol. 9.

Bonell, M., Purandara, B.K., Venkatesh, B., Krishnaswamy, J., Acharya, H.A.K., Singh, U.V., Jayakumar, R., Chappell, N., 2010. The impact of forest use and reforestation on soil hydraulic conductivity in the Western Ghats of India: implications for surface and sub-surface hydrology. *J. Hydrol.* 391, 47–62.

Caldeira, T.L., Mello, C.R., Beskow, S., Timm, L.C., Viola, M.R., 2019. LASH hydrological model: An analysis focused on spatial discretization. *Catena* 173, 183–193.

Davis, J.C., 1986. *Statistics and Data Analysis in Geology*. 2nd ed. New York, John Wiley & Sons.

Duan, L., Huang, M., Zhang, L., 2016. Use of a state-space approach to predict soil water storage at the hillslope scale on the Loess Plateau, China. *Catena* 137, 563–571.

Gee, G.W., Bauder, J.W., 1986. Particle-size analysis. In: Klute, A. (Ed.), Methods of Soil Analysis. Part 1, 2nd ed Agronomy Monograph Vol. 9. ASA-SSSA, Madison, WI, pp. 383–411.

Hair, J., Black, W.C., Babin, B.J., Anderson, R.E., 2009. Multivariate Data Analysis. 5th ed. Prentice Hall, New York.

Hasenack, H.; Weber, E., 2010. Base cartográfica vetorial continua do Rio Grande do Sul – escala 1:50.000. Porto Alegre: UFRGS – Centro de Ecologia, CD-ROM.

Hassler, S.K., Lark, R.M., Zimmermann, B., Elsenbeer, H., 2014. Which sampling design to monitor saturated hydraulic conductivity? European J. Soil Sci. 65, 792–802.

Hu, W., She, D., Shao, M., Chun, K., Si, B., 2015. Effects of initial soil water content and saturated hydraulic conductivity variability on small watershed runoff simulation using LISSEM. Hydrol. Sci. J. 60, 1137–1154.

Huffman, R.L., Fangmeier, D.D., Elliot, W.J., Workman, S.R., Schwab, G.O., 2011. Soil and water conservation engineering. sixth ed. St. Joseph, ASABE.

Hui, S., Wendroth, O., Parlange, M.B., Nielsen, D.R., 1998. Soil variability – infiltration relationships of agroecosystems. J. Balkan Ecol. 1, 21-40.

Jolliffe, I.T., 2002. Principal Component Analysis, second ed. New York, Springer.

Klute, A., 1986. Water retention: laboratory methods. In: Klute, A. (Ed.), Methods of Soil Analysis. Part 1, 2nd ed. Agronomy Monograph vol. 9. ASA-SSSA, Madison, WI, pp. 635–662.

Klute, A., Dirksen, C., 1986. Hydraulic conductivity and diffusivity: laboratory methods. In: Klute, A. (Ed.), Methods of Soil Analysis. Part 1, 2nd ed. Agronomy Monograph vol. 9. ASA-SSSA, Madison, WI, pp. 687–734.

Kuinchner, A., Buriol, G.A., 2001. Clima do estado do Rio Grande do Sul segundo a classificação climática de Köppen e Thornthwaite. Disciplinarum Scientia - Série: Ciências Exatas 2, 171–182.

Kværnø, S.H., Stolte, J., 2012. Effects of soil physical data sources on discharge and soil loss simulated by the LISEM model. Catena 97, 137–149.

Leij, F.J., Romano, N., Palladino, M., Schaap, M.G., Coppola, A., 2004. Topographical attributes to predict soil hydraulic properties along a hillslope transect. Water Resour. Res. 40, W02407.

Lizaga, I., Quijano, L., Gaspar, L., Ramos, M.C., Navas, A., 2019. Linking land use changes to variation in soil properties in a Mediterranean mountain agroecosystem. Catena 172, 516-527.

Loague, K., Gander, G.A., 1990. R-5 revisited. 1. Spatial variability of infiltration on a small rangeland catchment. *Water Resour. Res.* 26, 957–971.

Massey, F.J., 1951. The Kolmogorov–Smirnov test for goodness of fit. *J. Am. Stat. Assoc.* 46, 68–78.

Moore, I.D., Gessler, P.E., Nielsen, G.A., Peterson, G.A., 1993. Soil attribute prediction using terrain analysis. *Soil Sci. Soc. Am. J.* 57, 443–452.

Morbidelli, R., Saltalippi, C., Flammini, A., Cifrodelli, M., Picciafuoco, T., Corradini, C., Govindaraju, R., 2017. In-situ measurements of soil saturated hydraulic conductivity: assessment of reliability through rainfall-runoff experiments. *Hydrol. Process.* 31, 3084–3094.

Nelson, D.W., Sommers, L.E., 1982. Total carbon, organic carbon and organic matter. In:

Page, A.L., Miller, R.H., Keeney, D.R. (Eds.), *Methods of Soil Analysis. Part 2, 2nd ed.*

Agronomy Monograph vol. 9. ASA-SSSA, Madison, WI, pp. 534–580.

Nielsen, D.R., Alemi, M.H., 1989. Statistical opportunities for analyzing spatial and temporal heterogeneity of field soils. *Plant Soil* 115, 285-296.

Nielsen, D.R., Wendoroth, O., 2003. Spatial and temporal statistics – sampling field soils and their vegetation. Catena-Verlag, Cremlingen-Desdedet.

Oldoni, H., Terra, V.S.S., Timm, L.C., Reisser Júnior, C., Monteiro, A.B., 2019. Delineation of management zones in a peach orchard using multivariate and geostatistical analyses. *Soil Till. Res.* 191, 1 - 10.

Ottoni, M.V., Ottoni Filho, T.B., Lopes-Assad, M.L.R.C., Rotunno Filho, O.C., 2019. Pedotransfer functions for saturated hydraulic conductivity using a database with temperate and tropical soils. *J. Hydrol.* 575, 1345-1358.

Papanicolaou, A., Elhakeem, M., Wilson, C.G., Lee Burras, C., West, L.T., Lin, H., Clark, B., Oneal, B.E., 2015. Spatial variability of saturated hydraulic conductivity at the hillslope scale: understanding the role of land management and erosional effect. *Geoderma* 243–244, 58–68.

Perrotta, M.M., 2005. Processamento digital básico de imagens de sensores remotos ópticos para uso em mapeamento geológico – programa ENVI. Belo Horizonte: CPRM.

Picciafuoco, T., Morbidelli, R., Flammini, A., Saltalippi, C., Corradini, C., Strauss, P., Blöschl, G., 2019. On the estimation of spatially representative plot scale saturated hydraulic conductivity in an agricultural setting. *J. Hydrol.* 570, 106-117.

Price, K., Jackson, C.R., Parker, A.J., 2010. Variation of surficial soil hydraulic properties

across land uses in the southern Blue Ridge Mountains, North Carolina, USA. *J. Hydrol.* 383, 256–268.

Pruski, F.F., Ferreira, P.A., Ramos, M.M., 1997. A model to design level terraces.

*J. Irrig.*

*Drain. Eng.* 123, 8-12.

Qiao, J., Zhu, Y., Jia, X., Huang, L., Shao, M., 2018. Estimating the spatial relationships between soil hydraulic properties and soil physical properties in the critical zone (0–100 m) on the Loess Plateau, China: A state-space modeling approach. *Catena* 160, 385-393.

R Core Team, 2016. R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna. <https://www.R-project.org>.

Reichardt, K., Timm, L.C., 2020. Soil, Plant and Atmosphere: concepts, processes and applications. 1st. ed. Springer, Basel.

Salemi, L.F., Groppo, J.D., Trevisan, R., Moraes, J.M., Ferraz, S.F.B., Villani, J.P., Duarte-Neto, P.J., Martinelli, L.A., 2013. Land-use change in the Atlantic rainforest region: Consequences for the hydrology of small catchments. *J. Hydrol.* 499, 100–109.

Sartori, A., Lombardi Neto, F., Genovez, A.M., 2005. Classificação hidrológica de solos brasileiros para a estimativa da chuva excedente com o método do Serviço de Conservação do Solo dos Estados Unidos Parte 1: classificação. Rev. Bras. Recur. Hídricos 10, 5-18.

Soil Conservation Service (SCS), 1986. Hydrology for small watersheds. Technical Release 55. Springfield: United States Department of Agriculture.

Schaap, M.G., Leij, F.J., van Genuchten, M.T., 2001. Rosetta: A computer program for estimating soil hydraulic parameters with hierarchical pedotransfer functions. J. Hydrol. 251, 163–176.

She, D.L., Qiana, C., Timm, L.C., Beskow, S., Hu, W., Caldeira, T.L., Oliveira, L.M., 2017. Multi-scale correlations between soil hydraulic properties and associated factors along a Brazilian watershed transect. Geoderma 286, 15–24.

She, D.L., Zheng, J.X., Shao, M.A., Timm, L.C., Xia, Y.Q., 2015. Multivariate empirical mode decomposition derived multi-scale spatial relationships between saturated hydraulic conductivity and basic soil properties. Clean-Soil Air Water 43, 910–918.

Shumway, R.H., 1988. Applied statistical time series analyses. Prentice Hall, Englewood Cliffs.

Si, B.C., Zeleke, T.B., 2005. Wavelet coherency analysis to relate saturated hydraulic properties to soil physical properties. *Water Resour. Res.* 41, W11424.

Soil Survey Staff, 2010. Keys to Soil Taxonomy. 11th ed. USDA-Natural Resources Conservation Service, Washington, DC.

Taskinen, A., Sirviö, H., Bruen, M., 2008. Statistical analysis of the effects on overland flow of spatial variability in soil hydraulic conductivity. *Hydrol. Sci. J.* 53, 387–400.

Timm, L.C., Reichardt, K., Oliveira, J.C.M., Cassaro, F.A.M., Tominaga, T.T., Bacchi, O.O.S., Dourado-Neto, D., 2003. Sugarcane production evaluated by the state-space approach. *J. Hydrol.* 272, 226-237.

Vereecken, H., Maes, J., Feyen, J., 1990. Estimating unsaturated hydraulic conductivity from easily measured soil properties. *Soil Sci.* 149, 1-12.

Viola, M.R., Mello, C.R., Beskow, S., Norton, L.D., 2013. Applicability of the LASH model for hydrological simulation of the Grande River Basin, Brazil. *J. Hydrol. Eng.* 18, 1639–1652.

Vogel, H.-J., 2019. Scale issues in soil hydrology. *Vadose Zone J.* 18, 1-10.

Wang, Y., Shao, M., Liu, Z., Horton, R., 2013. Regional-scale variation and distribution patterns of soil saturated hydraulic conductivities in surface and subsurface layers in the loessial soils of China. *J. Hydrol.* 487, 13–23.

Wendroth, O., Reuter, H.I., Kersebaum, C., 2003. Predicting yield of barley across a landscape: a state-space modeling approach. *J. Hydrol.* 272, 250–263.

Wendroth, O., Reynolds, W.D., Vieira, S.R., Reichardt, K., Wirth, S., 1997. Statistical approaches to the analysis of soil quality data. In: Gregorich, E.G., Carter, M.R. (Eds.) *Soil quality for crop production and ecosystem health*. Elsevier Science, Amsterdam, pp 247-276.

Wilding, L.P., Drees, L.R., 1983. Spatial variability and pedology. In: Wilding, L.P., Smeck, N.E., Hall, G.F. (Eds.), *Pedogenesis and Soil Taxonomy: 1. Concepts and Soil Analysis*. second ed. American Society of Agronomy, Madison, pp. 635–662.

Wösten, J.H.M., Pachepsky, Y.A., Rawls, W.J., 2001. Pedotransfer function: Bridging the gap between available basic soil data and missing soil hydraulic characteristics. *J. Hydrol.* 251, 123–150.

Xin-Zhong, W., Guo-Shun, L., Hong-Chao, H., Zhen-Hai, W., Qing-Hua, L., Xu-Feng, L., Wei-Hong, H., Yan-Tao, L., 2009. Determination of management zones for a tobacco field based on soil fertility. *Comput. Electron. Agric.* 65, 168–175.

Zhang, Y., Schaap, M.G., 2019. Estimation of saturated hydraulic conductivity with pedotransfer functions: A review. *J. Hydrol.* 575, 1011-1030.

Zhang, X., Wendoroth, O., Matocha, C., Zhu, J., 2019. Estimating soil hydraulic conductivity at the field scale with a state-space approach. *Soil Sci.* 184, 101-111.

Zhang, Q., Yao, Y., Jia, X., Shao, M., 2017. Estimation of soil organic carbon under different vegetation types on a hillslope of China's northern Loess Plateau using state-space approach. *Can. J. Soil Sci.* 97, 667-677.

Zhao, C., Shao, M., Jia, X., Nasir, M., Zhang, C., 2016. Using pedotransfer functions to estimate soil hydraulic conductivity in the Loess Plateau of China. *Catena* 143, 1–6.

Zimmermann, A., Schinn, D.S., Francke, T., Elsenbeer, H., Zimmermann, B., 2013. Uncovering patterns of near-surface saturated hydraulic conductivity in an overland flow-controlled landscape. *Geoderma* 195-196, 1–11.

Zimmermann, B., Elsenbeer, H., De Moraes, J.M., 2006. The influence of land-use changes on soil hydraulic properties: implications for runoff generation. *Forest Ecol. Manag.* 222, 29-38.

## **6.2. Artigo 2**

Artigo publicado: Journal of Soil Science and Plant Nutrition

DOI: <https://doi.org/10.1007/s42729-020-00239-5>

### **Dominant control of macroporosity on saturated soil hydraulic conductivity at multiple scales and locations revealed by Wavelet analyses**

Luana Nunes Centeno<sup>1</sup>, Wei Hu<sup>2</sup>, Luís Carlos Timm<sup>3\*</sup>, Dongli She<sup>4</sup>, Arlan da Silva Ferreira<sup>5</sup>, Willian Silva Barros<sup>6</sup>, Samuel Beskow<sup>7</sup>, Tamara Leitzke Caldeira<sup>8</sup>

PhD student at Water Resources Post-Graduate Program, Center of Technological Development, Federal University of Pelotas, Campus Porto, Rua Gomes Carneiro, n. 01, CEP: 96010-610, Pelotas, Rio Grande do Sul, Brazil. luananunescenteno@gmail.com

<sup>2</sup>The New Zealand Institute for Plant & Food Research Limited, Private Bag 4704, Christchurch 8140, New Zealand. wei.hu@plantandfood.co.nz

<sup>3</sup>\*Department of Rural Engineering, Faculty of Agronomy, Federal University of Pelotas, Campus Universitário s/n, CEP: 96010-900, Capão do Leão, Rio Grande do Sul, Brazil. Corresponding author: lctimm@ufpel.edu.br

<sup>4</sup>Key Laboratory of Efficient Irrigation-Drainage and Agricultural Soil-Water Environment in Southern China, Ministry of Education, Hohai University, Nanjing 210098, China. shedongli@hhu.edu.cn

<sup>5</sup>Department of Physics, Federal University of Pelotas, Campus Universitário s/n, CEP 96010-900, Capão do Leão, Rio Grande do Sul, Brazil. arlansil@yahoo.com.br

<sup>6</sup>Department of Statistics, Federal University of Pelotas, Campus Universitário s/n, CEP 96010-900, Capão do Leão, Rio Grande do Sul, Brazil. wsbarros@hotmail.com

<sup>7</sup>Center of Technological Development, Federal University of Pelotas, Pelotas, Rio Grande do Sul, Brazil. samuelbeskow@gmail.com

<sup>8</sup>Engineering Center, Federal University of Pelotas, Pelotas, Rio Grande do Sul, Brazil. tamaraleitzkecaldeira@gmail.com

Corresponding author:

Luis Carlos Timm

E-mail: lctimm@ufpel.edu.br

Telephone Number: +555332757260

ORCID number: 0000-0003-2916-8125

## Abstract

**Purpose:** Knowledge on multi-scale and localized control of saturated soil hydraulic conductivity ( $K_{sat}$ ) at the watershed scale is lacking. The objective of this study was to evaluate the multi-scale spatial relationships among  $K_{sat}$  and environmental factors (i.e., soil and topographic attributes and land-use systems) using Wavelet coherency and multiple Wavelet coherence methods.

**Methods:** In the Fragata River Watershed (FRW) in southern Brazil, one hundred points were distributed at equal distances along a 15-km transect. In the 0-20 cm layer, clay and sand fractions, organic carbon content, bulk density, macroporosity,  $K_{sat}$ , and soil water retention curve were determined from soil sampled at each point. The digital elevation model was used for obtaining topographic attributes. A land-use map was developed by use of satellite images.

All data sets were analyzed using descriptive statistics and the relationship among  $K_{sat}$  and the other variables was evaluated through the Spearman correlation coefficient. Wavelet coherency and multiple Wavelet coherence were used to examine the correlation among  $K_{sat}$  and each of the explanatory variables and to investigate the scale-specific and localized multivariate relationships among  $K_{sat}$  and predictor variables, respectively.

**Results:** According to the bivariate Wavelet coherency and multiple Wavelet coherence analyses, macroporosity showed the greatest mean Wavelet coherence and percent area of significance coherence with  $K_{sat}$ . The variations of soil macroporosity itself was enough to explain the variations in  $K_{sat}$  in a multiple-scale and-location domain.

**Conclusion:** Soil macroporosity could be used as a proxy for assessing runoff potential at different land-use systems with different scales in the FRW in southern Brazil.

**Keywords:** spatial variability, scale-location domain, Fragata River Watershed, multiple Wavelet coherence.

## 1 Introduction

Soil hydraulic properties are essential to properly understand the various processes of the hydrological cycle. Water resource management decisions at the watershed scale are assisted by hydrological models based on the critical parameters that soil hydraulic properties can provide (Beskow et al. 2016; She et al. 2017). Saturated soil hydraulic conductivity ( $K_{sat}$ ) is an important soil hydraulic property for studies on soil and water management related to agriculture (Cherobim et al. 2018) and environment (Yao et al. 2015), as well as for simulating and predicting movement of water and solutes in the soil (Hwang et al. 2017). It has previously been shown that  $K_{sat}$  is highly variable in the soil and is a highly sensitive input parameter for distributed hydrological models (Wang et al. 2013). For this reason, many studies have attempted to characterize the spatial variability of  $K_{sat}$  under different climatic and hydrological conditions and spatial scales (Bagarello et al. 2017; Marín-Castro et al. 2016; Hu et al. 2009, 2012; Zhao et al. 2016).

The spatial variability of soil properties is influenced by many different aspects, including both intrinsic (soil material, climate, topography, relief, and time) and extrinsic factors (agricultural practices, such as land levelling,

fertilization and irrigation). Differences in field-scale variations of a soil property could be ascribed to scale-dependence and location-dependent relationships between the property and other prominent ecosystem features like topography, climate etc. (Biswas and Si 2011; Vasques et al. 2012; Xiong et al. 2016). Generally speaking, the spatial variation of soil is an ever-changing process, involving either spatially localized events or being influenced by a larger number of contributing factors (Si 2008). Gao et al. (2012) concluded that the statistical properties investigated for the K<sub>sat</sub> were scale-dependent in an experimental grid (10×10 m), established in a small watershed (50 ha) on the Loess Plateau of China. Using the noise-assisted multivariate empirical mode decomposition method, Yang et al. (2019), concluded that the small-scale variations of K<sub>sat</sub> along an 860-km spatial transect in the Loess Plateau of China were mainly dominated by bulk density and, in general, the large-scale variations of K<sub>sat</sub> were dominated by environmental factors (elevation, slope gradient, annual precipitation, and temperature).

Statistical tools such as Wavelet analyses have been used to quantify and characterize local spatial or temporal variability of soil hydro-physico-chemical properties (Biswas 2018; Hu et al. 2017; Si and Zeleke 2005; Torrence and Compo 1998). The main advantage of such methods is that they can be applied to examine both stationary and non-stationary natural trends of the variables studied, which may in fact, reflect important localized or transient features of soil processes and spatial variability (Si 2008).

Wavelet coherency has been used for understanding scale-specific and localized relationships for transient processes in various areas, including geoscience (Zhang et al. 2017), electrical engineering (Griche. 2017), health

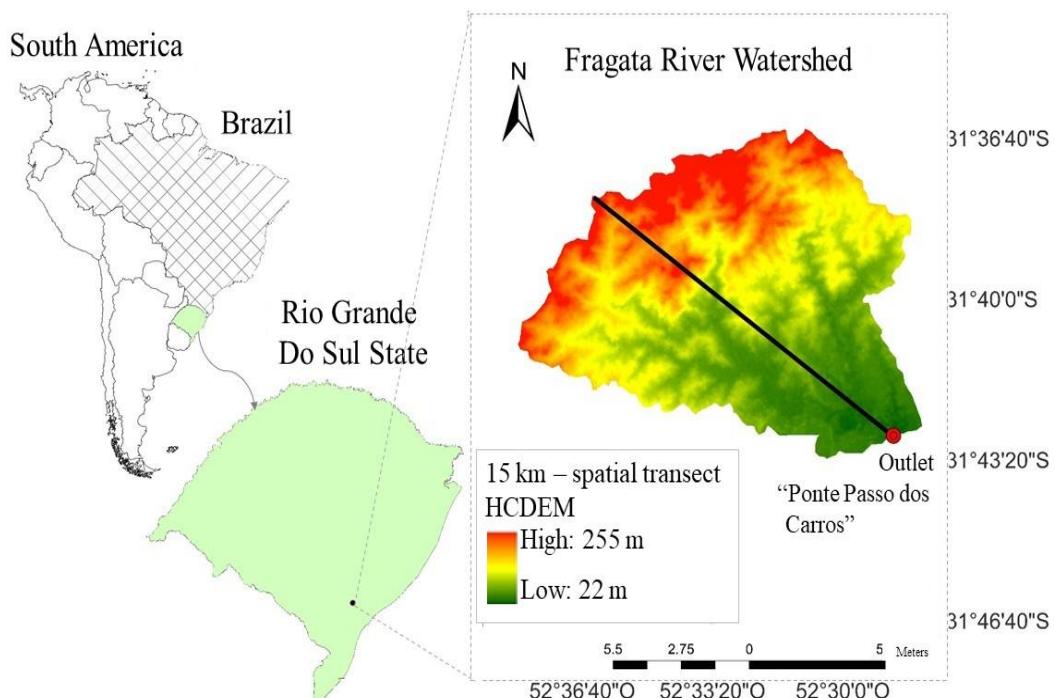
science (Adam et al. 2018), soil science (Biswas 2018) and meteorology (Torrence and Compo 1998). However, this method is limited to using only two variables, and natural processes are rarely simplistic but are generally influenced by more than two environmental factors. For this reason, Hu and Si (2016) developed a multiple Wavelet coherence method to enable the study of scale-specific and localized multivariate ( $> 2$  variables) relationships at multiple scales. To our knowledge, there are no published studies on the use of the multiple Wavelet coherence method to investigate the multi-scale spatial relationships between soil properties and environmental attributes at the watershed scale. Therefore, the objective of this study was to evaluate the multi-scale spatial relationships among Ksat and basic soil properties (soil organic carbon, clay and sand contents, soil bulk density, and macroporosity), and topographic attributes (elevation, slope, and aspect) and land-uses using Wavelet coherence and multiple Wavelet coherence methods along a 15-km transect established in the Fragata River Watershed in southern Brazil.

## 2 Material and Methods

### 2.1 Description of study area

The study was conducted in the Fragata River Watershed (FRW), located in the southern state of Rio Grande do Sul (RS), Brazil (Fig. 1). The section of the FRW used for this study was the drainage area located upstream from the outlet “Ponte Passo dos Carros (PC)”, an area covering about 132 km<sup>2</sup>. Based on the Köppen climate classifications, the climate of the FRW-PC region is characterized as Cfa (Kuinchtner and Buriol 2001), indicating a wet subtropical climate with an average temperature during the hottest month of over 22°C. Average annual

temperatures in this region were determined to be 17.8°C, (range of -3°C to 39.6°C), and the average annual rainfall found to be 1366.9 mm, (range of 823.2 and 1893.2 mm). Following the classifications outlined in the US Soil Taxonomy (Soil Survey Staff 2010), the main types of soils in the watershed were identified as Paleudult (34.2%), Hapludalf + Udorthent (56.7%) and Albaqualf (9.1%).



**Fig 1.** Location of the study area in the South America, Brazil and Rio Grande do Sul state maps, hydrologically consistent digital elevation model (HCDEM) map and the 15 km spatial transect established in the Fragata River Watershed (FRW), outlet “Passo dos Carros”.

## 2.2 Characterization of the study area and soil sampling

Beginning at the Ponte Passo dos Carros (PC) outlet, and continuing through the watershed in a north-west direction, a 15-km spatial transect through

the FRW was created (Fig. 1). One hundred soil sampling points were equidistantly spaced (150 m) along the transect, the coordinates of which were recorded using a portable GPS (Global Positioning System) instrument and identified on the watershed map using ArcGIS (Environmental Systems Research Institute, Redlands, CA). Disturbed soil samples at each point were collected from the 0-0.20 m soil layer and were used to evaluate distributions of particle size (clay and sand contents) using the pipette method (Gee and Bauder 1986). Soil organic carbon content (SOC) was evaluated by use of the Walkley-Black method (Nelson and Sommers 1982). Using volumetric rings (0.03 m high and 0.05 m diameter), undisturbed soil samples (in triplicate) were also collected at each sampling point at a depth of 0.10 m, and served as representative samples of the 0-0.20 m soil layer. Soil bulk density (BD) (Blake and Hartge 1986), saturated soil hydraulic conductivity (K<sub>sat</sub>) using the constant head method (Klute and Dirksen 1986) and soil water retention curve (soil water contents at matric potentials of 0, -1, -6, -10, -33, -100, and -1500 kPa) (Klute 1986) were also evaluated from the samples. The soil water content difference between saturation and -6 kPa of pressure head was taken as soil macroporosity (i.e., >50 µm).

Utilizing a cartographic database of the region (Hasenack and Weber 2010), a watershed relief of the area in question was obtained, providing contour lines, points of known elevation and vectored hydrography at a scale of 1:50,000. This information was then used as the input into the GIS environment ArcGIS, in order to develop a hydrologically consistent digital elevation model (HCDEM) for the FRW. Topographic features at each sampling point were evaluated for elevation (Ele), slope and aspect (measured in degrees clockwise from north and expressed in terms of its cosine) using ArcMap software (version 10.1).

### 2.3 Land-use map

A land-use map was constructed by accessing the website of the Brazilian Institute for Space Research (INPE) and deriving various Landsat satellite images. Specifically, Scenes 221\_81 and 222\_82 were utilized and were interpreted using the Environment for Visualizing Images (ENVI) software suggested by Perrotta (2005). Using a maximum-likelihood supervised classification method, the land use map was developed based on the interpretation of these satellite images, along with 100 training samples obtained in the FRW-PC with a portable GPS. These samples allowed for the identification of the six main land-uses in the FRW-PC, with the following distributions: cultivated pasture (59.0%), native forest (20.6%), silviculture (9.0%), annual cropping (6.5%), native grassland (4.5%), and permanent cropping (0.4%). The mean K<sub>sat</sub> value for each particular land-use system was first calculated to assess the effects of these six main land-use systems on K<sub>sat</sub> data variability along the spatial transect. Then, the six land-use systems were ordered with an ascending index from 1 to 6 according to the magnitude of their mean K<sub>sat</sub>. Therefore, indices of 1, 2, ..., 6 were assigned to permanent cropping, cultivated pasture, native grassland, annual cropping, silviculture, and native forest, respectively, with mean K<sub>sat</sub> value being 13.0, 21.6, 39.0, 47.6, 50.0, and 51.2 mm h<sup>-1</sup>, respectively. Analysis of variance (ANOVA) was performed to evaluate if there were statistical differences (*p* value = 0.05) of K<sub>sat</sub> mean values from the six groups of land-use systems.

To check the normality of each data distribution, all data sets were first submitted to the Kolmogorov-Smirnov (K-S) test (Massey 1951), at the 5%

significance level. Descriptive statistics were then calculated to determine mean, mode, standard deviation, coefficient of variation, maximum and minimum values and skewness coefficient of each data set distribution, using the R statistical software (R core Team 2012). The coefficient of variation (CV) of each data set was classified according to Wilding and Drees (1983):  $CV \leq 15\%$  - low variability of the data set around their mean;  $15\% < CV \leq 35\%$  - moderate variability; and  $CV > 35\%$  - high variability. The Spearman correlation coefficient was calculated to evaluate the relationship among Ksat and the other predictor variables.

## **2.4 Wavelet analyses**

The Wavelet power spectrum of each variable was calculated in order to quantify and characterize the scale-dependence and location-dependence of each dataset along the transect. The Wavelet coherency was used to examine the correlation among Ksat and each of the explanatory variables (i.e., soil organic carbon, clay and sand contents, soil bulk density and macroporosity, land-use system, elevation, slope, and aspect) at different scales and locations along the spatial transect. Next, the multiple Wavelet coherence was used to investigate the scale-specific and localized multivariate relationships among Ksat and predictor variables.

In the current study, we present only the equations related to Wavelet power spectrum and Wavelet coherence. Further details and comprehensive reviews on theoretical aspects and application of both Wavelet analyses can be found elsewhere (Biswas 2018; Farge 1992; Hu et al. 2017; Torrence and Compo 1998). Wavelet transform can be classified as either continuous (CWT) or discrete (DWT). In this study the CWT was preferred due to the fact that Wavelet

coherency using CWT has both frequency and spatial domain readily available, whereas DWT does not (Biswas and Si 2011). The CWT can be defined as the convolution of a spatial series  $Y_j$  of length  $N$  ( $j = 1, 2, 3, \dots, N$ ), along a spatial transect with uniform spatial steps  $\Delta t$  (Grinsted et al. 2004):

$$W^Y(s, \tau) = \sqrt{\frac{\delta t}{s}} \sum_{j=1}^N Y_j \psi_0 \left[ (j - \tau) \frac{\delta t}{s} \right] \quad (1)$$

where  $W^Y(s, \tau)$  are the Wavelet coefficients at scale  $s$  and location  $\tau$ . The function  $\psi_0[]$  is the mother Wavelet function. Among the mother Wavelets, the Morlet Wavelet is commonly utilized in CWT, due to it being a complex symmetric function that preserves the real and imaginary component of Wavelet coefficients (Biswas and Si 2011). The Morlet Wavelet can be shown as (Grinsted et al. 2004):

$$\psi_0(\eta) = \pi^{-1/4} e^{i\omega_0 \eta} e^{-\eta^2/2} \quad (2)$$

where  $\omega_0$  is dimensionless frequency and  $\eta$  is dimensionless space. The Wavelet is stretched in space by varying its scale ( $s$ ), so that  $\eta = s \cdot t$ , and normalizing it to have unit energy (Grinsted et al. 2004). The Morlet Wavelet ( $\omega_0 = 6$ ) is suitable for extracting features and was used in this study because it provided a good balance between space and frequency location (Biswas 2018; Farge 1992).

To evaluate whether the Wavelet coefficients associated at each scale and location were significant, a red noise test of statistical significance (5% of significance level was adopted here) was performed. More details on theoretical aspects about the red noise test of statistical significance can be found in Si and Zeleke (2005) and Si (2008). Briefly, if the Wavelet power of a spatial series at a given scale is determined to be within the 95% confidence interval, this would mean that at this scale and location the Wavelet power is not significantly different from the background red noise.

Before calculating the Wavelet coherency between two spatial series (X and Y), with Wavelet transforms  $W^X(s, \tau)$  and  $W^Y(s, \tau)$ , the cross-Wavelet power spectrum must be calculated and can be defined as  $|W^{Y,X}(s, \tau)| = |W^Y(s, \tau) \cdot \overline{W^X(s, \tau)}|$ , where  $\overline{W^X}$  is the complex conjugate of  $W^X$ . The complex argument of  $W^{Y,X}$  can be interpreted as the local relative phase between X and Y in the spatial frequency domain (Si and Zeleke 2005). Then, the squared Wavelet coherence between X and Y spatial series is calculated as (Grinsted et al. 2004):

$$R^2(s, \tau) = \frac{|S(s^{-1} W^{Y,X}(s, \tau))|^2}{S(s^{-1} |W^X(s, \tau)|^2) \cdot S(s^{-1} |W^Y(s, \tau)|^2)} \quad (3)$$

where S is a smoothing operator and can be represented as:

$$S(W) = S_{\text{scale}}(S_{\text{space}}(W(s, \tau))) \quad (4)$$

where  $S_{\text{scale}}$  denotes smoothing along the Wavelet scale axis and  $S_{\text{space}}$  smoothing in spatial domain.

The Wavelet phase between a response variable ( $Y$ ) and a predictor variable ( $X$ ) is:

$$\phi(s, \tau) = \tan^{-1} \left( \frac{\text{Im}(W^{Y,X}(s, \tau))}{\text{Re}(W^{Y,X}(s, \tau))} \right) \quad (5)$$

where  $\text{Im}$  and  $\text{Re}$  denote the imaginary and real part of  $W^{Y,X}(s, \tau)$ , respectively. More details on the smoothing function used here can be found in Si and Zeleke (2005). To examine if the squared Wavelet coherency coefficients associated at each scale and location were significant, a red noise test of statistical significance (at 5% of significance level) was also performed.

According to Hu and Si (2016), multiple Wavelet coherence is based on a series of auto- and cross-Wavelet power spectra, at different scales and spatial (or temporal) locations for the response variable and all predictor variables.

Assuming a response variable  $Y$  and multiple predictor variables  $X(X = \{X_1, X_2, \dots, X_q\})$ , the squared multiple Wavelet coherence (MWC) at scale  $s$  and location  $\tau$ ,  $\rho_m^2(s, \tau)$ , can be represented as:

$$\rho_m^2(s, \tau) = \frac{\overleftrightarrow{W}^{Y,X}(s, \tau) \overleftrightarrow{W}^{X,X}(s, \tau)^{-1} \overleftrightarrow{W}^{Y,X}(s, \tau)}{\overleftrightarrow{W}^{Y,Y}(s, \tau)} \quad (6)$$

where  $\overleftrightarrow{W}^{Y,X}(s,\tau)$ ,  $\overleftrightarrow{W}^{X,X}(s,\tau)$ , and  $\overleftrightarrow{W}^{Y,Y}(s,\tau)$  are the matrix of the smoothed cross-Wavelet power spectra between response variable Y and predictor variables X, the matrix of the smoothed auto- and cross-Wavelet power spectra among multiple predictor variables X, and the smoothed Wavelet power spectrum of response variable Y, respectively. The  $\overline{\overleftrightarrow{W}^{Y,X}(s,\tau)}$  is a complex conjugate of  $\overleftrightarrow{W}^{Y,X}(s,\tau)$ .

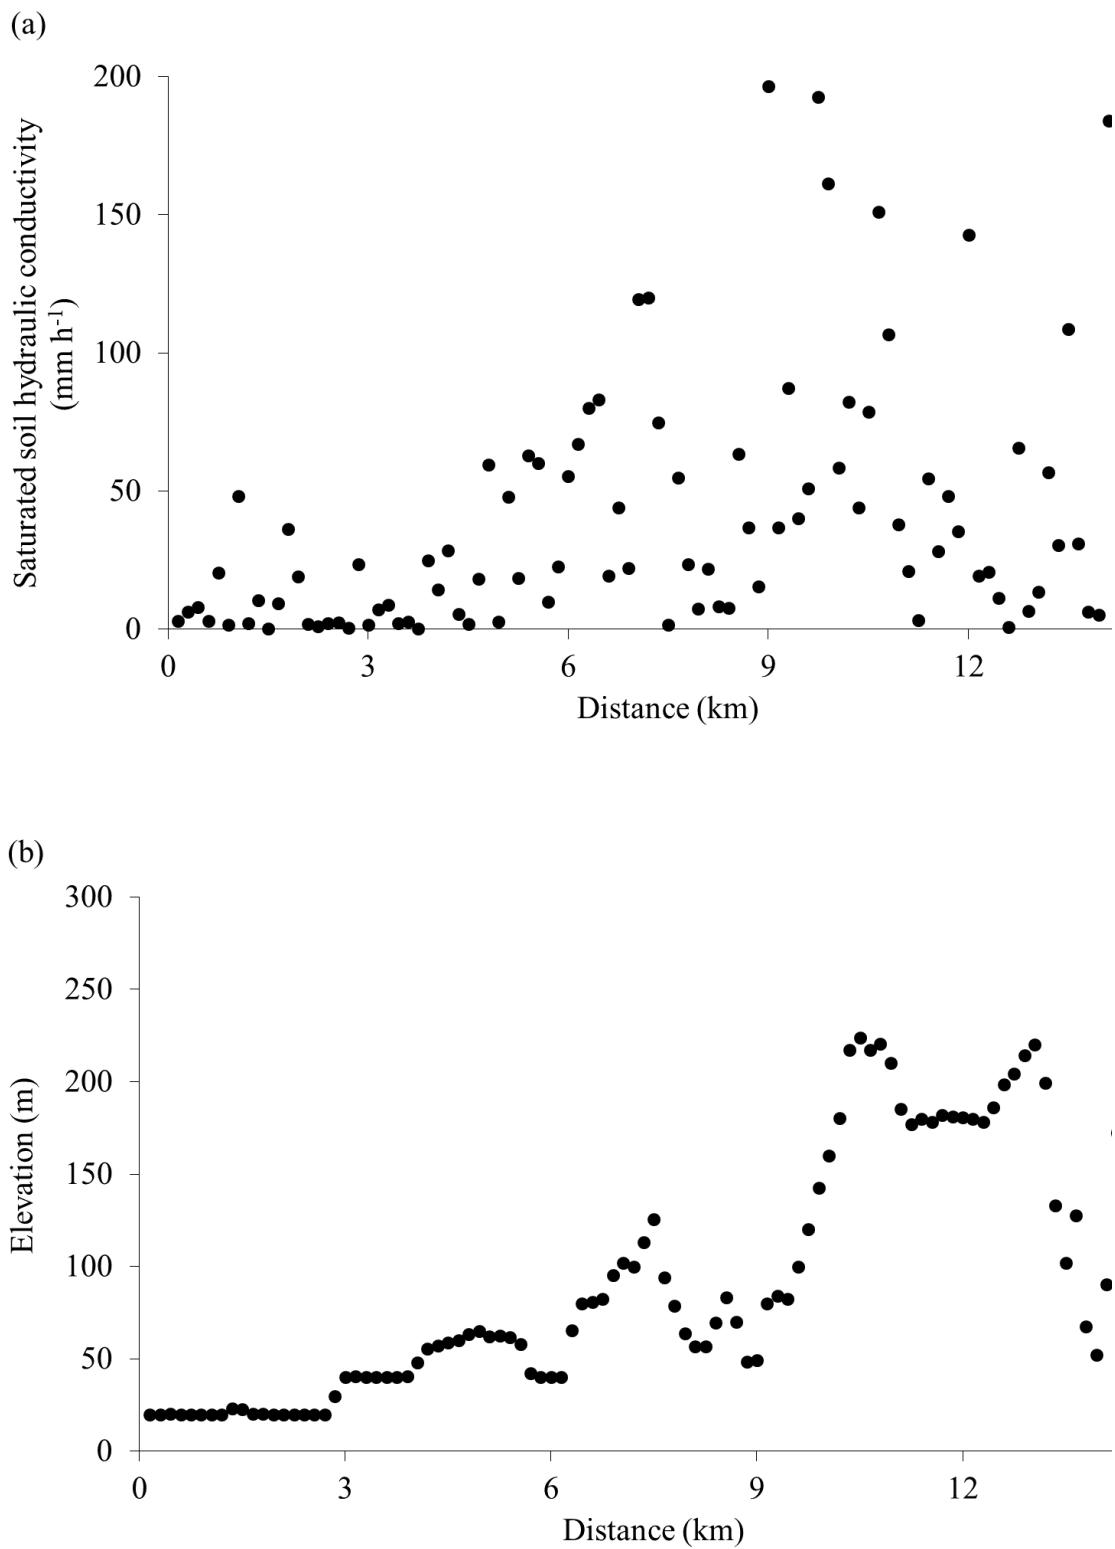
When only one predictor variable (e.g.,  $X_1$ ) is included in X, Eq. (6) becomes the equation for bivariate Wavelet coherence as Eq. (3) shows (Grinsted et al. 2004). Similar to bivariate Wavelet coherence, multiple Wavelet coherences at 95% significance level are calculated using the Monte Carlo method (Grinsted et al. 2004; Hu and Si 2016).

The software for the Wavelet power spectrum and Wavelet coherency was supplied by Grinsted et al. (2004), and the multiple Wavelet coherence was made available in the supplement provided by Hu and Si (2016).

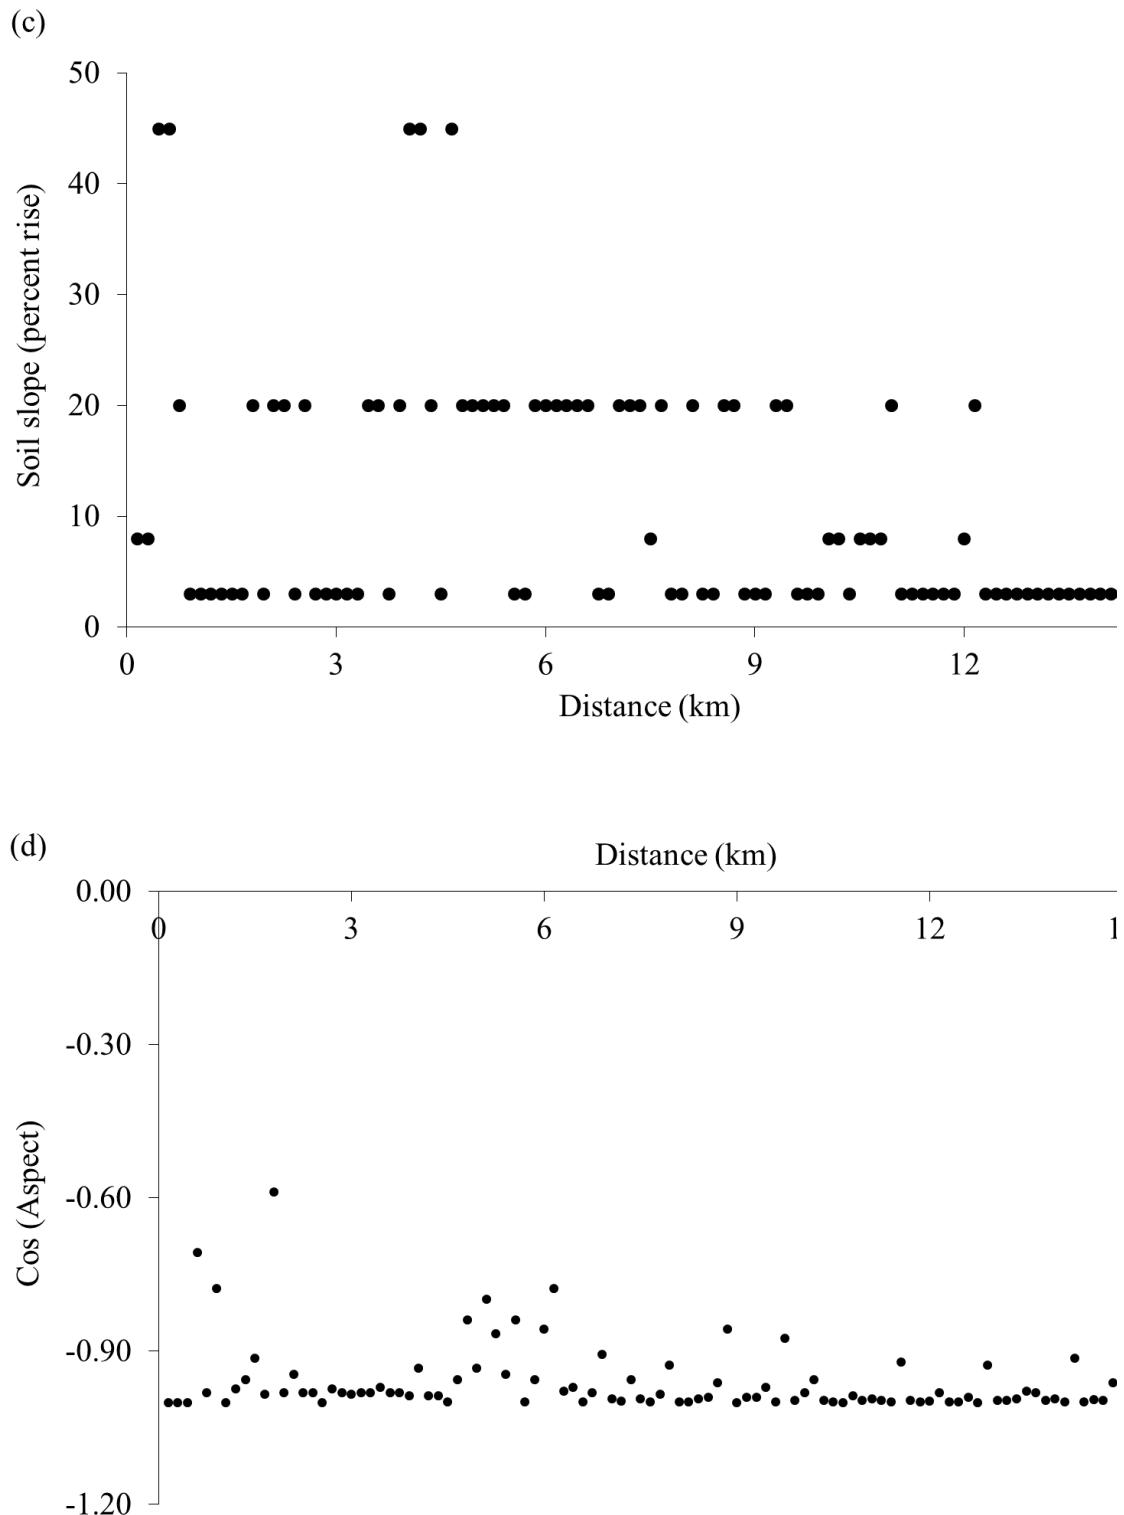
### 3 Results

The values of analyzed soil and topographic variables along the 15 km-spatial transect can be visualized in Fig. 2. The spatial distribution of Ksat values along the 15 km transect indicated a range of variation from  $0.27 \text{ mm h}^{-1}$  (at the distance of 1.5 km from the watershed outlet) to  $196.38 \text{ mm h}^{-1}$  (at the distance of 9.0 km from the watershed outlet), with mean and median values of  $39.93 \text{ mm h}^{-1}$  and  $23.10 \text{ mm h}^{-1}$ , respectively (Fig. 2a). It can also be seen that there is a small point-to-point fluctuation of Ksat values from the origin of the transect until the distance of 4.95 km, passing to a large point-to-point fluctuation of Ksat until

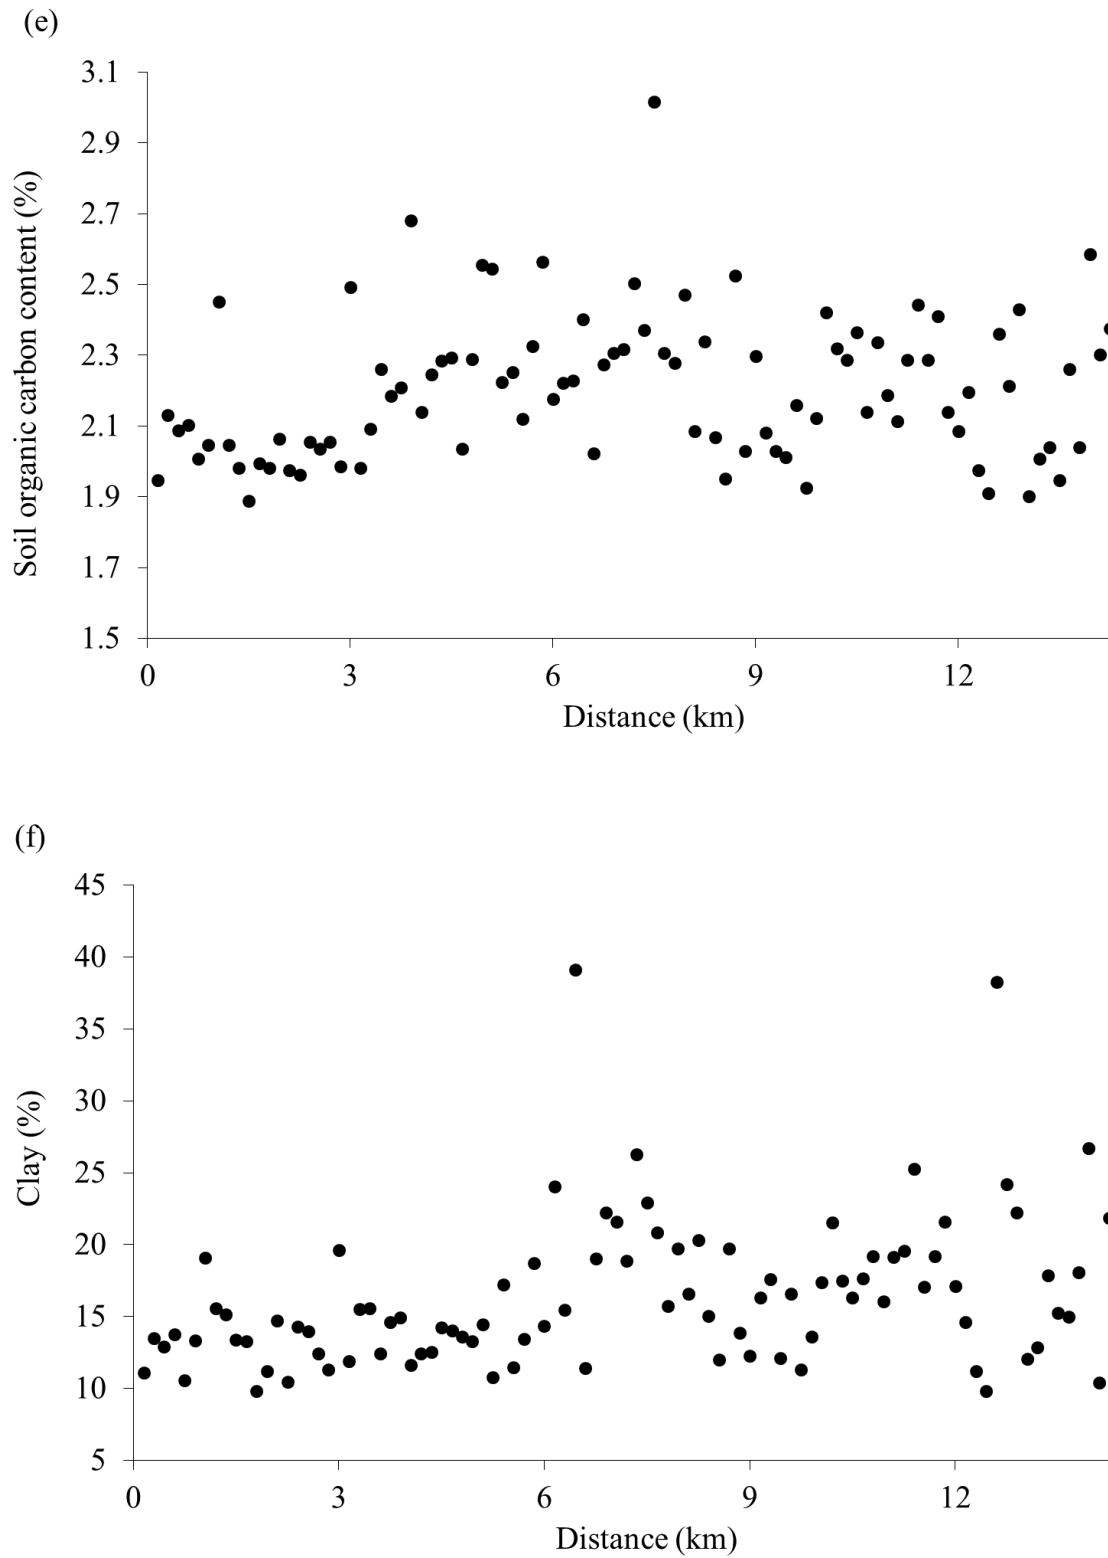
the end of the transect. The elevation ranged from 20 m to 261 m along the 15 km-spatial transect, with a mean value of 98 m (Fig. 2b), while the slope ranged from 3% to 45% (Fig. 2c). The aspect ranged from -1.000 ( $180^\circ$ ) to -0.588 ( $230^\circ$ ) along the transect (Fig. 2d), with a mean value of -0.961. The distribution of soil organic carbon values ranged from 1.89% to 3.02% along the transect, with a mean value of 2.21%. It can be noted that the organic carbon distribution was relatively stable along the transect (Fig. 2e). Clay content values exhibited greater oscillation from the middle to the end of the transect (Fig. 2f), ranging from 10 to 39%. Sand content values ranged from 22% to 84% with a mean value of 65% along the 15 km-spatial transect (Fig. 2g). Macroporosity values ranged from 2.5% to 33.4% with a mean value of 13% (Fig. 2h). It can be noted that there is a clear trend of an increase of soil macroporosity values along the transect, exhibiting great oscillation from the middle to the end of the transect. The opposite trend is observed for the distribution of soil bulk density values along the spatial transect (Fig. 2i), with a mean value of  $1.47 \text{ gcm}^{-3}$  ranging from 1.02 to  $1.74 \text{ gcm}^{-3}$ . Fig. 2j shows that the cultivated pasture is the predominant land-use system along the 15 km-spatial transect.



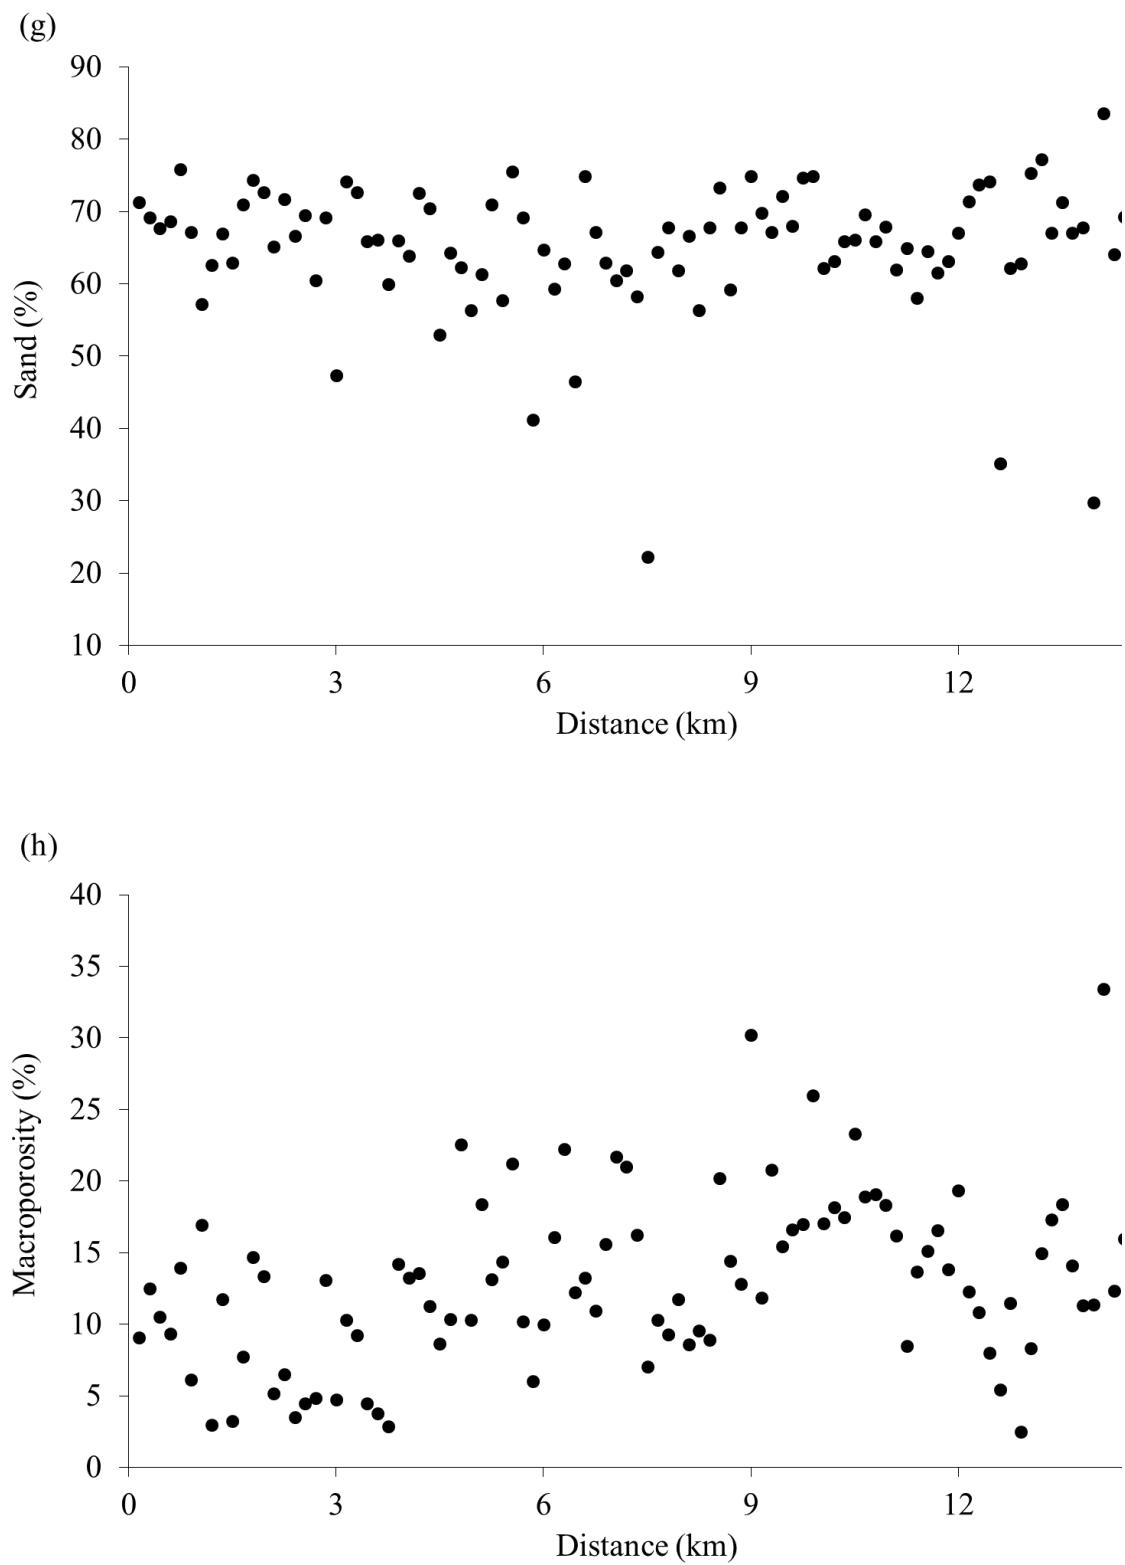
**Fig 2.** Spatial distribution of all studied variables along the 15 km-spatial transect:  
 (a) Saturated soil hydraulic conductivity (K<sub>sat</sub>) and (b) Elevation.



**Fig 2.** Spatial distribution of all studied variables along the 15 km-spatial transect: (c) Soil slope and (d) Aspect.

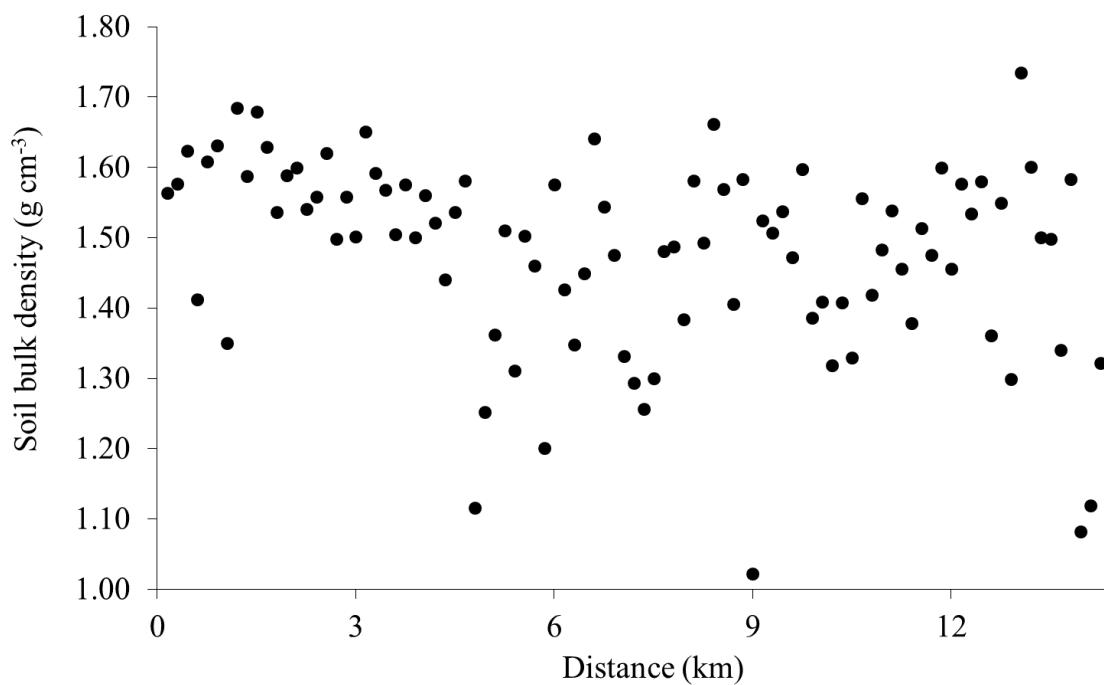


**Fig 2.** Spatial distribution of all studied variables along the 15 km-spatial transect: (e) Soil organic carbon content and (f) Clay content.

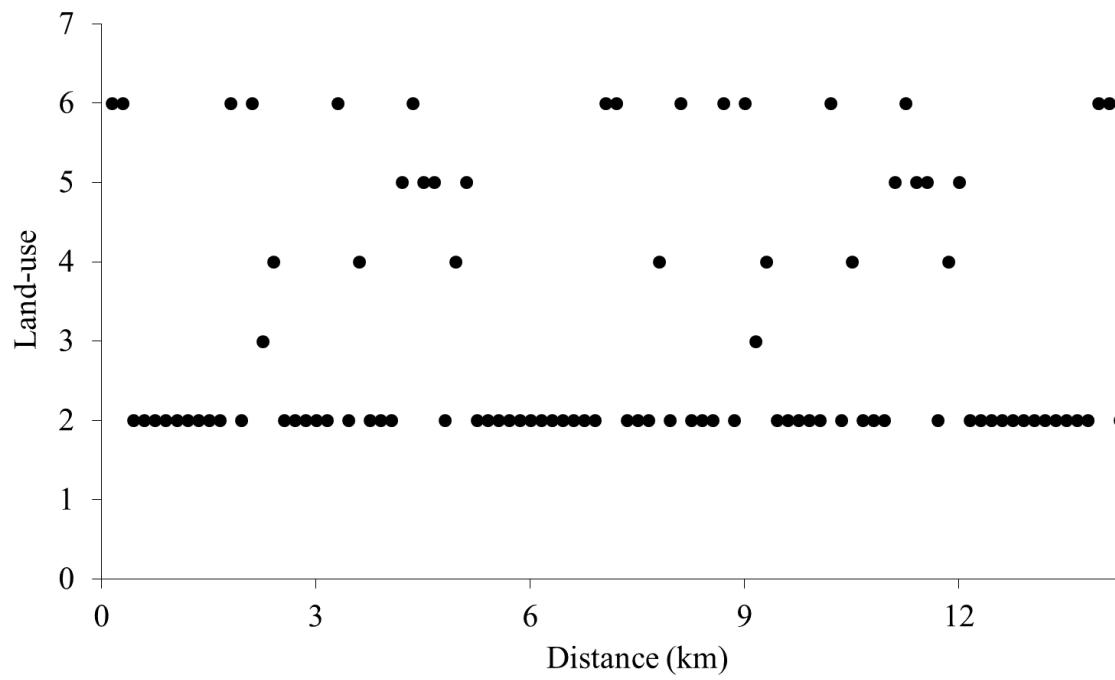


**Fig 2.** Spatial distribution of all studied variables along the 15 km-spatial transect: (g) Sand content and (h) Macroporosity.

(i)



(j)

**Fig 2.** Spatial distribution of all studied variables along the 15 km-spatial transect:

(i) Soil bulk density and (j) Land-use system.

Data distribution of Ksat, elevation, slope, and aspect did not follow the normal distribution according to the K-S test at a probability of 5%, while those of SOC, Clay, Sand, Macro and BD tended to be normally distributed (Table 1). The CV values for data sets which followed the normal distribution ranged from 9% (organic carbon) to 46% (macroporosity) along the transect (Table 1). Macroporosity data distribution exhibited high variability ( $CV > 35\%$ ) while SOC, sand and BD showed low variability ( $CV \leq 15\%$ ) along the transect, according to the CV classification of Wilding and Drees (1983). Clay content showed moderate variability along the transect ( $15\% < CV \leq 35\%$ ).

**Table 1** - Classical statistics applied to all soil and topographical attributes along the 15 km-Fragata River Watershed spatial transect

| Variables                  | Mean   | SD     | Min    | Max    | K-S (p-value)         | CV (%) |
|----------------------------|--------|--------|--------|--------|-----------------------|--------|
| Ksat (mm.h <sup>-1</sup> ) | 39.93  | 44.74  | 0.27   | 196.38 | 1.8E-03 <sup>NN</sup> | -      |
| Elev (m)                   | 98     | 71.779 | 20     | 261    | 6.5E-03 <sup>NN</sup> | -      |
| Slope (%)                  | 11     | 10.958 | 3      | 45     | 2.2E-16 <sup>NN</sup> | -      |
| Aspect                     | -0.961 | 0.067  | -1.000 | -0.588 | 2.1E-07 <sup>NN</sup> | -      |
| SOC (%)                    | 2.21   | 0.204  | 1.89   | 3.02   | 3.4E-01 <sup>N</sup>  | 9      |
| Clay (%)                   | 17     | 5.401  | 10     | 39     | 1.3E-01 <sup>N</sup>  | 32     |
| Sand (%)                   | 65     | 9.225  | 22     | 84     | 1.6E-02 <sup>N</sup>  | 14     |
| Macro (%)                  | 13     | 5.926  | 2.5    | 33.4   | 9.1E-01 <sup>N</sup>  | 46     |
| BD (g.cm <sup>-3</sup> )   | 1.47   | 0.14   | 1.02   | 1.74   | 9.7E-02 <sup>N</sup>  | 10     |

SD: standard deviation; Min and Max: minimum and maximum values, respectively, of the data set; Ksat: saturated soil hydraulic conductivity; Elev: Elevation; Slope: soil slope; SOC: soil organic carbon content; Clay and Sand: clay and sand contents, respectively Macro: soil macroporosity; BD: soil bulk density; CV: coefficient of variation; K-S = p values of the Kolmogorov-Smirnov test; <sup>N</sup> and <sup>NN</sup> normal and non-normal distribution data considering  $p = 0.05$ .

The relationships among Ksat and the other variables at the measurement scale were investigated by calculating the Spearman's correlation coefficient at a significance level of 5% (p-value = 5%) (Table 2). Elevation, slope, and macroporosity had a significant ( $p < 0.05$ ) and positive correlation with Ksat. Soil BD had a significant and negative correlation with Ksat.

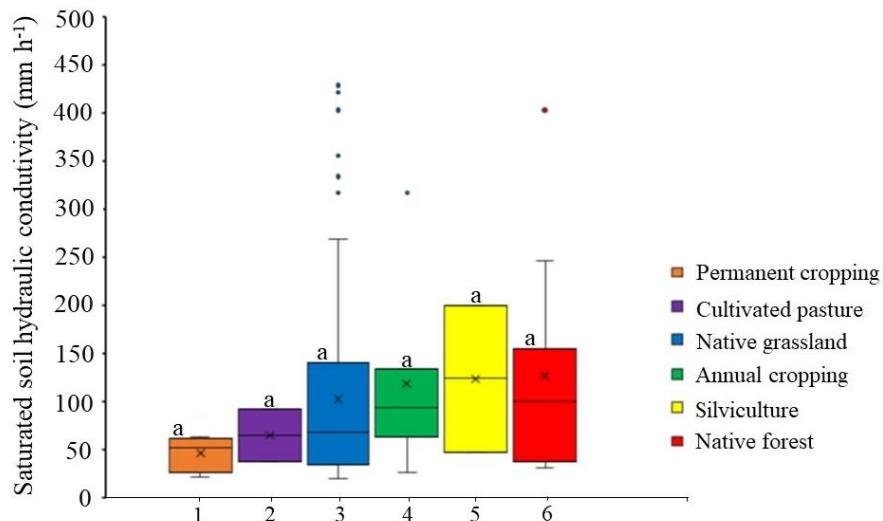
**Table 2 –** Spearman's correlation coefficient values between the soil saturated hydraulic conductivity and the other soil and topographic attributes evaluated along the 15 km-Fragata River Watershed spatial transect

| Attribute                  | Spearman correlation coefficient | p-value |
|----------------------------|----------------------------------|---------|
| Ksat (mm h <sup>-1</sup> ) | 1.000                            | -       |
| Elev (m)                   | 0.481*                           | <0.001  |
| Slope (%)                  | 0.455*                           | 0.002   |
| Aspect                     | -0.090                           | 0.389   |
| SOC (%)                    | 0.166                            | 0.099   |
| Clay (%)                   | 0.193                            | 0.055   |
| Sand (%)                   | 0.101                            | 0.319   |
| Macro (%)                  | 0.858*                           | <0.001  |
| Bd (g cm <sup>-3</sup> )   | -0.389*                          | <0.001  |

\* \*significant Spearman correlation coefficient at p value = 5% of probability level.

It can be noted on Fig.3 that, in general, native forest soils in this study area demonstrated Ksat values approximately 3.9 and 2.4 times greater than permanent cropping and cultivated pasture soils, respectively. In our study, no

statistical differences between mean values of K<sub>sat</sub> were found under different land-use systems at a 5% of significance level (Fig. 3).



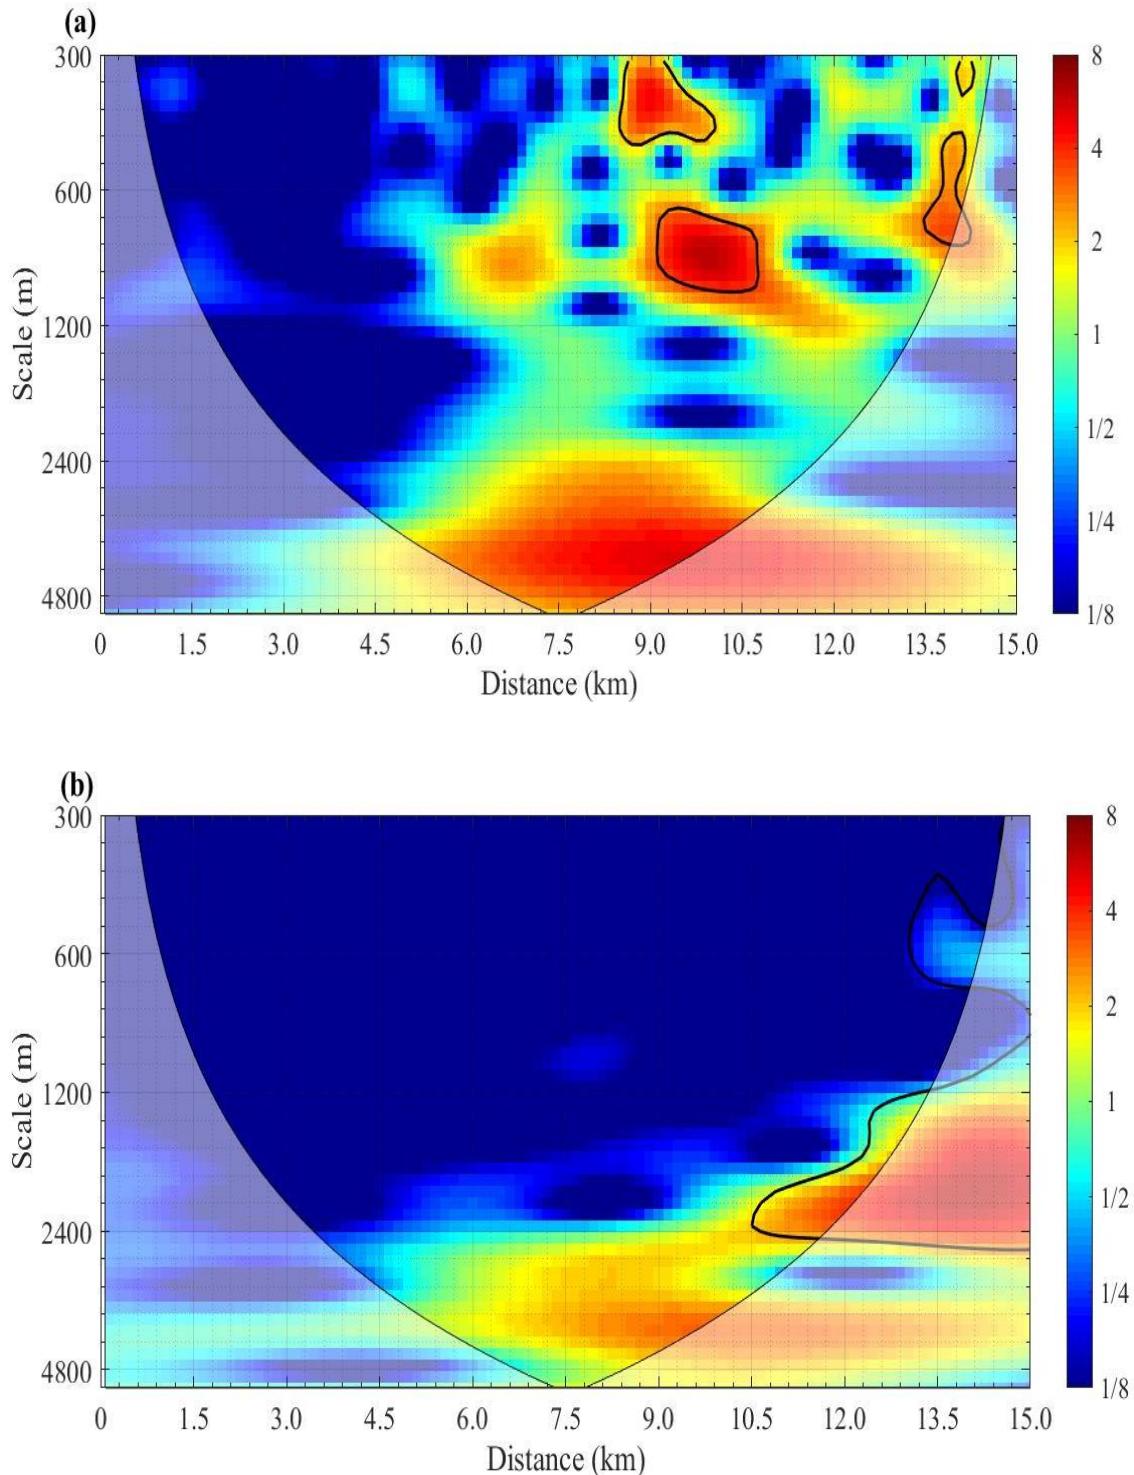
**Fig 3.** Box-plot for saturated soil hydraulic conductivity values and land-use systems.

Fig.4 shows the local Wavelet spectrum for K<sub>sat</sub> and environmental factors. At scales of 300-450 m, K<sub>sat</sub> showed significantly high variances at locations that are 8.5-10.0 km and 14 km from the initial point of the transect at the outlet (Fig. 4a). These variations correspond to the small-scale random variations as shown in Fig. 2a. High variances of K<sub>sat</sub> can be found at scales of 450-750 m and 600-950 m at locations that are 13.5-14.5 km and 9.0–10.5 km, respectively, from the beginning of the transect. The strong variance exhibited at these scales indicated the large point-to-point fluctuation of K<sub>sat</sub> from the middle to the end of the transect (Fig. 2a). High variances of K<sub>sat</sub> were exhibited at

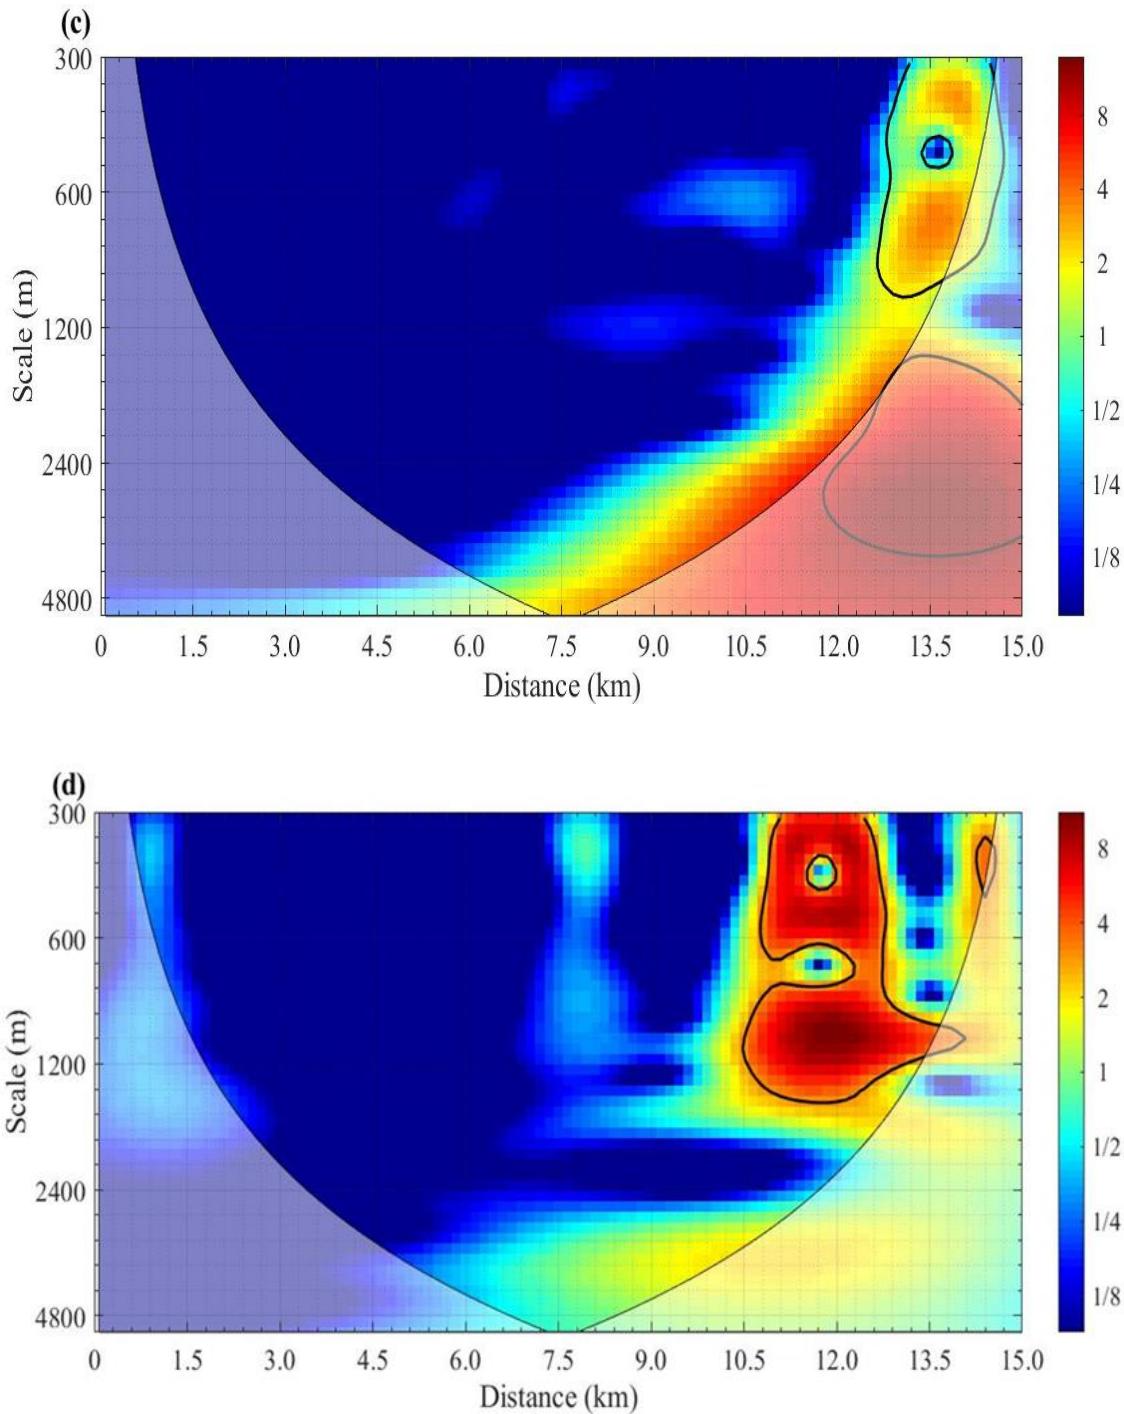
scales of 2,400-4,800 m (Fig. 4a). Wavelet analysis has been used to analyze soil hydro-physical variables with cyclic patterns, their scale and their amplitude (Si 2008; Biswas 2018). However, in reality, the cyclic patterns may not easily be detected because high-frequency (small-scale) processes is usually superimposed on low-frequency (large-scale) processes. In addition, variables are usually transient (e.g., K<sub>sat</sub>) consisting of a variety of frequency regimes that may be localized in space. Because of these two reasons, the variables in fields may not present obvious cyclic characteristic like our case although some influencing factors such as elevation showed more obvious cyclic pattern (Fig. 2b). Therefore, one of the advantages of the Wavelet is that it can detect the scale-specific and localized features of variables of interest.

The elevation local Wavelet spectrum indicates that high and significant variances of elevation are depicted at scales of 400-2,500 m, at locations that are 10.5 km from the beginning of the transect to its end (Fig. 4b). High variances of slope are exhibited at scales of 300-750 m at locations that are from the beginning to the middle of the transect (Fig. 4c). Fig. 4d shows that high variances of aspect are exhibited at scales of 300-1,400 m at locations that are 10.5-14.0 km from the initial point of the transect at the outlet. At small scales (300-450 m), high variances of SOC are found at locations that are 7.0-9.0 km and around 13.0 km from the beginning of the transect (Fig. 4e). At large scales (3,200-3,600 m) at locations that are 7.0-10.5 km from the beginning of the transect, high variances of SOC were found. Fig. 4f shows that high variances of clay are exhibited at small scales (300-450 m) at locations that are around 6.0 km and 12.0 km from the beginning of the transect. At scales of 600-1,200 m strong and significant variances of clay are exhibited at locations that are 12-13.5 km from the start of

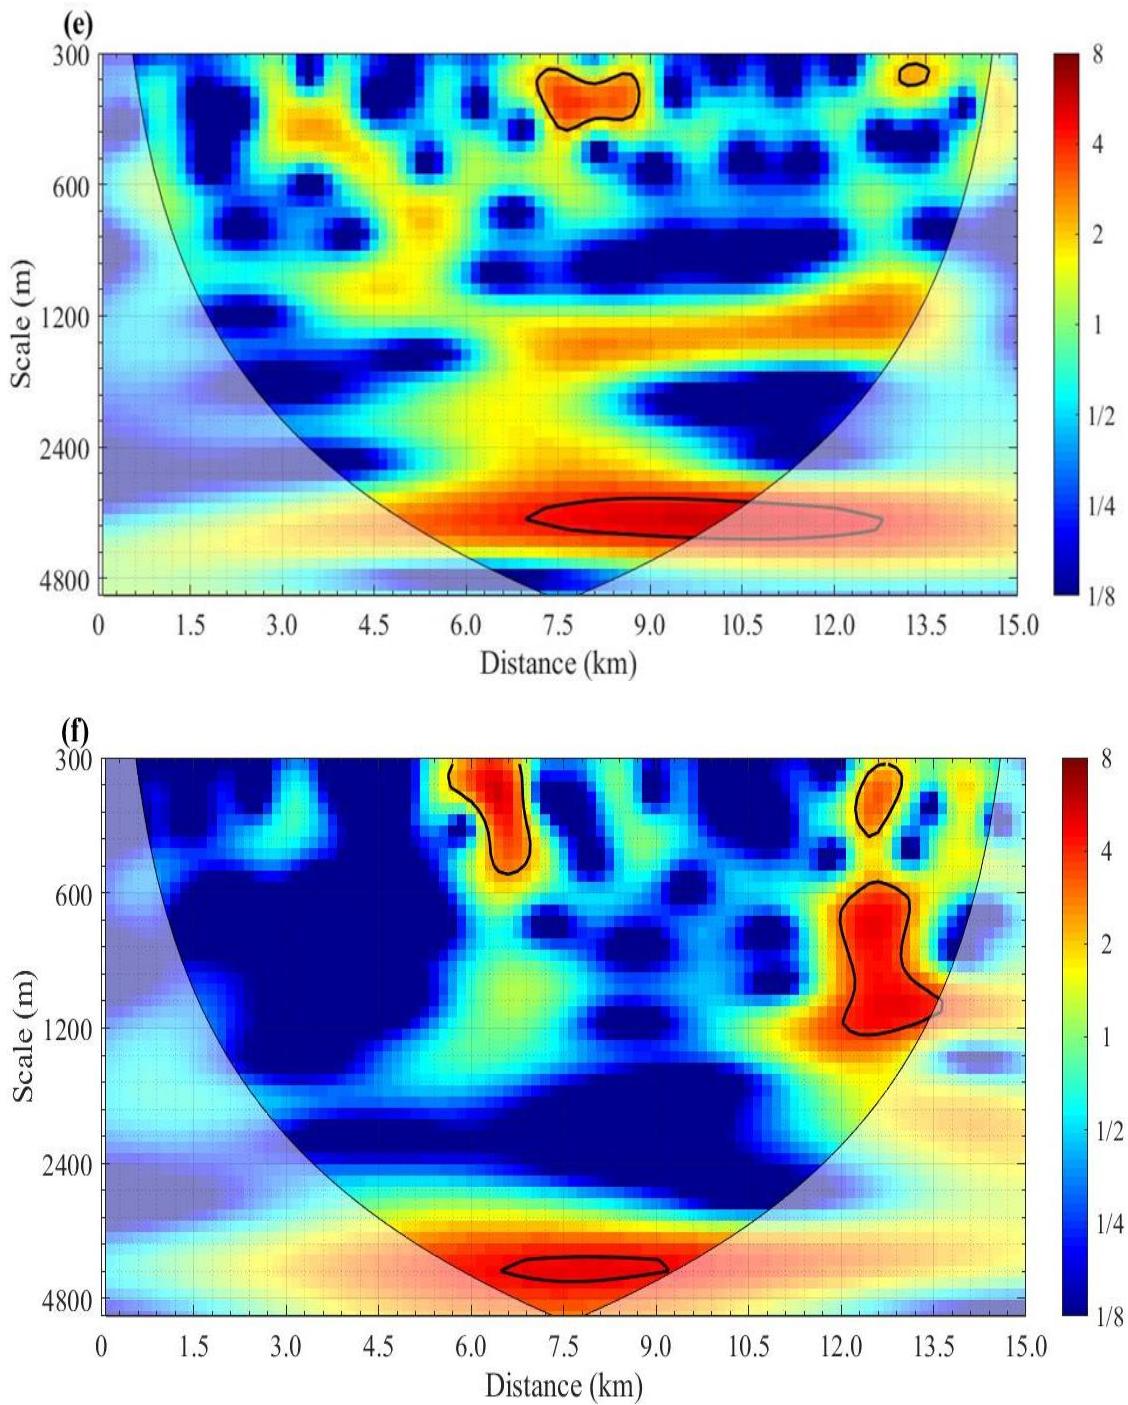
the transect. It can be noted that local Wavelet spectrum of Ksat (Fig. 4a) and clay (Fig. 4f) presented similar patterns at scales of 300-600 at locations around 13.0 km from the beginning of the transect. At small scales (300-450 m) at locations from the middle to the end of the transect, the sand Wavelet spectrum (Fig. 4g) exhibited similar behavior compared with those of Ksat, SOC, and clay. High variances of sand content are observed at scales of 900-1,300 m at locations that are 6.0-7.5 km and 12.0-13.5 km from the origin of the transect. At small scales (300-450 m), high variances of macroporosity are exhibited at locations that are 7.0-9.0 km and around 14.0 km from the beginning of the transect (Fig. 4h). Common variance behavior can be observed among the local Wavelet spectrum of Ksat (Fig. 4a), SOC (Fig. 4e), clay (Fig. 4f) and macroporosity (Fig. 4h) at scales of 300-450 m at locations from the middle to the end of the 15 km-spatial transect. At small scales (300-450 m) at locations that are around 9.0 km and 13.5 km from the start of the transect, high and significant variances are depicted for Wavelet spectrum of BD (Fig. 4i). The land-use Wavelet spectrum (Fig.4) shows similar behavior of that of Ksat (Fig. 4a) at small scales at locations from the middle to the end of the transect.



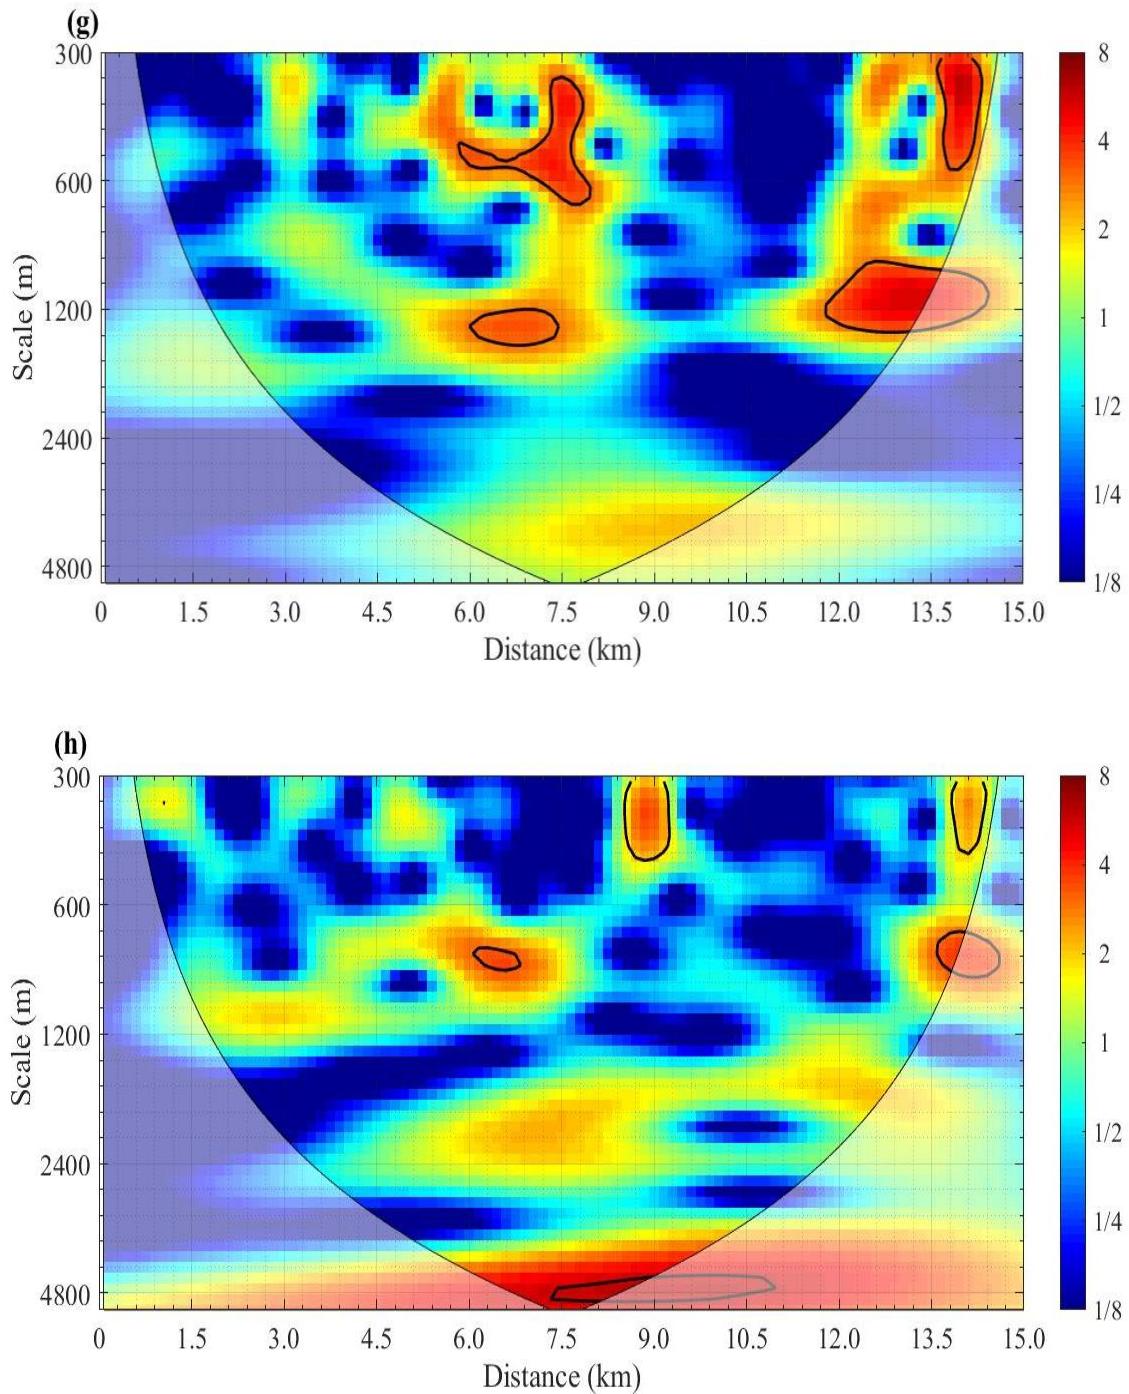
**Fig 4.** Local Wavelet spectrum of all studied variables: (a) Saturated soil hydraulic conductivity (Ksat) and (b) Elevation. Thick solid lines indicate the 5% significance level against the background red noise and thin solid lines indicate the cone of influence (COI) where edge effects might distort the Picture.



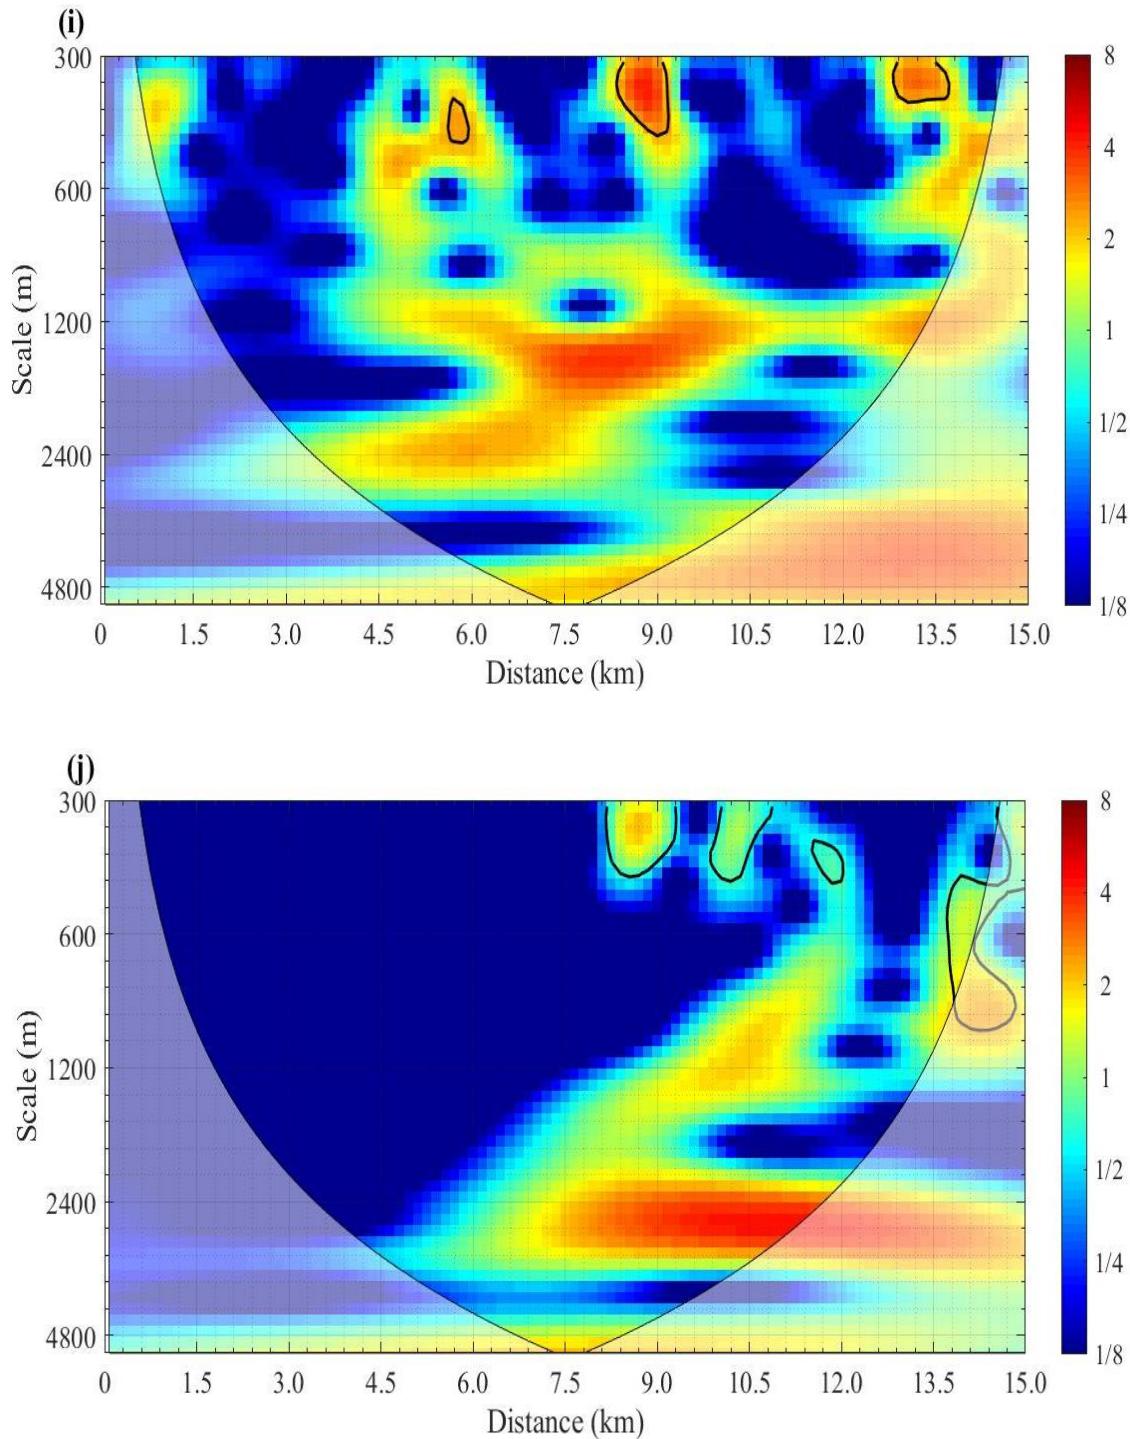
**Fig 4.** Local Wavelet spectrum of all studied variables (c) Soil slope and (d) Aspect. Thick solid lines indicate the 5% significance level against the background red noise and thin solid lines indicate the cone of influence (COI) where edge effects might distort the Picture.



**Fig 4.** Local Wavelet spectrum of all studied variables: (e) Soil organic carbon content and (f) Clay content. Thick solid lines indicate the 5% significance level against the background red noise and thin solid lines indicate the cone of influence (COI) where edge effects might distort the Picture.



**Fig 4.** Local Wavelet spectrum of all studied variables: (g) Sand content and (h) Macroporosity. Thick solid lines indicate the 5% significance level against the background red noise and thin solid lines indicate the cone of influence (COI) where edge effects might distort the Picture.



**Fig 4.** Local Wavelet spectrum of all studied variables: (i) Soil bulk density and (j) Land-use system. Thick solid lines indicate the 5% significance level against the background red noise and thin solid lines indicate the cone of influence (COI) where edge effects might distort the Picture.

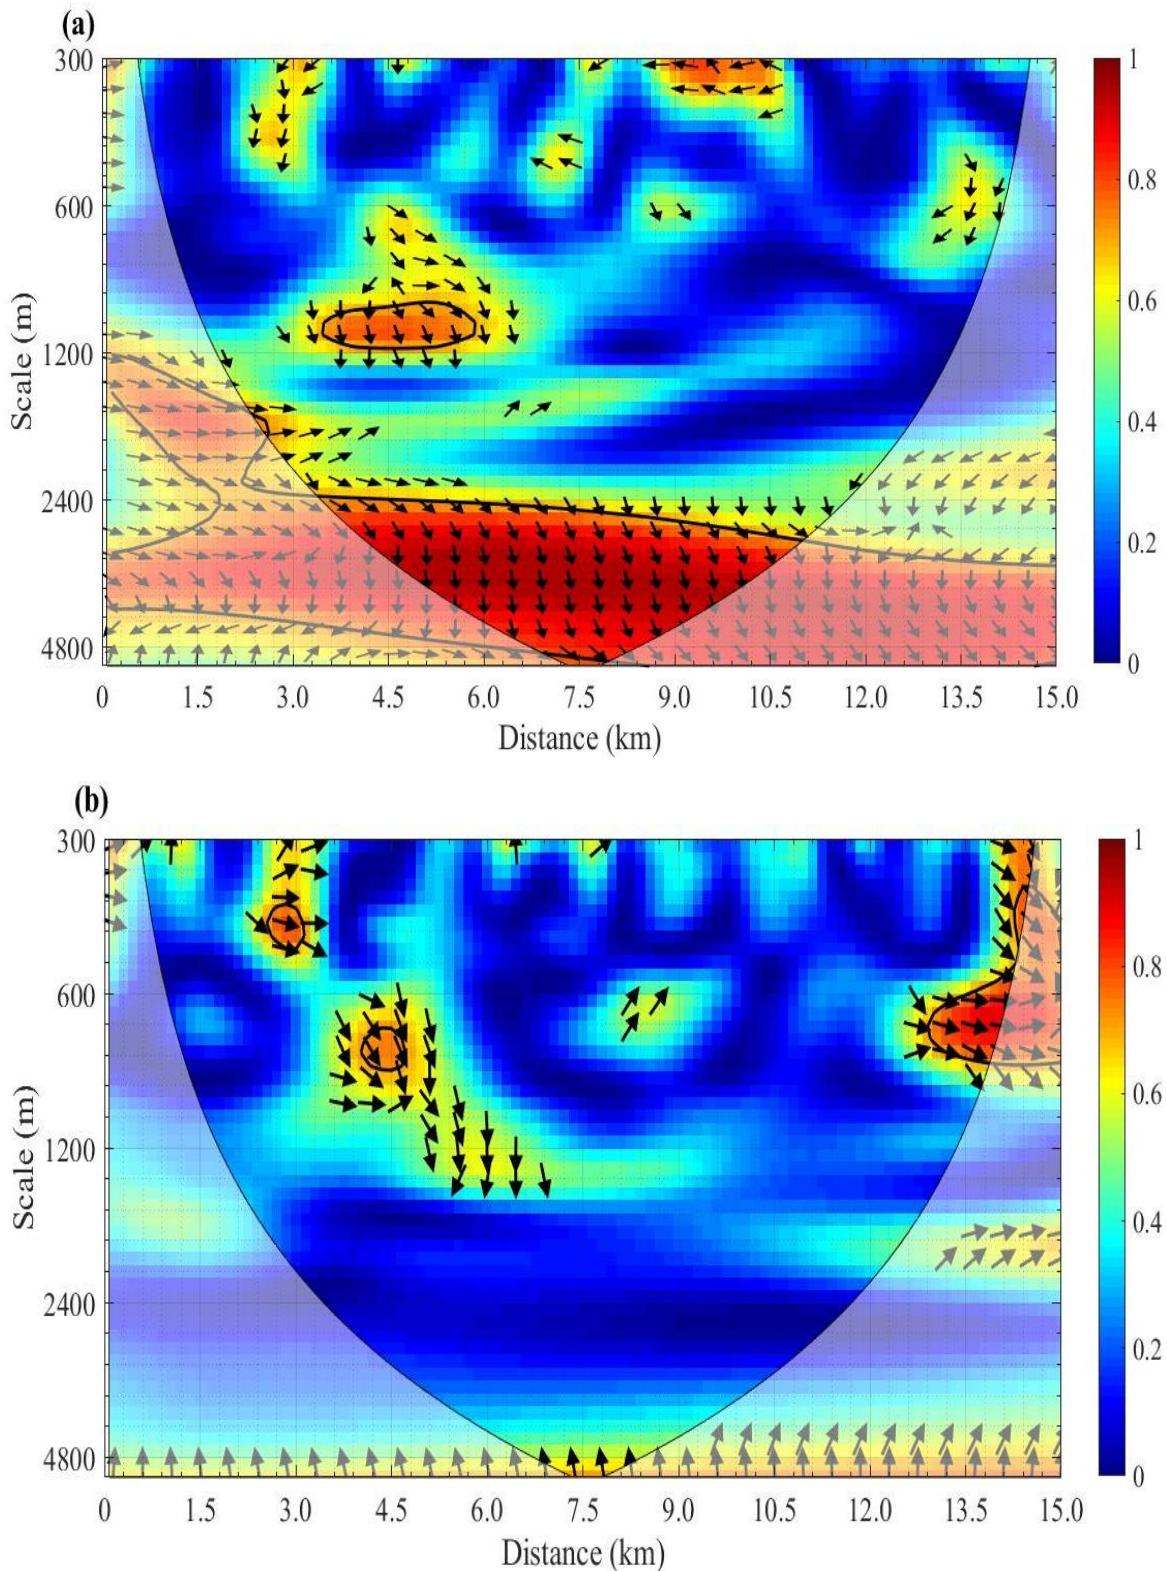
The Wavelet coherency between Ksat and all studied variables is shown in Fig. 5. It can be seen that there is a high and significant coherency between Ksat and elevation (Fig. 5a), and SOC (Fig. 5d), and clay (Fig. 5e), and sand (Fig. 5f) at large scales (2,400-4,800 m) at locations that are 4.0 km-12.0 km from the origin of the transect, indicating that their covariance is significantly different from that of red noise at these scales.

High coherences were exhibited between Ksat and Soil slope at scales of 300-1,500 m at locations that are 9.0-13.5 km from the initial point of the transect (Fig. 5b). At large scales (2,400-4,800 m) through the whole transect, a positive and significantly correlation between Ksat and aspect can be seen in Fig. 5c, while a positive and significant correlation is found between them at small scales at distances that are 0.6-1.2 km and 2.85-3.75 km from the beginning of the transect. At all scales through the whole sampling transect, high and significant coherency can be found between Ksat and macroporosity (Fig. 5g).

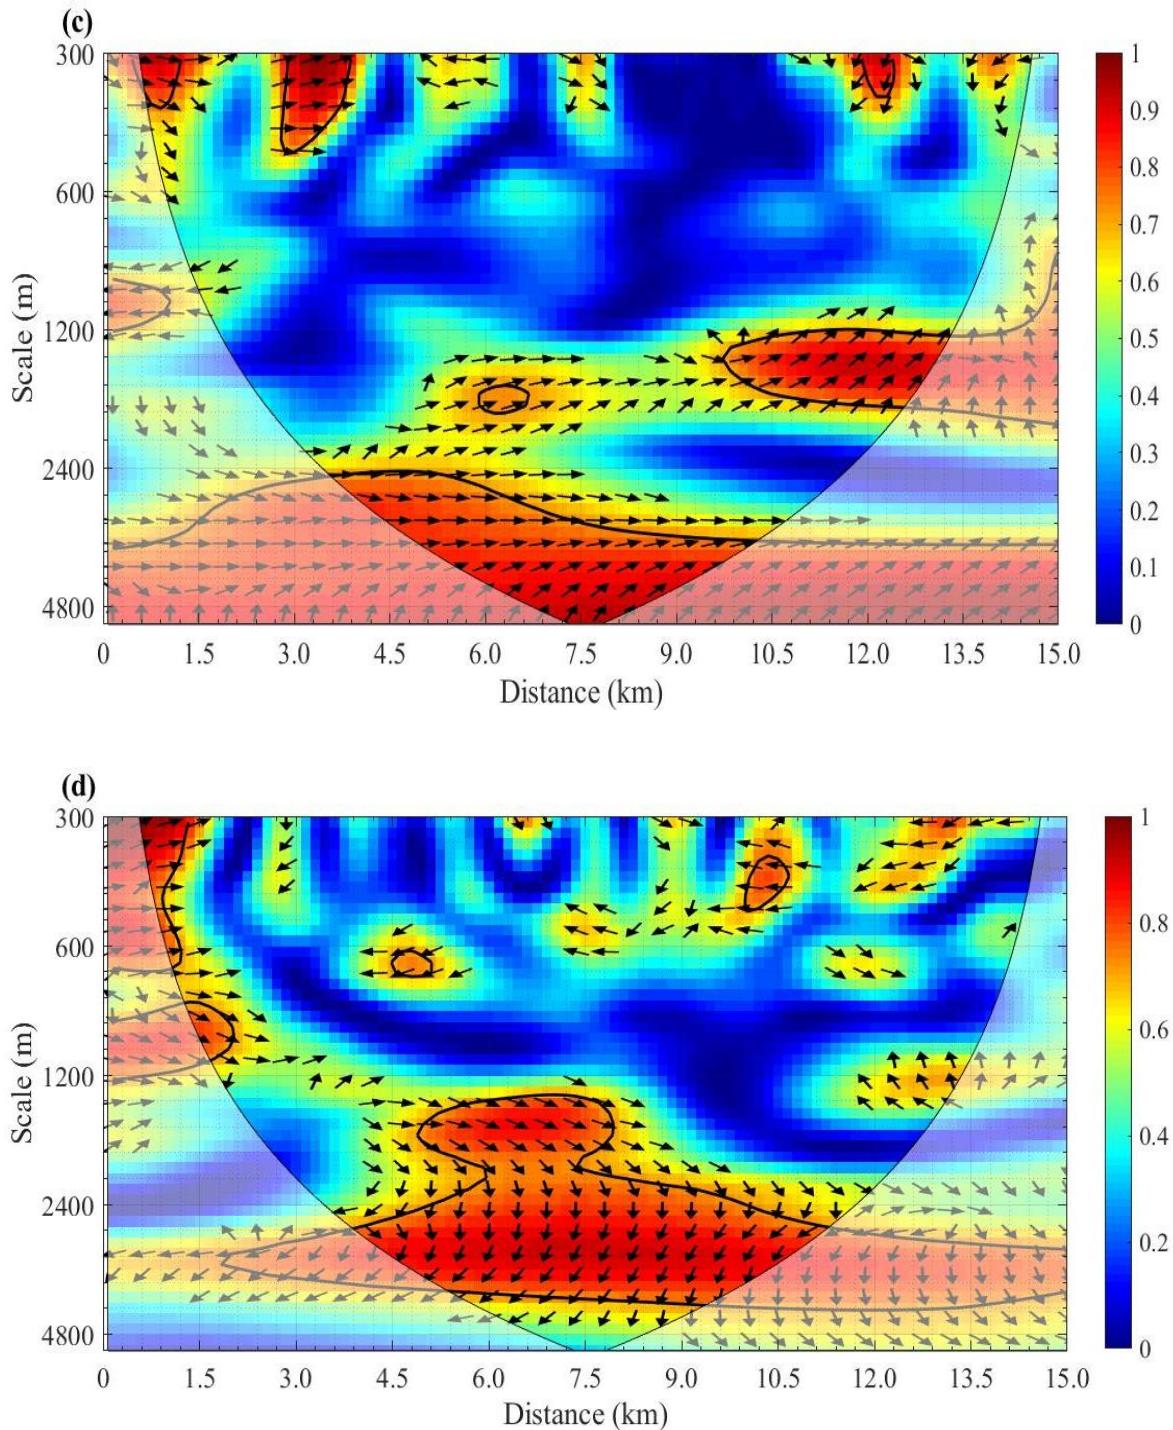
The Wavelet coherence spectrum between Ksat and soil BD exhibited high and significant covariance at scales of 300-1,900 m and a predominantly negative correlation between them through the whole transect (Fig. 5h). The coherency between Ksat and the land-use system (Fig. 5i), shows that there are two patches of high variations: at the scale of 420-1,000 m, there are high and significant covariances at locations that are 10.5-14.0 km from the beginning of the transect, while at the scale of 1,600-2,500 m, there are high and significant covariances at locations that are 4.5-9.0 km from the beginning of the transect.

The result of the Wavelet coherency between Ksat and macroporosity (Fig. 5g) is in agreement with what we found from that one with the Spearman's rank correlation (Table 2). It is worth to emphasize that in the calculus of the

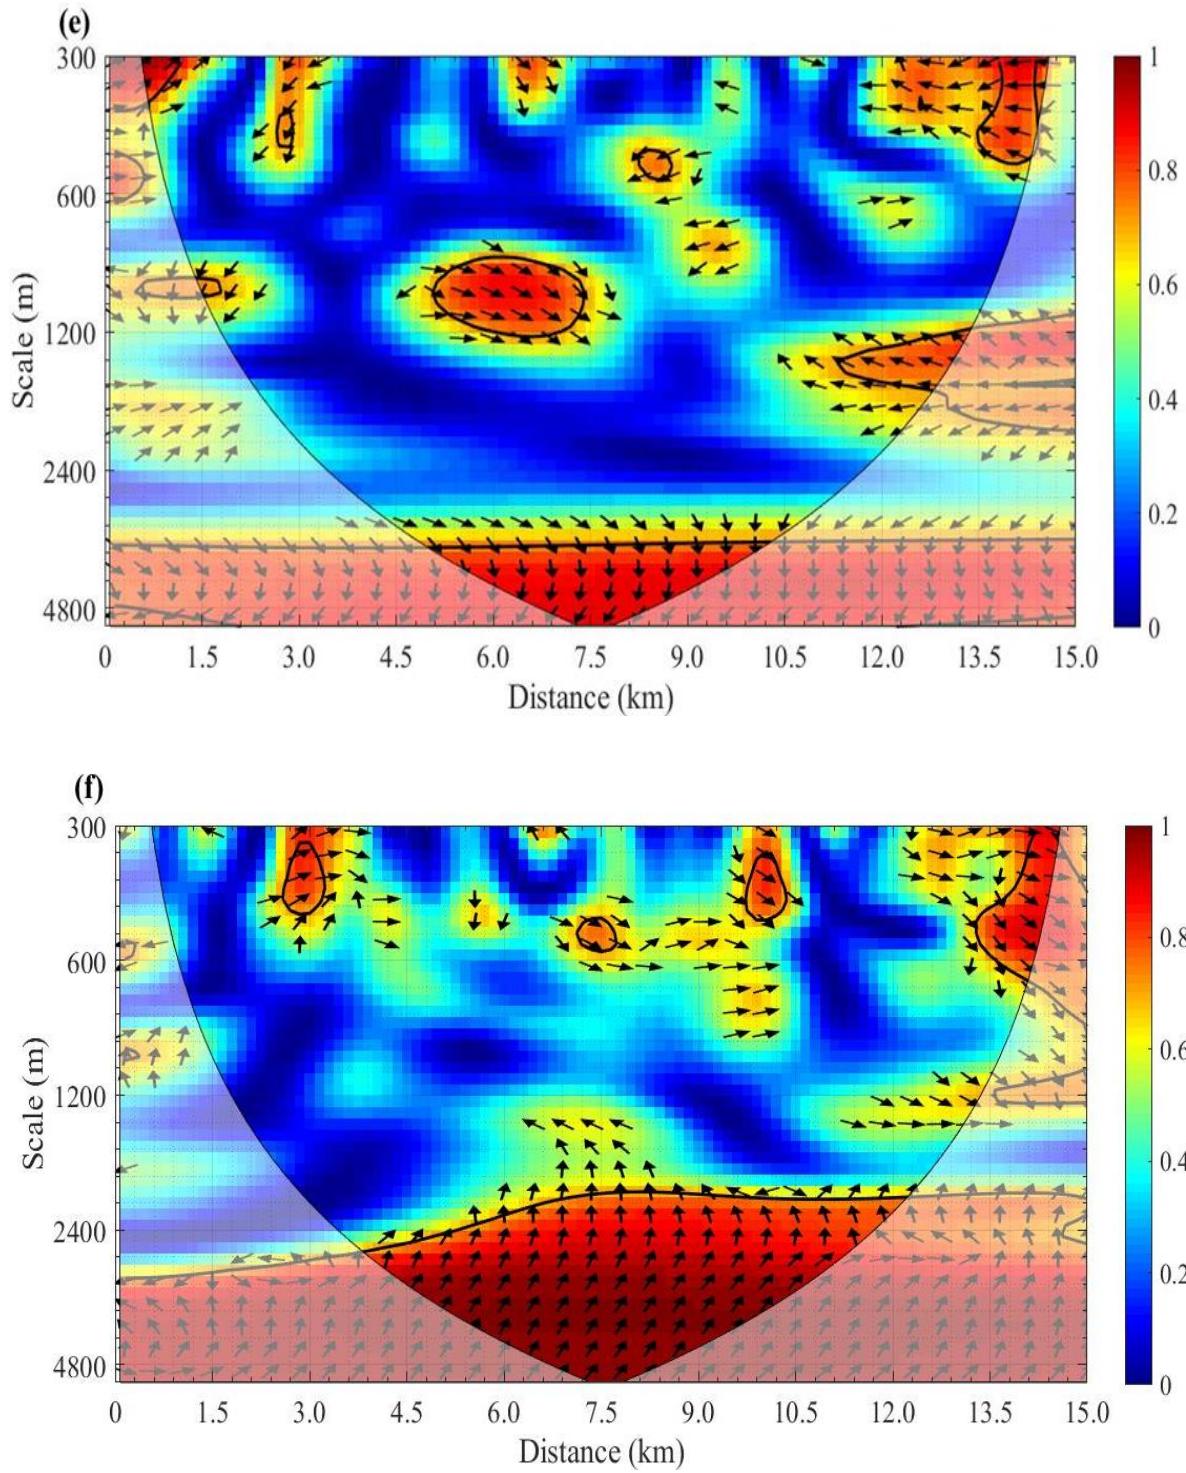
Spearman's rank correlation the coordinates of the data in the field are disregarded. The Spearman correlation can only identify an overall correlation which does not necessarily mean that this correlation is occurring at all locations within the spatial series along the 15 km-spatial transect. On the other hand, Fig. 5g shows that K<sub>sat</sub> and macroporosity are correlated at different scale and location domains along the transect. It is also important to highlight that significant correlation between two variables at the sampling scale which are usually identified by correlation analyses does not necessary mean significant correlation at all scales and locations. This is the case for K<sub>sat</sub> and elevation which were significantly correlated at scales >2400 m only (Fig. 5a), although the Spearman's correlation coefficient is significant at the sampling scale (Table 2). Therefore, the Wavelet coherence analyses confirmed the dominant role of macroporosity on K<sub>sat</sub> at all scales and locations.



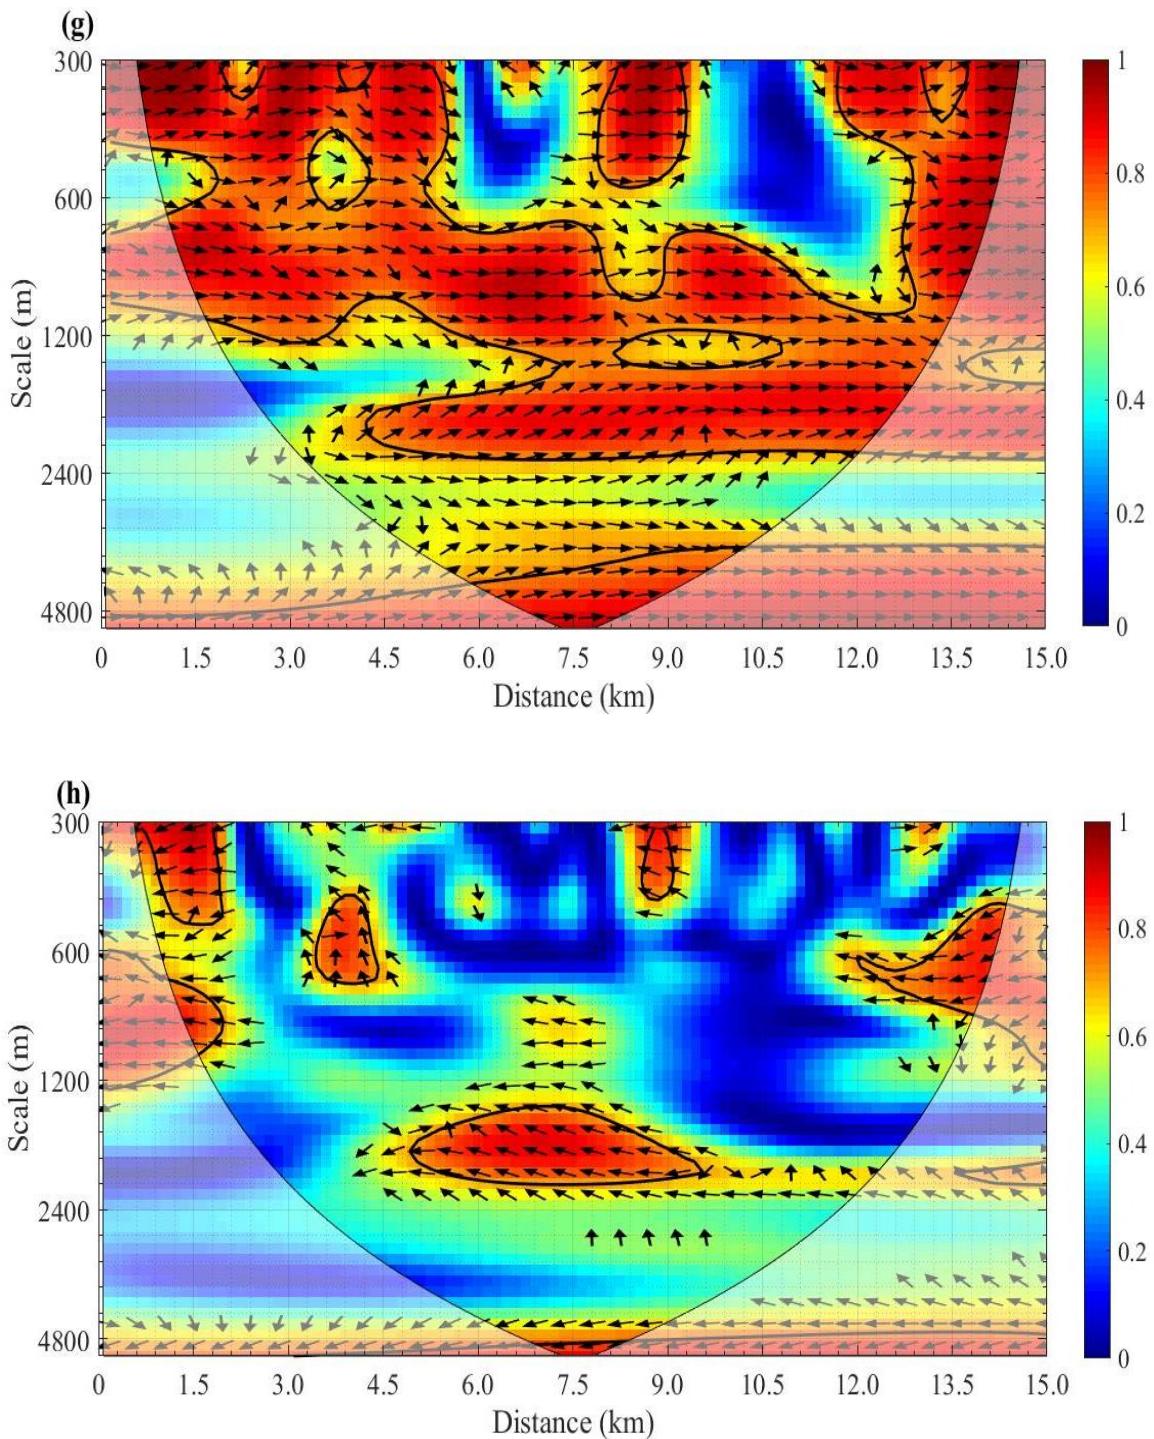
**Fig 5.** Wavelet coherency among  $K_{sat}$  and other soil, topographic and land-use variables: (a)  $K_{sat}$  and Elevation and (b)  $K_{sat}$  and Soil slope. Arrows pointing to the right mean that both spatial series are in phase (positive correlation), while arrows pointing to the left, mean a negative correlation between both series.



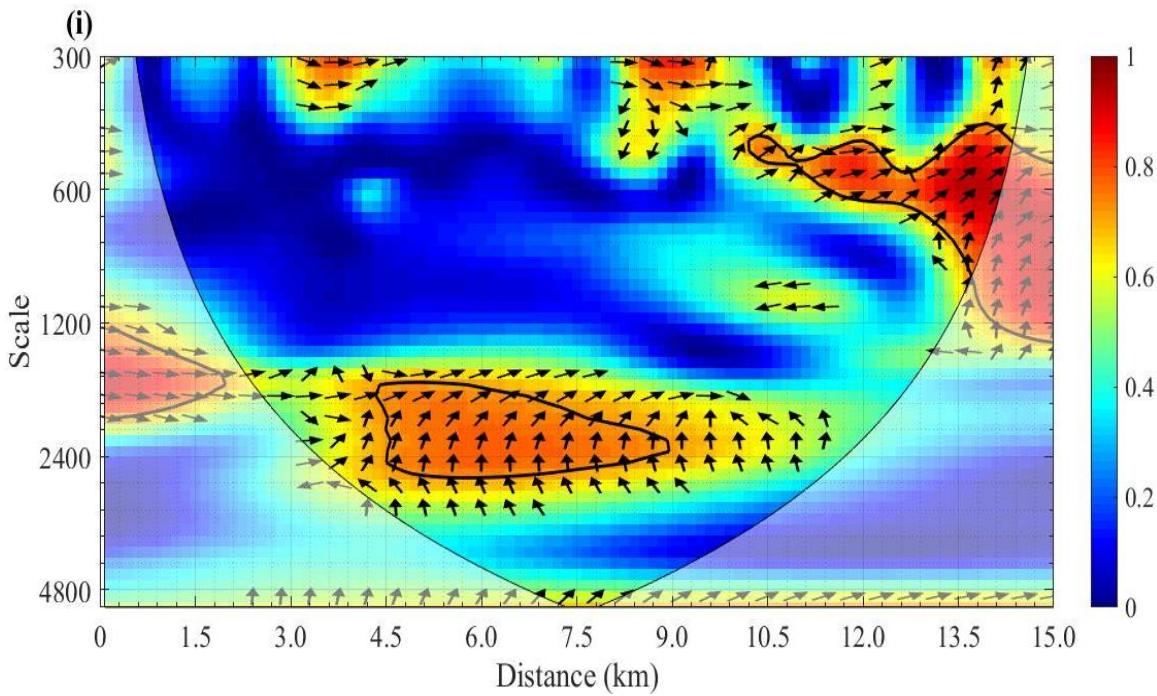
**Fig 5.** Wavelet coherency among Ksat and other soil, topographic and land-use variables: (c) Ksat and Aspect and (d) Ksat and soil organic content. Arrows pointing to the right mean that both spatial series are in phase (positive correlation), while arrows pointing to the left, mean a negative correlation between both series.



**Fig 5.** Wavelet coherency among Ksat and other soil, topographic and land-use variables: (e) Ksat and Clay and (f) Ksat and Sand. Arrows pointing to the right mean that both spatial series are in phase (positive correlation), while arrows pointing to the left, mean a negative correlation between both series.



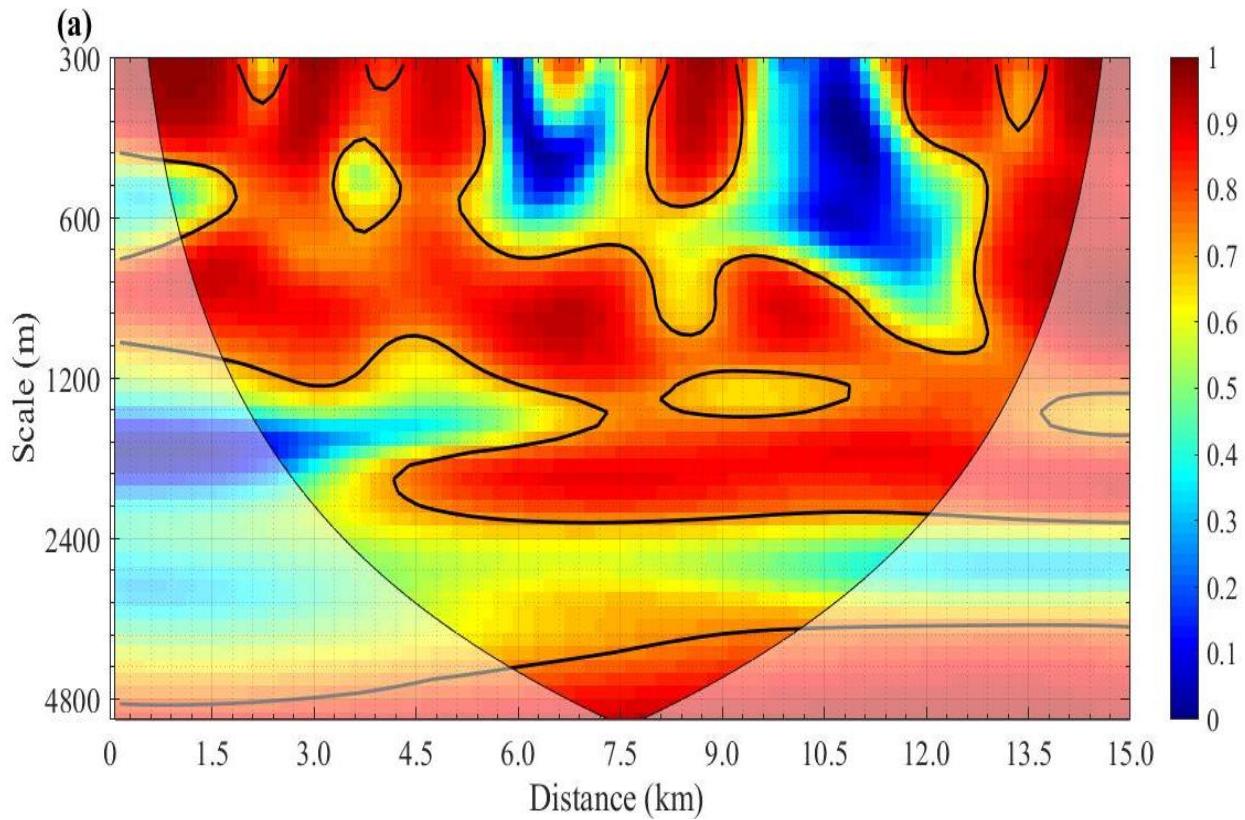
**Fig 5.** Wavelet coherency among Ksat and other soil, topographic and land-use variables: (g) Ksat and macroporosity and (h) Ksat and soil bulk density. Arrows pointing to the right mean that both spatial series are in phase (positive correlation), while arrows pointing to the left, mean a negative correlation between both series.



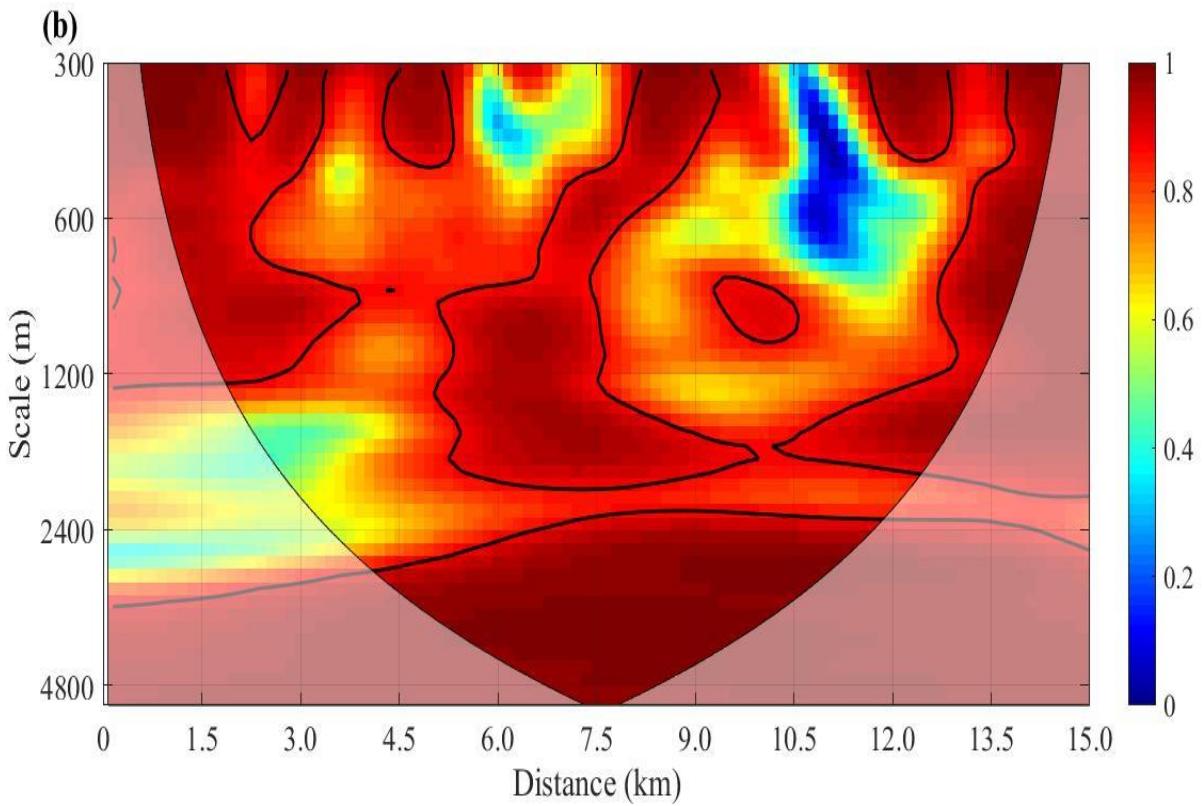
**Fig 5.** Wavelet coherency among Ksat and other soil, topographic and land-use variables: (i) Ksat and land-use system. Arrows pointing to the right mean that both spatial series are in phase (positive correlation), while arrows pointing to the left, mean a negative correlation between both series.

With the objective of identifying whether more variations of Ksat in scale-location domain can be explained by including more factors, multiple Wavelet coherences were calculated using all combinations of Ksat and environmental factors. Because mean Wavelet coherence usually increases with more independent variables being included, percent area of significance coherence was used to assess whether explanation of Ksat variation can be benefited from increasing independent variables (Hu and Si 2016). We found that a combination of macroporosity and land use system was the best for explaining the Ksat variations among all two-factor cases and the percent area of significance area increased to 53.9%. (Fig. 6a). An addition of sand factor, which was the best

among all three-factor cases, further increased the percent area of significance coherence to 56% (Fig. 6b). Mean Wavelet coherence continued to increase as expected by adding more factors, but the percent area of significance coherence decreased (data not shown).



**Fig. 6.** Multiple Wavelet coherency among Ksat, macroporosity, and land-use system (a).



**Fig. 6.** Multiple Wavelet coherency among Ksat, macroporosity, sand, and land-use system (b).

#### 4 Discussion

The mean Ksat value shows that FRW-PC's soils (Table 1) have low infiltration when completely wet, implying a potential to generate above average direct surface runoff according to the proposed classification by Pruski et al. (1997) for Brazilian soils. Ksat plays a key role for the comprehension and quantification of several hydrological processes (for instance, surface and subsurface runoff and base flow) at the watershed scale (Wang et al. 2013; Hu et al. 2015; Caldeira et al. 2019). At the watershed scale, there is a need to identify the spatial variability patterns of soil hydro-physical properties (Fig. 4), especially those ones related to the soil structure (Vogel 2019) which directly

affects Ksat. Therefore, the development of Pedotransfer functions (PTFs) for estimating the spatial variation of Ksat over watersheds, using soil properties more easily determined in the field or laboratory, are expected to strongly contribute for the better use of hydrological models and the understanding of their outputs.

Studies have also shown that different land-use systems have an added effect on soil hydraulic properties and thereby on their spatial distribution (Zimmermann et al. 2006; Taskinen et al. 2008; Bonell et al. 2010; Price et al. 2010; Salemi et al. 2013; Lizaga et al. 2019). Cultivated soils under native vegetation (e.g., native forest) generally present lower BD and higher Ksat and macroporosity when compared with soils altered by agriculture (e.g., cultivated pasture) (Fig. 3), potentially owing to a substantial presence of organic litter cover, root growth and decay and ground dwelling animals (Lee and Foster 1991; Viola et al. 2013). Price et al. (2010) argued that the differences observed in the Ksat, soil BD, total porosity, and volumetric moisture content at field capacity between forest and non-forest soils can be understood as having resulted from a mixture of land management and differences in macropore-forming biotic activities. Compared to native forests, Bonell et al. (2010) suggested that monoculture plantations can greatly affect soil ecology, since agricultural activities can reduce soil fauna and indirectly reduce macroporosity and Ksat over time. In a study of Wang et al. (2013) through the entire Loess Plateau in China, soil particle composition and bulk density (small-scale factors) and land-use type (large-scale factors) significantly contributed to the variation of topsoil Ksat values. Picciafuoco et al. (2019), in a small Austrian catchment, mentioned that

a wider variation of K<sub>sat</sub> may be caused by the characteristics of each land-use system, rather than by a direct dependency of K<sub>sat</sub> on soil textural composition.

At the measurement scale, the high variation of topographic features most likely would result in substantial variations in the microclimate, vegetation types, biotic and abiotic processes and soil development. As a result, the large ranges in the soil (soil organic carbon, clay and sand contents, macroporosity, and BD) and topographic (elevation, aspect, and slope) attributes could potentially be considered to be explanatory variables of the spatial behavior of K<sub>sat</sub> along the transect. Strong relationships have been previously reported among K<sub>sat</sub> and topographic features and soil attributes in other studies (Hu et al. 2012; Salemi et al. 2013; She et al. 2017; Zimmerman et al. 2013; Wang et al. 2013).

Soil BD had a significant and negative correlation with K<sub>sat</sub>. The soil BD mainly affects the soil macro-structure which in turn has an impact on the formation of macropores, directly affecting K<sub>sat</sub>. Aspect, soil organic carbon, clay, and sand variables were poorly correlated with K<sub>sat</sub> and the relationships were not significant ( $p > 0.05$ ). The effects of the mechanical soil structure are relevant to both its macro-structure and to the matrix of the soil. Increasing sand therefore would positively affect the macropore system, and conversely would negatively affect the micropore system, albeit to a lower degree. Organic carbon in soils have a similar effect to that of clay (Saxton and Rawls 2006). Textures with a high clay levels could therefore disguise the influence of increased organic carbon, which decreases the soil water retention capabilities at high water tensions.

It should be noted that all distances and scales with significant coherency are predominantly in phase, suggesting a positive correlation between K<sub>sat</sub> and macroporosity (Fig. 5g), which was already visually depicted from Figs. 2a and

2h. By comparing all the Wavelet coherency (Fig. 5), the soil macroporosity was the best single factor to explain the spatial variation of K<sub>sat</sub> in multiple spatial and scale domain due to the fact that it produced the greatest mean Wavelet coherence (0.68) and percent area of significance coherence (53.3%). Our results are in agreement with those of Zhang et al. (2019), who found that soil macroporosity was the crucial component that greatly improved the performance of their PTF as compared to those examined existing PTFs that did not account for macroporosity.

Including sand, macroporosity and land-use, we can slightly improve the explanation of K<sub>sat</sub> (Fig. 6b). This can be explained that the area with significant coherence between K<sub>sat</sub> at large scales at the latter part of the transect and that between sand and land-use at the moderate scales in the middle part of the transect can be a very good complement (no overlap) to that between K<sub>sat</sub> and macroporosity (Fig. 5g). However, this slight improvement may not be applicably valuable. The reasoning may be related to fact that the two complementary areas did not correspond to a significant (although large in some areas) variation of K<sub>sat</sub> as shown in Fig. 4a. This also implies that multiple Wavelet coherence may not necessarily be beneficial to explaining variation of a variable as found by Hu et al. (2017).

## **Conclusions**

In the Fragata River Watershed in Southern Brazil, saturated soil hydraulic conductivity and other soil (soil organic carbon, clay and sand contents, soil macroporosity, and soil bulk density) and topographic (elevation and soil slope) attributes and land-use systems were measured along a 15-km spatial transect.

The multiple Wavelet coherence (MWC) analysis identified different spatial relationship patterns along the transect, showing the importance of various combinations of Ksat and soil and topographic attributes and land-use systems as well. The bivariate Wavelet coherency and multiple Wavelet coherence analyses showed that the variations of soil macroporosity itself was enough to explain the variations in Ksat in multiple scale and location domains in the Fragata River Watershed. This implies that soil macroporosity could be used as a proxy for assessing runoff potential at different land-use systems with different scales in the Fragata River Watershed in Southern Brazil.

### **Acknowledgments**

The authors wish to thank the Brazilian National Council for Scientific and Technological Development (CNPq) for the financial support and scholarships provided, and the Coordination for the Improvement of Higher Education Personnel - Brazil (CAPES), Finance Code 001, for scholarships.

### **References**

Adam M, Oh SL, Sudarshan VK, Koh JE, Hagiwara Y, Tan JH, Tan RS, Acharya UR (2018) Automated characterization of cardiovascular diseases using relative Wavelet nonlinear features extracted from ECG signals. Comp Methods Progr Biomed 161:133-143

Bagarello V, Prima SD, Iovino M (2017) Estimating saturated soil hydraulic conductivity by the near steady-state phase of a Beerkan infiltration test. *Geoderma* 303: 70–77

Beskow S, Timm LC, Tavares VEQ, Caldeira TL, Aquino LA (2016) Potential of the LASH model for water resources management in data-scarce basins: a case study of the Fragata River basin, southern Brazil. *Hydrol Sci J* 61:2567–2578

Biswas A (2018) Scale–location specific soil spatial variability: A comparison of continuous Wavelet transform and Hilbert–Huang transform. *Catena* 160:24–31

Biswas A, Si BC (2011) Identifying scale specific controls of soil water storage in a hummocky landscape using Wavelet coherency. *Geoderma* 165: 50–59

Blake, GR, Hartge KH (1986) Bulk density. In: Klute A (ed) *Methods of Soil Analysis*. Part 1, 2nd edn. Agronomy Monograph, ASA-SSSA, Madison, WI, pp. 363–382

Bonell M, Purandara BK, Venkatesh B, Krishnaswamy J, Acharya HAK, Singh UV, Jayakumar R, Chappell N (2010) The impact of forest use and reforestation on soil hydraulic conductivity in the Western Ghats of India: Implications for surface and sub-surface hydrology. *J Hydrol* 391(1-2):47–62

Caldeira TL, Mello CR, Beskow S, Timm LC, Viola MR (2019) LASH hydrological model: An analysis focused on spatial discretization. *Catena* 173:183–193.

MARÍN-CASTRO, B.e.; GEISSERT, D.; NEGRETE-YANKELEVICH, S.; CHÁVEZ, A. Gómez-tagle (2016) Spatial distribution of hydraulic conductivity in soils of secondary tropical montane cloud forests and shade coffee agroecosystems. *Geoderma* 283:57–67

Cherobim VF, Favaretto N, Melo VM, Barth G, Huang C (2018) Soil surface sealing by liquid dairy manure affects saturated hydraulic conductivity of Brazilian Oxisols. *Agric Water Manag* 203:193-196

Farge M (1992) Wavelet transforms and their applications to turbulence. *Annu Rev Fluid Mech* 24:395-458

Gao L, Shao M, Wang Y (2012) Spatial scaling of saturated hydraulic conductivity of soils

in a small watershed on the Loess Plateau, China. *J Soils Sediments* 12:863–875

Gee GW, Bauder JW (1986) Particle-size analysis. In: Klute A (ed) *Methods of Soil Analysis*. Part 1, 2nd edn. Agronomy Monograph, ASA-SSSA, Madison, WI, pp. 383–411

Grinsted A, Moore JC, Jevrejeva S (2004) Application of the cross Wavelet transform and Wavelet coherence to geophysical time series. *Nonlin Processes Geophys* 11:561-566

Hasenack H, Weber E (Org) (2010) Base cartográfica vetorial contínua do Rio Grande do Sul - escala 1:50000. UFRGS - Centro de Ecologia, Porto Alegre

Hu W, Shao MA, Si BC (2012) Seasonal changes in surface bulk density and saturated hydraulic conductivity of natural landscapes. Eur J Soil Sci 63(6): 820-830.

Hu W, Shao MG, Wang QJ, Fan J, Horton R (2009) Temporal changes of soil hydraulic properties under different land uses. Geoderma 149(3-4): 355-366.

Hu W, Si BC, Biswas A, Chau HW (2017) Temporally stable patterns but seasonal dependent controls of soil water content: Evidence from Wavelet analyses. Hydrol Proc 31:3697-3707

Hu W, Si BC (2016) Multiple Wavelet coherence for untangling scale-specific and localized multivariate relationships in geosciences. Hydrol Earth Syst Sci 20:3183-3191

Hu W, She D, Shao M, Chun K, Si B, (2015) Effects of initial soil water content and saturated hydraulic conductivity variability on small watershed runoff simulation using LISSEM. Journal Hydrological Sciences J 60:1137–1154

Hwang HT, Jeen SW, Suleiman A, Lee KK (2017) Comparison of saturated hydraulic conductivity estimated by three different methods. Water 9: 942-959

Klute A (1986) Water retention: laboratory methods. In: Klute A (ed) Methods of Soil Analysis. Part 1, 2nd edn. Agronomy Monograph, ASA-SSSA, Madison, WI, pp. 635–662

Klute A, Dirksen C (1986) Hydraulic conductivity and diffusivity: laboratory methods. In: Klute A (ed) Methods of Soil Analysis. Part 1, 2nd edn. Agronomy Monograph, ASA-SSSA, Madison, WI, pp. 687–734

Kuinchner A, Buriol GA (2001) Clima do estado do Rio Grande do Sul segundo a classificação climática de Köppen e Thornthwaite. Disciplinarum Scientia - Série: Ciências Exatas 2:171–182

Lee K, Foster RC (1991) Soil fauna and soil structure. Soil Res 29:745-755

Lizaga I, Quijano L, Gaspar L, Ramos MC, Navas A (2019) Linking land use changes to variation in soil properties in a Mediterranean mountain agroecosystem. Catena 172: 516-527

Massey FJ (1951) The Kolmogorov-Smirnov test for goodness of fit. J Am Stat Assoc 46:68-78

Nelson DW, Sommers LE (1982) Total carbon, organic carbon and organic matter. In: Page AL, Miller RH, Keeney DR (eds) Methods of Soil Analysis. Part 2, 2nd edn. Agronomy Monograph, ASA-SSSA, Madison, WI, pp. 534–580

Picciafuoco T, Morbidelli R, Flammini A, Saltalippi C, Corradini C, Strauss P, Bloschl G (2019) On the estimation of spatially representative plot scale saturated hydraulic conductivity in an agricultural setting. *J Hydrol* 507: 106-117

Perrota, MM (2005) Processamento digital básico de imagens de sensores remotos ópticos para uso em mapeamento geológico – programa ENVI. CPRM, Belo Horizonte

Price K, Jackson CR, Parker AJ (2010) Variation of surficial soil hydraulic properties across land uses in the southern Blue Ridge Mountains, North Carolina, USA. *J Hydrol* 383:256-268

Pruski FF, Ferreira PA, Ramos MM (1997) A model to design level terraces. *J Irrig Drain Eng* 123: 8-12

R Development Core Team (2012) R: A Language and Environment for Statistical Computing Vienna: R foundation for Statistical Computing <http://wwwR-project.org/>

GRICHE, Rezki Mohamed (2017) Detection of muscle fatigue: relative study with different methods. *Commun Fac Sci Univ Ank Series A2-A3* 59:21-28

Salemi LF, Groppo JD, Trevisan R, Moraes JM, Ferraz SF, Villani JP, Duarte-Neto PJ, Martinelli LA (2013) Land-use change in the Atlantic rainforest region: Consequences for the hydrology of small catchments. *J Hydrol* 499:100-109

Saxton KE, Rawls WJ (2006) Soil water characteristic estimates by texture and organic matter for hydrologic solutions. *Soil Sci Soc Am J* 70: 1569–1578

She D, Qian C, Timm LC, Beskow S, Wei H, Caldeira TL, Oliveira LM (2017) Multi-scale correlations between soil hydraulic properties and associated factors along a Brazilian watershed transect. *Geoderma* 286:15-24

Si BC (2008) Spatial scaling analyses of soil physical properties: a review of spectral and Wavelet methods. *Vadose Zone J* 7:547-562

Si BC, Zeleke TB (2005) Wavelet coherency analysis to relate saturated hydraulic properties to soil physical properties. *Water Resour Res* 41:1-9

Taskinen A, Sirviö H, Bruen M (2008) Statistical analysis of the effects on overland flow of spatial variability in soil hydraulic conductivity. *Hydrol Sci J* 53:387–400

Torrence GC, Compo GP (1998) A practical guide to Wavelet analysis. *Bull Am Meteor Soc* 79: 61-78

Vasques GM, Grunwald S, Myers DB (2012) Associations between soil carbon and ecological landscape variables at escalating spatial scales in Florida, USA. *Landscape Ecol* 27: 355-367

Viola MR, Mello CR, Beskow S, Norton LD (2013) Applicability of the LASH model for hydrological simulation of the Grande river basin, Brazil. *J Hydrol Eng* 18: 1639-1652

Vogel H-J (2019) Scale issues in Soil Hydrology. *Vadose Zone J* 18: 1-10

Wang Y, Shao M, Liu Z, Horton R (2013) Regional-scale variation and distribution patterns of soil saturated hydraulic conductivities in surface and subsurface layers in the loessial soils of China. *J Hydrol* 487:13-23

Wilding LP, Drees LR (1983) Spatial variability and pedology. In: Wilding LP, Smeck NE, Hall GF (eds) *Pedogenesis and Soil Taxonomy: 1. Concepts and Soil Analysis*. 2nd edn. Am Soc Agronomy, Madison, pp. 635–662

Xiong X, Grunwald S, Corstanje R, Yu C, Bliznyuk N (2016) Scale-dependent variability of soil organic carbon coupled to land use and land cover. *Soil Till Res* 160:101-109

Yang Y, Jia X, Wendoroth O, Liu B, Shi Y, Huang T, Bai X (2019) Noise-assisted multivariate empirical mode decomposition of saturated hydraulic conductivity along a south-north transect across the Loess Plateau of China. *Soil Sci Soc Am J* 83:311-323

Yao RJ, Yang JS, Wu DH, Li FR, Gao P, Wang XP (2015) Evaluation of pedotransfer functions for estimating saturated hydraulic conductivity in coastal salt affected mud farmland. *J Soils Sediments* 15: 902–916

Zhang L, Chen J, Qiu B (2017) Region-of-interest coding based on saliency detection and directional Wavelet for remote sensing images. *IEEE Geosci Remote S* 14: 23-27

Zhang X, Zhu J, Wendoroth, O, Matocha C, Edwards D (2019) Effect of Macroporosity on Pedotransfer Function Estimates at the Field Scale. *Vadose Zone J* 18:1-12

Zhao C, Ming'an S, Jia X, Nasir M, Zhang C (2016) Using pedotransfer functions to estimate soil hydraulic conductivity in the Loess Plateau of China. *Catena* 143: 1-6

Zimmermann B, Elsenbeer H, De Moraes JM (2006) The influence of land-use changes on soil hydraulic properties: implications for runoff generation. *Forest Ecol Manag* 222:29-38

## **7. Conclusões**

Os resultados do presente trabalho permitem aceitar as hipóteses levantadas inicialmente. Deste modo, pode-se concluir que:

- a abordagem em espaço de estados se mostrou uma ferramenta eficaz para melhor descrever as relações espaciais entre a condutividade hidráulica do solo saturado e as covariáveis selecionadas na escala da bacia hidrográfica, quando comparadas aos modelos de regressão linear múltipla equivalentes.

- os modelos de espaço de estados evidenciaram a importância da macroporosidade na variabilidade da condutividade hidráulica do solo saturado, entretanto, ela não é um atributo facilmente disponível nos bancos de dados do solo. Portanto, este estudo sugere que o tipo de uso do solo possa ser potencialmente usado como uma das variáveis representativas da estrutura do solo no intuito de explicar as variações espaciais de Ksat na escala da bacia hidrográfica, uma vez que atualmente é uma variável de fácil mensuração a partir de imagens de satélite.

- as transformadas de Wavelets (*Wavelet spectrum, Wavelet coherence e multiple Wavelet coherence*) mostraram-se ferramentas promissoras no intuito de caracterizar e quantificar as correlações multiespaciais entre a condutividade hidráulica do solo saturado e os atributos físico-hídricos do solo e topográficos e o tipo de uso do solo ao longo da transeção espacial de 15 km construída na Bacia do Arroio Fragata.

- a *multiple Wavelet coherence* identificou diferentes padrões de relações espaciais entre a condutividade hidráulica do solo saturado e os atributos do solo e topográficos e tipos de uso do solo ao longo da transeção espacial de 15 km na bacia do Arroio Fragata. Também destacou a importância das variações da macroporosidade do solo para explicar as variações espaciais de Ksat no domínio de múltiplas escalas e frequências.

## **Referências Bibliográficas**

ADAM, Muhammad; OH, Shu Lih; SUDARSHAN, Vidya K; KOH, Joel Ew; HAGIWARA, Yuki; TAN, Jen Hong; TAN, Ru San; ACHARYA, U Rajendra. Automated characterization of cardiovascular diseases using relative Wavelet nonlinear features extracted from ECG signals. **Computer Methods And Programs In Biomedicine**, [s.l.], v. 161, p. 133-143, jul. 2018. Elsevier BV.  
<http://dx.doi.org/10.1016/j.cmpb.2018.04.018>. Disponível em:  
<https://www.sciencedirect.com/science/article/abs/pii/S016926071631118X?via%3Dhub>. Acesso em: 24 abr. 2020.

ADDISON, Paul S. **The Illustrated Wavelet Transform Handbook: Introductory Theory and Applications in Science, Engineering, Medicine and Finance**. 2. ed. Boca Raton: Taylor & Francis Group, 2016. 464 p. ISBN 9781482251326.

ANDRADE, Márcio A.; MELLO, Carlos R. de; BESKOW, Samuel. Simulação hidrológica em uma bacia hidrográfica representativa dos Latossolos na região Alto Rio Grande, MG. **Revista Brasileira de Engenharia Agrícola e Ambiental**, [s.l.], v. 17, n. 1, p. 69-76, jan. 2013. FapUNIFESP (SciELO).  
<http://dx.doi.org/10.1590/s1415-43662013000100010>. Disponível em:  
[http://www.scielo.br/scielo.php?pid=S1415-43662013000100010&script=sci\\_abstract&tlang=pt](http://www.scielo.br/scielo.php?pid=S1415-43662013000100010&script=sci_abstract&tlang=pt). Acesso em: 24 abr. 2020.

AQUINO, Leandro Sanzi; TIMM, Luís Carlos; REICHARDT, Klaus; BARBOSA, Emanuel Pimentel; PARFITT, José Maria Barbat; NEBEL, Alvaro Luiz Carvalho; PENNING, Letiane Helwig. State-space approach to evaluate effects of land levelling on the spatial relationships of soil properties of a lowland area. **Soil And Tillage Research**, [s.l.], v. 145, p. 135-147, jan. 2015. Elsevier BV.  
<http://dx.doi.org/10.1016/j.still.2014.09.007>. Disponível em:  
<https://www.sciencedirect.com/science/article/abs/pii/S016719871400186X>. Acesso em: 24 abr. 2020.

ARNOLD, J. G.; SRINIVASAN, R.; MUTTIAH, R. S.; WILLIAMS, J. R.. Large area hydrologic modeling and assessment part I: model development: model

development. **Journal Of The American Water Resources Association**, [s.l.], v. 34, n. 1, p. 73-89, fev. 1998. Wiley. <http://dx.doi.org/10.1111/j.1752-1688.1998.tb05961.x>. Disponível em: <https://onlinelibrary.wiley.com/doi/10.1111/j.1752-1688.1998.tb05961.x>. Acesso em: 24 abr. 2020.

AWE, G. O.; REICHERT, J. M.; TIMM, L. C.; WENDROTH, O. O.. Temporal processes of soil water status in a sugarcane field under residue management. **Plant And Soil**, [s.l.], v. 387, n. 1-2, p. 395-411, 25 out. 2014. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s11104-014-2304-5>. Disponível em: <https://link.springer.com/article/10.1007/s11104-014-2304-5>. Acesso em: 24 abr. 2020.

BAGARELLO, V.; PRIMA, S. di; IOVINO, M. Estimating saturated soil hydraulic conductivity by the near steady-state phase of a Beerkan infiltration test. **Geoderma**, [s.l.], v. 303, p. 70-77, out. 2017. Elsevier BV. <http://dx.doi.org/10.1016/j.geoderma.2017.04.030>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S001670611730201X>. Acesso em: 24 abr. 2020.

BAIAMONTE, Giorgio; BAGARELLO, Vincenzo; D'ASARO, Francesco; PALMERI, Vincenzo. Factors Influencing Point Measurement of Near-surface Saturated Soil Hydraulic Conductivity in a Small Sicilian Basin. **Land Degradation & Development**, [s.l.], v. 28, n. 3, p. 970-982, 9 mar. 2017. Wiley. <http://dx.doi.org/10.1002/lrd.2674>. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1002/lrd.2674>. Acesso em: 24 abr. 2020.

BALL, B. C.; WATSON, C. A.; BADDELEY, J. A. Soil physical fertility, soil structure and rooting conditions after ploughing organically managed grass/clover swards. **Soil Use And Management**, [s.l.], v. 23, n. 1, p. 20-27, mar. 2007. Wiley. <http://dx.doi.org/10.1111/j.1475-2743.2006.00059.x>. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1111/j.1475-2743.2006.00059.x>. Acesso em: 24 abr. 2020.

BESKOW, Samuel; TIMM, Luis Carlos; TAVARES, Vitor Emanuel Quevedo; CALDEIRA, Tamara Leitzke; AQUINO, Leandro Sanzi. Potential of the LASH model for water resources management in data-scarce basins: a case study of the fragata river basin, southern brazil: a case study of the Fragata River basin, southern Brazil. **Hydrological Sciences Journal**, [s.l.], v. 61, n. 14, p. 2567-2578, 15 jul. 2016. Informa UK Limited.

<http://dx.doi.org/10.1080/02626667.2015.1133912>. Disponível em:  
<https://www.tandfonline.com/doi/full/10.1080/02626667.2015.1133912>. Acesso em: 24 abr. 2020.

BISWAS, Asim. Scale–location specific soil spatial variability: a comparison of continuous Wavelet transform and hilber-huang transform: A comparison of continuous Wavelet transform and Hilbert–Huang transform. **Catena**, [s.l.], v. 160, p. 24-31, jan. 2018. Elsevier BV.

<http://dx.doi.org/10.1016/j.catena.2017.08.019>. Disponível em:  
<https://www.sciencedirect.com/science/article/abs/pii/S0341816217302746>. Acesso em: 24 abr. 2020.

BISWAS, Asim; CRESSWELL, Hamish P.; CHAU, Henry W.; ROSSEL, Raphael A. Viscarra; SI, Bing C. Separating scale-specific soil spatial variability: a comparison of multi-resolution analysis and empirical mode decomposition: A comparison of multi-resolution analysis and empirical mode decomposition. **Geoderma**, [s.l.], v. 209-210, p. 57-64, nov. 2013. Elsevier BV.  
<http://dx.doi.org/10.1016/j.geoderma.2013.06.003>. Disponível em:  
<https://www.sciencedirect.com/science/article/abs/pii/S0016706113002024>. Acesso em: 24 abr. 2020.

BISWAS, Asim; SI, Bing Cheng. Identifying scale specific controls of soil water storage in a hummocky landscape using Wavelet coherency. **Geoderma**, [s.l.], v. 165, n. 1, p. 50-59, out. 2011. Elsevier BV.  
<http://dx.doi.org/10.1016/j.geoderma.2011.07.002>. Disponível em:  
<https://www.sciencedirect.com/science/article/abs/pii/S0016706111001911>. Acesso em: 24 abr. 2020.

BISWAS, Asim; SI, Bing Cheng. Scales and locations of time stability of soil water storage in a hummocky landscape. **Journal Of Hydrology**, [s.l.], v. 408, n. 1-2, p. 100-112, set. 2011. Elsevier BV.  
<http://dx.doi.org/10.1016/j.jhydrol.2011.07.027>. Disponível em:  
<https://www.sciencedirect.com/science/article/pii/S0022169411004835>. Acesso em: 24 abr. 2020.

Blake, G. R., Hartge K. H. Bulk density. In: Klute A (ed) Methods of Soil Analysis. Part 1. 2. ed. Agronomy Monograph. ASA-SSSA, Madison, 1986. 363–382p. ISBN-13: 978-0891188117.

BOLZAN, Maurício José Alves. Análise da transformada em ondeletas aplicada em sinal geofísico. **Revista Brasileira de Ensino de Física**, [s.l.], v. 26, n. 1, p. 37-41, 2004. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s1806-11172004000100006>. Disponível em:  
[http://www.scielo.br/scielo.php?pid=S1806-11172004000100006&script=sci\\_abstract&tlang=pt](http://www.scielo.br/scielo.php?pid=S1806-11172004000100006&script=sci_abstract&tlang=pt). Acesso em: 24 abr. 2020.

BOLZAN, Maurício José Alves. Transformada em ondeleta: uma necessidade: uma necessidade. **Revista Brasileira de Ensino de Física**, [s.l.], v. 28, n. 4, p. 563-567, 2006. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s1806-11172006000400019>. Disponível em:  
[http://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S1806-11172006000400019](http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1806-11172006000400019). Acesso em: 24 abr. 2020.

BONELL, M.; PURANDARA, B.k.; VENKATESH, B.; KRISHNASWAMY, Jagdish; ACHARYA, H.a.k.; SINGH, U.v.; JAYAKUMAR, R.; CHAPPELL, N. The impact of forest use and reforestation on soil hydraulic conductivity in the Western Ghats of India: implications for surface and sub-surface hydrology: Implications for surface and sub-surface hydrology. **Journal Of Hydrology**, [s.l.], v. 391, n. 1-2, p. 47-62, set. 2010. Elsevier BV.  
<http://dx.doi.org/10.1016/j.jhydrol.2010.07.004>. Disponível em:

<https://www.sciencedirect.com/science/article/pii/S0022169410004178>. Acesso em: 24 abr. 2020.

BRASIL. Ministério da agricultura. Departamento nacional de pesquisa agropecuária. Divisão de pesquisa pedológica. Levantamento de reconhecimento dos solos do Estado do Rio Grande do Sul. Recife, 1973. 431 p. (Boletim Técnico, 30).

CALDEIRA, Tamara Leitzke; MELLO, Carlos Rogério; BESKOW, Samuel; TIMM, Luís Carlos; VIOLA, Marcelo Ribeiro. LASH hydrological model: an analysis focused on spatial discretization: An analysis focused on spatial discretization. **Catena**, [s.l.], v. 173, p. 183-193, fev. 2019. Elsevier BV. <http://dx.doi.org/10.1016/j.catena.2018.10.009>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0341816218304363>. Acesso em: 24 abr. 2020.

CHEROBIM, Verediana Fernanda; FAVARETTO, Nerilde; MELO, Vander de Freitas; BARTH, Gabriel; HUANG, Chi-hua. Soil surface sealing by liquid dairy manure affects saturated hydraulic conductivity of Brazilian Oxisols.

**Agricultural Water Management**, [s.l.], v. 203, p. 193-196, abr. 2018. Elsevier BV. <http://dx.doi.org/10.1016/j.agwat.2018.03.016>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0378377418301707>. Acesso em: 24 abr. 2020.

DAVIS, J. C. **Statistics and data analysis in geology**. 2<sup>a</sup> ed. New York: John Wiley & Sons, 1986. 646 p. ISBN 0471080799, 9780471080794.

DONGLI, She; QIAN, Chen; TIMM, Luis Carlos; BESKOW, Samuel; WEI, Hu; CALDEIRA, Tamara Leitzke; OLIVEIRA, Luciana Montebello de. Multi-scale correlations between soil hydraulic properties and associated factors along a Brazilian watershed transect. **Geoderma**, [s.l.], v. 286, p. 15-24, jan. 2017. Elsevier BV. <http://dx.doi.org/10.1016/j.geoderma.2016.10.017>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0016706116306279>. Acesso em: 25 abr. 2020.

DUAN, Liangxia; HUANG, Mingbin; ZHANG, Luodan. Use of a state-space approach to predict soil water storage at the hillslope scale on the Loess Plateau, China. **Catena**, [s.l.], v. 137, p. 563-571, fev. 2016. Elsevier BV. <http://dx.doi.org/10.1016/j.catena.2015.11.003>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0341816215301521>. Acesso em: 24 abr. 2020.

EMBRAPA - Empresa brasileira de pesquisa agropecuária. **Manual de métodos de análise de solos**. 2.ed. Rio de janeiro: Embrapa Solos, 1997. 212 p. ISBN 978-85-7035-771-7.

FARGE, M. Wavelet Transforms and their Applications to Turbulence. **Annual Review Of Fluid Mechanics**, [s.l.], v. 24, n. 1, p. 395-458, jan. 1992. Annual Reviews. <http://dx.doi.org/10.1146/annurev.fl.24.010192.002143>. Disponível em: <https://www.annualreviews.org/doi/abs/10.1146/annurev.fl.24.010192.002143>. Acesso em: 24 abr. 2020.

FLANDRIN, Patrick; GONÇALVÈS, Paulo. Empirical mode decompositions as data-driven Wavelet-like expansions. **International Journal Of Wavelets, Multiresolution And Information Processing**, [s.l.], v. 02, n. 04, p. 477-496, dez. 2004. World Scientific Pub Co Pte Lt. <http://dx.doi.org/10.1142/s0219691304000561>. Disponível em: <https://www.worldscientific.com/doi/10.1142/S0219691304000561>. Acesso em: 24 abr. 2020.

GAO, Lei; SHAO, Mingan; WANG, Youqi. Spatial scaling of saturated hydraulic conductivity of soils in a small watershed on the Loess Plateau, China. **Journal Of Soils And Sediments**, [s.l.], v. 12, n. 6, p. 863-875, 12 abr. 2012. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s11368-012-0511-3>. Disponível em: <https://link.springer.com/article/10.1007/s11368-012-0511-3>. Acesso em: 24 abr. 2020.

GEE GW, BAUDER JW. Particle-size analysis. In: Klute A (ed) Methods of Soil Analysis. Part 1. **Physical and mineralogical methods.** 2 ed. Agronomy Monograph, ASA-SSSA, Madison, 1986. 383–411 p. ISBN 9780891182030.

GENOVEZ, Abel; FRANCISCO NETO, SARTORI, Aderson. Classificação Hidrológica de Solos Brasileiros para a Estimativa da Chuva Excedente com o Método do Serviço de Conservação do Solo dos Estados Unidos Parte 1: classificação: Classificação. Revista Brasileira de Recursos Hídricos, [s.l.], v. 10, n. 4, p. 5-18, 2005. FapUNIFESP (SciELO).  
<http://dx.doi.org/10.21168/rbrh.v10n4.p5-18>. Disponível em:  
<https://www.abrhidro.org.br/SGCv3/publicacao.php?PUB=1&ID=26&SUMARIO=440>. Acesso em: 25 abr. 2020.

GOMES, João Bosco Vasconcellos; FERNANDES, Marcelo Ferreira; BARRETO, Antonio Carlos; ARAÚJO FILHO, José Coelho de; CURI, Nilton. Soil attributes under agroecosystems and forest vegetation in the coastal tablelands of northeastern Brazil. **Ciência e Agrotecnologia**, [s.l.], v. 36, n. 6, p. 649-664, dez. 2012. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s1413-70542012000600007>. Disponível em:  
[http://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S1413-70542012000600007](http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1413-70542012000600007). Acesso em: 25 abr. 2020.

GRAPS, A. An introduction to Wavelets. **Ieee Computational Science And Engineering**, [s.l.], v. 2, n. 2, p. 50-61, 1995. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/99.388960>. Disponível em: <https://ieeexplore.ieee.org/document/388960>. Acesso em: 24 abr. 2020.

GRICHE, Rezki Mohamed. Detection of muscle fatigue: relative study with different methods: relative study with different methods. **Communications Faculty Of Science University Of Ankara**, [s.l.], v. 59, n. 2, p. 21-28, 2017. Ankara Avrupa Calismalari Dergisi. [http://dx.doi.org/10.1501/commua1-2\\_0000000101](http://dx.doi.org/10.1501/commua1-2_0000000101). Disponível em:  
<https://www.semanticscholar.org/paper/DETECTION-OF-MUSCLE-FATIGUE%3A-RELATIVE-STUDY-WITH-Rezki->

Belaídi/45031e495a84daf45c51903852c5f546b1dfac45. Acesso em: 25 abr. 2020.

GRINSTED, A.; MOORE, J. C.; JEVREJAVA, S.. Application of the cross Wavelet transform and Wavelet coherence to geophysical time series. **Nonlinear Processes In Geophysics**, [s.l.], v. 11, n. 5/6, p. 561-566, 18 nov. 2004. Copernicus GmbH. <http://dx.doi.org/10.5194/npg-11-561-2004>. Disponível em: <https://www.nonlin-processes-geophys.net/11/561/2004/>. Acesso em: 25 abr. 2020.

GUO, Yadong; ZHAO, Ruiying; ZENG, Yongnian; SHI, Zhou; ZHOU, Qing. Identifying scale-specific controls of soil organic matter distribution in mountain areas using anisotropy analysis and discrete Wavelet transform. **Catena**, [s.l.], v. 160, p. 1-9, jan. 2018. Elsevier BV. <http://dx.doi.org/10.1016/j.catena.2017.08.016>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0341816217302722>. Acesso em: 25 abr. 2020.

Hair, J., Black, W.C., Babin, B.J., Anderson, R.E.. **Multivariate Data Analysis**. 7th ed. Prentice Hall, New York. 2009. 785p. ISBN-13: 978-0138132637.

HASENACK, H.; WEBER, E. **Base cartográfica vetorial continua do Rio Grande do Sul – escala 1:50.000**, Porto Alegre, UFRGS-IB-Centro de Ecologia. 1 DVD-ROM (Série Geoprocessamento, 3), 2010.

HASSLER, S. K.; LARK, R. M.; ZIMMERMANN, B.; ELSENBEEER, H.. Which sampling design to monitor saturated hydraulic conductivity? **European Journal Of Soil Science**, [s.l.], v. 65, n. 6, p. 792-802, 17 set. 2014. Wiley. <http://dx.doi.org/10.1111/ejss.12174>. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1111/ejss.12174>. Acesso em: 25 abr. 2020.

HU, W.; SHAO, M. A.; SI, B. C.. Seasonal changes in surface bulk density and saturated hydraulic conductivity of natural landscapes. **European Journal Of**

**Soil Science**, [s.l.], v. 63, n. 6, p. 820-830, 21 ago. 2012. Wiley.  
<http://dx.doi.org/10.1111/j.1365-2389.2012.01479.x>. Disponível em:  
<https://onlinelibrary.wiley.com/doi/abs/10.1111/j.1365-2389.2012.01479.x>.  
Acesso em: 25 abr. 2020.

HU, Wei; SHAO, Mingan; WANG, Quanjiu; FAN, Jun; HORTON, Robert.  
Temporal changes of soil hydraulic properties under different land uses.  
**Geoderma**, [s.l.], v. 149, n. 3-4, p. 355-366, mar. 2009. Elsevier BV.  
<http://dx.doi.org/10.1016/j.geoderma.2008.12.016>. Disponível em:  
<https://www.sciencedirect.com/science/article/abs/pii/S0016706108003881>.  
Acesso em: 25 abr. 2020.

HU, Wei; SHE, Dongli; SHAO, Ming'an; CHUN, Kwok P.; SI, Bingcheng. Effects of initial soil water content and saturated hydraulic conductivity variability on small watershed runoff simulation using LISEM. **Hydrological Sciences Journal**, [s.l.], v. 60, n. 6, p. 1137-1154, 6 maio 2015. Informa UK Limited.  
<http://dx.doi.org/10.1080/02626667.2014.903332>. Disponível em:  
<https://www.tandfonline.com/doi/full/10.1080/02626667.2014.903332>. Acesso em: 25 abr. 2020.

HU, Wei; SI, Bing Cheng. Soil water prediction based on its scale-specific control using multivariate empirical mode decomposition. **Geoderma**, [s.l.], v. 193-194, p. 180-188, fev. 2013. Elsevier BV.  
<http://dx.doi.org/10.1016/j.geoderma.2012.10.021>. Disponível em:  
<https://www.sciencedirect.com/science/article/abs/pii/S0016706112003746>.  
Acesso em: 25 abr. 2020.

HU, Wei; SI, Bing Cheng. Technical note: multiple Wavelet coherence for untangling scale-specific and localized multivariate relationships in geosciences: Multiple Wavelet coherence for untangling scale-specific and localized multivariate relationships in geosciences. **Hydrology And Earth System Sciences**, [s.l.], v. 20, n. 8, p. 3183-3191, 8 ago. 2016. Copernicus GmbH.  
<http://dx.doi.org/10.5194/hess-20-3183-2016>. Disponível em:

[https://www.hydrol-earth-syst-sci.net/20/3183/2016/hess-20-3183-2016.pdf.](https://www.hydrol-earth-syst-sci.net/20/3183/2016/hess-20-3183-2016.pdf)

Acesso em: 25 abr. 2020.

HUANG, Norden E.; SHEN, Zheng; LONG, Steven R.; WU, Manli C.; SHIH, Hsing H.; ZHENG, Quanan; YEN, Nai-chyuan; TUNG, Chi Chao; LIU, Henry H.. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. **Proceedings Of The Royal Society Of London. Series A: Mathematical, Physical and Engineering Sciences**, [s.l.], v. 454, n. 1971, p. 903-995, 8 mar. 1998. The Royal Society.  
<http://dx.doi.org/10.1098/rspa.1998.0193>. Disponível em:  
<https://scinapse.io/papers/2007221293>. Acesso em: 25 abr. 2020.

HUBBARD, Barbara Burke. **The World According to Wavelets**: The Story of a Mathematical Technique in the Making. 2. ed. Natick: A K Peters, 1998. 286 p. ISBN-13: 978-1568810720.

HUFFMAN, R.L., Fangmeier, D.D., Elliot, W.J., Workman, S.R., Schwab, G.O.. Soil and water conservation engineering. 6 ed. John Wiley & Sons. 528 p. 2011. ISBN-13: 978-0471574903.

HUPET, F.; VANCLOOSTER, M.. Sampling strategies to estimate field areal evapotranspiration fluxes with a soil water balance approach. **Journal Of Hydrology**, [s.l.], v. 292, n. 1-4, p. 262-280, jun. 2004. Elsevier BV.

<http://dx.doi.org/10.1016/j.jhydrol.2004.01.006>. Disponível em:  
<https://www.sciencedirect.com/science/article/pii/S0022169404000162>. Acesso em: 25 abr. 2020.

HWANG, Hyoun-tae; JEEN, Sung-wook; SULEIMAN, Ayman; LEE, Kang-kun. Comparison of Saturated Hydraulic Conductivity Estimated by Three Different Methods. **Water**, [s.l.], v. 9, n. 12, p. 942-957, 4 dez. 2017. MDPI AG.  
<http://dx.doi.org/10.3390/w9120942>. Disponível em:  
<https://www.mdpi.com/2073-4441/9/12/942>. Acesso em: 25 abr. 2020.

JAMES, J. F. **A Student's Guide to Fourier Transforms:** With Applications in Physics and Engineering. 3. ed. New York: Cambridge University Press, 2011. 156 p. ISBN-13: 978-0521176835.

JIA, Xiaoxu; SHAO, Mingan; WEI, Xiaorong; HORTON, Robert; LI, Xuezhang. Estimating total net primary productivity of managed grasslands by a state-space modeling approach in a small catchment on the Loess Plateau, China.

**Geoderma**, [s.l.], v. 160, n. 3-4, p. 281-291, jan. 2011. Elsevier BV.

<http://dx.doi.org/10.1016/j.geoderma.2010.09.016>. Disponível em:

<https://www.sciencedirect.com/science/article/abs/pii/S0016706110002879>.

Acesso em: 25 abr. 2020.

Jolliffe, I.T.. Principal Component Analysis, second ed. New York, Springer.

Klute A, Dirksen C. Hydraulic conductivity and diffusivity: laboratory methods.

In: Klute A (ed) Methods of Soil Analysis. Part 1. 2 ed. Agronomy Monograph, ASA-SSSA, Madison, WI. 1986. 687–734 p. ISBN-13: 978-0891188117.

Klute A. Water retention: laboratory methods. In: Klute A (ed) Methods of Soil Analysis. Part 1. 2 ed. Agronomy Monograph, ASA-SSSA, Madison, WI. 2002. 635–662 p. ISBN-13: 978-0891188117.

Klute, A.. Water retention: laboratory methods. In: Klute, A. (Ed.), Methods of Soil Analysis. Part 1. 2 ed. Agronomy Monograph vol. 9. ASA-SSSA, Madison, WI. 1986. 635–662 p. ISBN-13: 978-0891188117.

Kuinchner, A., Buriol, G.A.. Clima do estado do Rio Grande do Sul segundo a classificação climática de Köppen e Thornthwaite. **Revista Eletrônica Disciplinarum Scientia.** v. 2, p. 171–182, 2001. Disponível em:  
<https://periodicos.ufn.edu.br/index.php/disciplinarumNT/article/view/1136/1077>.  
Acesso em: 25 abr. 2020.

KVÆRNØ, Sigrun H.; STOLTE, Jannes. Effects of soil physical data sources on discharge and soil loss simulated by the LISSEM model. **Catena**, [s.l.], v. 97, p. 137-149, out. 2012. Elsevier BV. <http://dx.doi.org/10.1016/j.catena.2012.05.001>. Disponível em:

<https://www.sciencedirect.com/science/article/abs/pii/S0341816212001002>.

Acesso em: 25 abr. 2020.

LARK, R.m.. Changes in the variance of a soil property along a transect, a comparison of a non-stationary linear mixed model and a Wavelet transform.

**Geoderma**, [s.l.], v. 266, p. 84-97, mar. 2016. Elsevier BV.

<http://dx.doi.org/10.1016/j.geoderma.2015.12.002>. Disponível em:

<https://www.sciencedirect.com/science/article/pii/S0016706115301567>. Acesso em: 25 abr. 2020.

LATHI, B. P. **Sinais e Sistemas Lineares**. 2. ed. Porto Alegre: Bookman, 2007.

856 p. ISBN-13: 978-8560031139.

LEE, Ke; FOSTER, Rc. Soil fauna and soil structure. **Soil Research**, [s.l.], v. 29, n. 6, p. 745-775, 1991. CSIRO Publishing.

<http://dx.doi.org/10.1071/sr9910745>. Disponível em:

<https://www.publish.csiro.au/SR/SR9910745>. Acesso em: 25 abr. 2020.

LEIJ, Feike J.; ROMANO, Nunzio; PALLADINO, Mario; SCHAAP, Marcel G.; COPPOLA, Antonio. Topographical attributes to predict soil hydraulic properties along a hillslope transect. **Water Resources Research**, [s.l.], v. 40, n. 2, p. 1-15, fev. 2004. American Geophysical Union (AGU).

<http://dx.doi.org/10.1029/2002wr001641>. Disponível em:

<https://agupubs.onlinelibrary.wiley.com/doi/10.1029/2002WR001641>. Acesso em: 25 abr. 2020.

LI, Xiangdong; SHAO, Ming'an; ZHAO, Chunlei. Estimating the field capacity and permanent wilting point at the regional scale for the Hexi Corridor in China using a state-space modeling approach. **Journal Of Soils And Sediments**, [s.l.], v. 19, n. 11, p. 3805-3816, 9 abr. 2019. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s11368-019-02314-6>. Disponível em: <https://link.springer.com/article/10.1007/s11368-019-02314-6>. Acesso em: 25 abr. 2020.

LIBARDI, P.L. Dinâmica da água no solo. 2<sup>a</sup> ed. São Paulo, EDUSP, 2012. 346 p. ISBN-13: 978-8531413841.

LIZAGA, Ivan; QUIJANO, Laura; GASPAR, Leticia; RAMOS, María Concepción; NAVAS, Ana. Linking land use changes to variation in soil properties in a Mediterranean mountain agroecosystem. **Catena**, [s.l.], v. 172, p. 516-527, jan. 2019. Elsevier BV.  
<http://dx.doi.org/10.1016/j.catena.2018.09.019>. Disponível em:  
<https://www.sciencedirect.com/science/article/abs/pii/S0341816218303874>.  
Acesso em: 25 abr. 2020.

LOAGUE, Keith; GANDER, Gene A.. R-5 revisited: 1. spatial variability of infiltration on a small rangeland catchment: 1. Spatial variability of infiltration on a small rangeland catchment. **Water Resources Research**, [s.l.], v. 26, n. 5, p. 957-971, maio 1990. American Geophysical Union (AGU).  
<http://dx.doi.org/10.1029/wr026i005p00957>. Disponível em:  
<https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/WR026i005p00957>.  
Acesso em: 25 abr. 2020.

LUO, Ya et al. The effect of environmental factors on spatial variability in land use change in the high-sediment region of China's Loess Plateau. **Journal Of Geographical Sciences**, [s.l.], v. 24, n. 5, p.802-814, 10 jul. 2014.

Mallat, S.. **A Wavelet Tour of Signal Processing**: The Sparse Way. 3 Ed. Academic Press. 2008. 832 p. ISBN-13: 978-0123743701.

MARÍN-CASTRO, B.e.; GEISSERT, D.; NEGRETE-YANKELEVICH, S.; CHÁVEZ, A. Gómez-tagle. Spatial distribution of hydraulic conductivity in soils of secondary tropical montane cloud forests and shade coffee agroecosystems. **Geoderma**, [s.l.], v. 283, p. 57-67, dez. 2016. Elsevier BV.  
<http://dx.doi.org/10.1016/j.geoderma.2016.08.002>. Disponível em:  
<https://www.sciencedirect.com/science/article/abs/pii/S001670611630341X>.  
Acesso em: 24 abr. 2020.

MASSEY, Frank J.. The Kolmogorov-Smirnov Test for Goodness of Fit. **Journal Of The American Statistical Association**, [s.l.], v. 46, n. 253, p. 68-78, mar.

1951. Informa UK Limited. <http://dx.doi.org/10.1080/01621459.1951.10500769>.

Disponível em:

<https://www.tandfonline.com/doi/abs/10.1080/01621459.1951.10500769>.

Acesso em: 25 abr. 2020.

MCBRATNEY, Alex B; MINASNY, Budiman; CATTLE, Stephen R;

VERVOORT, R.willem. From pedotransfer functions to soil inference systems.

**Geoderma**, [s.l.], v. 109, n. 1-2, p. 41-73, set. 2002. Elsevier BV.

[http://dx.doi.org/10.1016/s0016-7061\(02\)00139-8](http://dx.doi.org/10.1016/s0016-7061(02)00139-8). Disponível em:

<https://www.sciencedirect.com/science/article/abs/pii/S0016706102001398>.

Acesso em: 25 abr. 2020.

MOORE, I. D.; GESSLER, P. E.; NIELSEN, G. A.; PETERSON, G. A.. Soil

Attribute Prediction Using Terrain Analysis. **Soil Science Society Of America**

**Journal**, [s.l.], v. 57, n. 2, p. 443-452, mar. 1993. Wiley.

<http://dx.doi.org/10.2136/sssaj1993.03615995005700020026x>. Disponível em:

<https://acsess.onlinelibrary.wiley.com/doi/abs/10.2136/sssaj1993.03615995005700020026x>.

Acesso em: 25 abr. 2020.

MORBIDELLI, Renato; SALTALIPPI, Carla; FLAMMINI, Alessia; CIFRODELLI,

Marco; PICCIAFUOCO, Tommaso; CORRADINI, Corrado; GOVINDARAJU,

Rao S.. In situ measurements of soil saturated hydraulic conductivity:

assessment of reliability through rainfall-runoff experiments: Assessment of

reliability through rainfall-runoff experiments. **Hydrological Processes**, [s.l.], v.

31, n. 17, p. 3084-3094, 7 jul. 2017. Wiley. <http://dx.doi.org/10.1002/hyp.11247>.

Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1002/hyp.11247>.

Acesso em: 25 abr. 2020.

NELSON D.W., SOMMERS L.E.. Total carbon, organic carbon and organic

matter. In: Page AL, Miller RH, Keeney DR (eds) Methods of Soil Analysis. Part

2. 2 ed. Agronomy Monograph, vol.9, ASA-SSSA, Madison, WI. 1982. 534–580

p. ISBN-13: 978-0891180722

NIELSEN, D. R.; ALEMI, Mohammad H.. Statistical opportunities for analyzing spatial and temporal heterogeneity of field soils. **Plant And Soil**, [s.l.], v. 115, n. 2, p. 285-296, abr. 1989. Springer Science and Business Media LLC.  
<http://dx.doi.org/10.1007/bf02202595>. Disponível em:  
<https://link.springer.com/article/10.1007%2FBF02202595>. Acesso em: 25 abr. 2020.

NIELSEN, D.R.; WENDROTH, O. Spatial and temporal statistics: Sampling field soil and their vegetation. Reiskirchen: **Catena** Verlag, 2003. 398 p. ISBN-13: 978-1593262594.

OGUNWOLE, Joshua O.; OBIDIKE, Evelyn O.; TIMM, Luis C.; ODUNZE, Azubuike C.; GABRIELS, Donald M.. Assessment of Spatial Distribution of Selected Soil Properties using Geospatial Statistical Tools. **Communications In Soil Science And Plant Analysis**, [s.l.], v. 45, n. 16, p. 2182-2200, 14 ago. 2014. Informa UK Limited. <http://dx.doi.org/10.1080/00103624.2014.912288>. Disponível em:  
<https://www.tandfonline.com/doi/abs/10.1080/00103624.2014.912288>. Acesso em: 25 abr. 2020.

OLDONI, Henrique; TERRA, Viviane Santos Silva; TIMM, Luís Carlos; REISSER JÚNIOR, Carlos; MONTEIRO, Alex Becker. Delineation of management zones in a peach orchard using multivariate and geostatistical analyses. **Soil And Tillage Research**, [s.l.], v. 191, p. 1-10, ago. 2019. Elsevier BV. <http://dx.doi.org/10.1016/j.still.2019.03.008>. Disponível em:  
<https://www.sciencedirect.com/science/article/pii/S0167198719303952>. Acesso em: 25 abr. 2020.

OLIVEIRA, Marcio Paulo de; TAVARES, Maria Hermínia Ferreira; URIBE-OPAZO, Miguel Angel; TIMM, Luis Carlos. Selecting statistical models to study the relationship between soybean yield and soil physical properties. **Revista Brasileira de Ciência do Solo**, [s.l.], v. 35, n. 1, p. 97-104, fev. 2011. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s0100-06832011000100009>.

Disponível em: [http://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S0100-06832011000100009](http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-06832011000100009). Acesso em: 25 abr. 2020.

Otoni, M.V., Otoni Filho, T.B., Lopes-Assad, M.L.R.C., Rotunno Filho, O.C., 2019. Pedotransfer functions for saturated hydraulic conductivity using a database with temperate and tropical soils. *J. Hydrol.* 575, 1345-1358.

PAPANICOLAOU, Athanasios (thanos) N.; ELHAKEM, Mohamed; WILSON, Christopher G.; BURRAS, C. Lee; WEST, Larry T.; LIN, Hangsheng (henry); CLARK, Ben; ONEAL, Brad E.. Spatial variability of saturated hydraulic conductivity at the hillslope scale: understanding the role of land management and erosional effect: Understanding the role of land management and erosional effect. **Geoderma**, [s.l.], v. 243-244, p. 58-68, abr. 2015. Elsevier BV.  
<http://dx.doi.org/10.1016/j.geoderma.2014.12.010>. Disponível em:  
<https://www.sciencedirect.com/science/article/abs/pii/S0016706114004443>.  
Acesso em: 25 abr. 2020.

PERCIVAL, Donald B.; WALDEN, Andrew T. **Wavelet Methods for Time Series Analysis**. New York: Cambridge University Press, 2008. 594 p.  
ISBN:9780511841040.

PERROTTA, M.M.. Processamento digital básico de imagens de sensores remotos ópticos para uso em mapeamento geológico – programa ENVI. Belo Horizonte: CPRM. 2005. CD-Room.

PICCIAFUOCO, Tommaso; MORBIDELLI, Renato; FLAMMINI, Alessia; SALTALIPPI, Carla; CORRADINI, Corrado; STRAUSS, Peter; BLÖSCHL, Günter. On the estimation of spatially representative plot scale saturated hydraulic conductivity in an agricultural setting. **Journal Of Hydrology**, [s.l.], v. 570, p. 106-117, mar. 2019. Elsevier BV.  
<http://dx.doi.org/10.1016/j.jhydrol.2018.12.044>. Disponível em:  
<https://www.sciencedirect.com/science/article/abs/pii/S0022169419300198>. Acesso em: 25 abr. 2020.

PRICE, Katie; JACKSON, C. Rhett; PARKER, Albert J.. Variation of surficial soil hydraulic properties across land uses in the southern Blue Ridge Mountains, North Carolina, USA. **Journal Of Hydrology**, [s.l.], v. 383, n. 3-4, p. 256-268, mar. 2010. Elsevier BV. <http://dx.doi.org/10.1016/j.jhydrol.2009.12.041>.

Disponível em:

<https://www.sciencedirect.com/science/article/pii/S002216940900835X>. Acesso em: 25 abr. 2020.

PRUSKI, Fernando Falco; FERREIRA, Paulo Afonso; RAMOS, Márcio Mota; CECON, Paulo Roberto. Model to Design Level Terraces. **Journal Of Irrigation And Drainage Engineering**, [s.l.], v. 123, n. 1, p. 8-12, jan. 1997. American Society of Civil Engineers (ASCE). [http://dx.doi.org/10.1061/\(asce\)0733-9437\(1997\)123:1\(8\)](http://dx.doi.org/10.1061/(asce)0733-9437(1997)123:1(8)). Disponível em:

<https://ascelibrary.org/doi/abs/10.1061/%28ASCE%290733-9437%281997%29123%3A1%288%29>. Acesso em: 25 abr. 2020.

QIAO, Jiangbo; ZHU, Yuanjun; JIA, Xiaoxu; HUANG, Laiming; SHAO, Ming'an. Estimating the spatial relationships between soil hydraulic properties and soil physical properties in the critical zone (0–100 m) on the Loess Plateau, China: a state-space modeling approach: A state-space modeling approach. **Catena**, [s.l.], v. 160, p. 385-393, jan. 2018. Elsevier BV.

<http://dx.doi.org/10.1016/j.catena.2017.10.006>. Disponível em:

<https://www.sciencedirect.com/science/article/abs/pii/S0341816217303284>.

Acesso em: 25 abr. 2020.

R DEVELOPMENT CORE TEAM. R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna. <https://www.R-project.org>. 2016.

R DEVELOPMENT CORE TEAM. R: A Language and Environment for Statistical Computing Vienna: R foundation for Statistical Computing <http://wwwR-projectorg/>. 2012.

REHMAN, N.; MANDIC, D. P.. Multivariate empirical mode decomposition. **Proceedings Of The Royal Society A: Mathematical, Physical and Engineering Sciences**, [s.l.], v. 466, n. 2117, p. 1291-1302, 23 dez. 2009. The Royal Society. <http://dx.doi.org/10.1098/rspa.2009.0502>. Disponível em: <https://royalsocietypublishing.org/doi/10.1098/rspa.2009.0502>. Acesso em: 25 abr. 2020.

Reichardt, K., Timm, L.C.. **Soil, Plant and Atmosphere**: concepts, processes and applications. 1 ed. Springer, Basel. 2020. ISBN 978-3-030-19322-5.

REICHARDT, K.; TIMM, L.C. **Solo, Planta e Atmosfera**: Conceitos, processos e aplicações. 3<sup>a</sup> ed, São Paulo: Ed. Manole, 2016. 524 p. ISBN-13: 978-8520433393.

RIENZI, E.a.; MAGGI, A.e.; SCROFFA, M.; LOPEZ, V.c.; CABANELLA, P.. Autoregressive state spatial modeling of soil bulk density and organic carbon in fields under different tillage system. **Soil And Tillage Research**, [s.l.], v. 159, p. 56-66, jun. 2016. Elsevier BV. <http://dx.doi.org/10.1016/j.still.2016.01.006>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S016719871630006X>. Acesso em: 25 abr. 2020.

ROA-GARCÍA, M. C.; BROWN, S.; SCHREIER, H.; LAVKULICH, L. M.. The role of land use and soils in regulating water flow in small headwater catchments of the Andes. **Water Resources Research**, [s.l.], v. 47, n. 5, p. 1-27, maio 2011. American Geophysical Union (AGU). <http://dx.doi.org/10.1029/2010wr009582>. Disponível em: <https://agupubs.onlinelibrary.wiley.com/doi/full/10.1029/2010WR009582>. Acesso em: 25 abr. 2020.

SALEMI, Luiz Felipe; GROOPPO, Juliano Daniel; TREVISAN, Rodrigo; MORAES, Jorge Marcos de; FERRAZ, Silvio Frosini de Barros; VILLANI, João Paulo; DUARTE-NETO, Paulo José; MARTINELLI, Luiz Antonio. Land-use change in the Atlantic rainforest region: consequences for the hydrology of

- small catchments: Consequences for the hydrology of small catchments. **Journal Of Hydrology**, [s.l.], v. 499, p. 100-109, ago. 2013. Elsevier BV. <http://dx.doi.org/10.1016/j.jhydrol.2013.06.049>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0022169413005027?via%3Dhub>. Acesso em: 25 abr. 2020.
- SAMADIANFARD, Saeed; ASADI, Esmaeil; JARHAN, Salar; KAZEMI, Honeyeh; KHESHTGAR, Salar; KISI, Ozgur; SAJJADI, Shahin; MANAF, Azizah Abdul. Wavelet neural networks and gene expression programming models to predict short-term soil temperature at different depths. **Soil And Tillage Research**, [s.l.], v. 175, p. 37-50, jan. 2018. Elsevier BV. <http://dx.doi.org/10.1016/j.still.2017.08.012>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S016719871730154X>. Acesso em: 25 abr. 2020.
- SAXTON, K. E.; RAWLS, W. J.. Soil Water Characteristic Estimates by Texture and Organic Matter for Hydrologic Solutions. **Soil Science Society Of America Journal**, [s.l.], v. 70, n. 5, p. 1569-1578, set. 2006. Wiley. <http://dx.doi.org/10.2136/sssaj2005.0117>. Disponível em: <https://acess.onlinelibrary.wiley.com/doi/abs/10.2136/sssaj2005.0117>. Acesso em: 25 abr. 2020.
- SCHAAP, Marcel G.; LEIJ, Feike J.; VAN GENUCHTEN, Martinus Th.. Rosetta: a computer program for estimating soil hydraulic parameters with hierarchical pedotransfer functions: a computer program for estimating soil hydraulic parameters with hierarchical pedotransfer functions. **Journal Of Hydrology**, [s.l.], v. 251, n. 3-4, p. 163-176, out. 2001. Elsevier BV. [http://dx.doi.org/10.1016/s0022-1694\(01\)00466-8](http://dx.doi.org/10.1016/s0022-1694(01)00466-8). Disponível em: <https://www.sciencedirect.com/science/article/pii/S0022169401004668>. Acesso em: 25 abr. 2020.
- SCHNEIDER, K.; HUISMAN, J.a.; BREUER, L.; ZHAO, Y.; FREDE, H.-g.. Temporal stability of soil moisture in various semi-arid steppe ecosystems and its application in remote sensing. **Journal Of Hydrology**, [s.l.], v. 359, n. 1-2, p.

16-29, set. 2008. Elsevier BV. <http://dx.doi.org/10.1016/j.jhydrol.2008.06.016>.

Disponível em:

<https://www.sciencedirect.com/science/article/pii/S0022169408002813>. Acesso em: 25 abr. 2020.

SHE, Dongli; XUEMEI, Gao; JINGRU, Song; TIMM, Luis Carlos; HU, Wei. Soil organic carbon estimation with topographic properties in artificial grassland using a state-space modeling approach. **Canadian Journal Of Soil Science**, [s.l.], v. 94, n. 4, p. 503-514, ago. 2014. Canadian Science Publishing.

<http://dx.doi.org/10.4141/cjss2013-060>. Disponível em:

<https://www.nrcresearchpress.com/doi/full/10.4141/cjss2013-060#.XqRmQSIKjIU>. Acesso em: 25 abr. 2020.

SHE, Dongli; ZHENG, Jiaxing; SHAO, Ming'an; TIMM, Luis Carlos; XIA, Yongqiu. Multivariate Empirical Mode Decomposition Derived Multi-Scale Spatial Relationships between Saturated Hydraulic Conductivity and Basic Soil Properties. **Clean - Soil, Air, Water**, [s.l.], v. 43, n. 6, p. 910-918, 21 maio 2015. Wiley. <http://dx.doi.org/10.1002/clen.201400143>. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1002/clen.201400143>. Acesso em: 25 abr. 2020.

SHUMWAY, R.H. **Applied statistical time series analysis**. New York: Prentice-Hall. 1988. 379 p. ISBN-13: 978-0130415004.

SHUMWAY, R.H.; Stoffer, D.S. **Time Series Analysis and Its Applications, With R Examples**. 3 ed. London: Springer. 2011. 609 p. ISBN-13: 978-1441978646.

SI, Bing Cheng. Spatial Scaling Analyses of Soil Physical Properties: a review of spectral and Wavelet methods: A Review of Spectral and Wavelet Methods. **Vadose Zone Journal**, [s.l.], v. 7, n. 2, p. 547-562, maio 2008. Wiley. <http://dx.doi.org/10.2136/vzj2007.0040>. Disponível em: <https://acsess.onlinelibrary.wiley.com/doi/full/10.2136/vzj2007.0040>. Acesso em: 25 abr. 2020.

SI, Bing Cheng; ZELEKE, Takele B.. Wavelet coherency analysis to relate saturated hydraulic properties to soil physical properties. **Water Resources Research**, [s.l.], v. 41, n. 11, p. 1-9, nov. 2005. American Geophysical Union (AGU). <http://dx.doi.org/10.1029/2005wr004118>. Disponível em: <https://agupubs.onlinelibrary.wiley.com/doi/full/10.1029/2005WR004118>. Acesso em: 25 abr. 2020.

SOIL CONSERVATION SERVICE (SCS). **Hydrology for small watersheds**. Technical Release 55. Springfield: United States Department of Agriculture. 1986.

SOIL SURVEY STAFF. **Keys to Soil Taxonomy**. 11 ed. USDA-Natural Resources Conservation Service, Washington, DC. 2010. ISBN-13: 978-1782662112.

TASKINEN, Antti; SIRVIÖ, Hannu; BRUEN, Michael. Statistical analysis of the effects on overland flow of spatial variability in soil hydraulic conductivity (Analyse statistique des effets de la variabilité spatiale de la conductivité hydraulique du sol sur l'écoulement de surface). **Hydrological Sciences Journal**, [s.l.], v. 53, n. 2, p. 387-400, abr. 2008. Informa UK Limited. <http://dx.doi.org/10.1623/hysj.53.2.387>. Disponível em: <https://www.tandfonline.com/doi/abs/10.1623/hysj.53.2.387>. Acesso em: 25 abr. 2020.

TEDESCO, M.J.; GIANELLO, C.; BISSANI, C.A.; BOHNEN, H.; VOLKWEISS, S.J. **Análise de solo, plantas e outros materiais**. 2 ed. Porto Alegre: Faculdade de Agronomia/UFRGS. 1995. 174p.

TIMM, L.C.; REICHARDT, K.; OLIVEIRA, J.C.M.; CASSARO, F.A.M.; TOMINAGA, T.T.; BACCHI, O.O.S.; DOURADO-NETO, D.. Sugarcane production evaluated by the state-space approach. **Journal Of Hydrology**, [s.l.], v. 272, n. 1-4, p. 226-237, mar. 2003. Elsevier BV. [http://dx.doi.org/10.1016/s0022-1694\(02\)00267-6](http://dx.doi.org/10.1016/s0022-1694(02)00267-6). Disponível em:

<https://www.sciencedirect.com/science/article/pii/S0022169402002676>. Acesso em: 25 abr. 2020.

TOLSTOV, Georgi P. **Fourier Series**. New York: Dover Publications. 2012. 352 p. ISBN-13: 978-1614277156.

TORRENCE, C.; COMPO, G.P.. A Practical Guide to Wavelet Analysis.

**Bulletin Of The American Meteorological Society**, [s.l.], v. 79, n. 1, p. 61-78, jan. 1998. American Meteorological Society. [http://dx.doi.org/10.1175/1520-0477\(1998\)0792.0.co;2](http://dx.doi.org/10.1175/1520-0477(1998)0792.0.co;2). Disponível em: <https://journals.ametsoc.org/doi/abs/10.1175/1520-0477%281998%29079%3C0061%3AAPGTWA%3E2.0.CO%3B2>. Acesso em: 25 abr. 2020.

VASQUES, G. M.; GRUNWALD, S.; MYERS, D.B.. Associations between soil carbon and ecological landscape variables at escalating spatial scales in Florida, USA. **Landscape Ecology**, [s.l.], v. 27, n. 3, p. 355-367, 3 jan. 2012. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s10980-011-9702-3>. Disponível em: <https://link.springer.com/article/10.1007/s10980-011-9702-3>. Acesso em: 25 abr. 2020.

VEREECKEN, H.. Estimating the unsaturated hydraulic conductivity from theoretical models using simple soil properties. **Geoderma**, [s.l.], v. 65, n. 1-2, p. 81-92, fev. 1995. Elsevier BV. [http://dx.doi.org/10.1016/0016-7061\(95\)92543-x](http://dx.doi.org/10.1016/0016-7061(95)92543-x). Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/001670619592543X>. Acesso em: 25 abr. 2020.

VIEIRA, S. R; DECHEN, S. C. F.. Spatial variability studies in São Paulo, Brazil along the last twenty five years. **Bragantia**, [s.l.], v. 69, p. 53-66, 2010. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s0006-87052010000500007>. Disponível em: [http://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S0006-87052010000500007](http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0006-87052010000500007). Acesso em: 25 abr. 2020.

VIOLA, Marcelo Ribeiro; MELLO, Carlos Rogério de; BESKOW, Samuel; NORTON, Lloyd Darrell. Applicability of the LASH Model for Hydrological Simulation of the Grande River Basin, Brazil. **Journal Of Hydrologic Engineering**, [s.l.], v. 18, n. 12, p. 1639-1652, dez. 2013. American Society of Civil Engineers (ASCE). [http://dx.doi.org/10.1061/\(asce\)he.1943-5584.0000735](http://dx.doi.org/10.1061/(asce)he.1943-5584.0000735). Disponível em: <https://ascelibrary.org/doi/pdf/10.1061/%28ASCE%29HE.1943-5584.0000735>. Acesso em: 25 abr. 2020.

VOGEL, Hans-jörg. Scale Issues in Soil Hydrology. **Vadose Zone Journal**, [s.l.], v. 18, n. 1, p. 1-10, jan. 2019. Wiley.  
<http://dx.doi.org/10.2136/vzj2019.01.0001>. Disponível em:  
<https://acsess.onlinelibrary.wiley.com/doi/full/10.2136/vzj2019.01.0001>. Acesso em: 25 abr. 2020.

WANG, Yunqiang; SHAO, Ming'an; LIU, Zhipeng; HORTON, Robert. Regional-scale variation and distribution patterns of soil saturated hydraulic conductivities in surface and subsurface layers in the loessial soils of China. **Journal Of Hydrology**, [s.l.], v. 487, p. 13-23, abr. 2013. Elsevier BV.  
<http://dx.doi.org/10.1016/j.jhydrol.2013.02.006>. Disponível em:  
<https://www.sciencedirect.com/science/article/pii/S0022169413001182>. Acesso em: 25 abr. 2020.

WENDROTH, O., REYNOLDS, W.D., VIEIRA, S.R., REICHARDT, K., WIRTH, S.. Statistical approaches to the analysis of soil quality data. In: Gregorich, E.G., Carter, M.R. (Eds.) Soil quality for crop production and ecosystem health. Elsevier Science, Amsterdam. 1997. 247-276 p. ISBN: 9780444816610.

WENDROTH, Ole; JÜRSCHIK, Peter; KERSEBAUM, K.christian; REUTER, Hannes; VAN KESSEL, Chris; NIELSEN, Donald R. Identifying, understanding, and describing spatial processes in agricultural landscapes — four case studies. **Soil And Tillage Research**, [s.l.], v. 58, n. 3-4, p. 113-127, mar. 2001. Elsevier BV. [http://dx.doi.org/10.1016/s0167-1987\(00\)00162-8](http://dx.doi.org/10.1016/s0167-1987(00)00162-8). Disponível em:  
<https://www.sciencedirect.com/science/article/pii/S0167198700001628>. Acesso em: 25 abr. 2020.

WENDROTH, Ole; REUTER, Hannes I.; KERSEBAUM, K.christian. Predicting yield of barley across a landscape: a state-space modeling approach: a state-space modeling approach. **Journal Of Hydrology**, [s.l.], v. 272, n. 1-4, p. 250-263, mar. 2003. Elsevier BV. [http://dx.doi.org/10.1016/s0022-1694\(02\)00269-x](http://dx.doi.org/10.1016/s0022-1694(02)00269-x).

Disponível em:

<https://www.sciencedirect.com/science/article/pii/S002216940200269X>. Acesso em: 25 abr. 2020.

Wilding, L.P., Drees, L.R.. Spatial variability and pedology. In: Wilding, L.P., Smeck, N.E., Hall, G.F. (Eds.), Pedogenesis and Soil Taxonomy: 1. Concepts and Soil Analysis. second ed. American Society of Agronomy, Madison 1983. 635–662 p. ISBN: 9780080869780.

WÖSTEN, J.h.m.; PACHEPSKY, Ya.a.; RAWLS, W.j.. Pedotransfer functions: bridging the gap between available basic soil data and missing soil hydraulic characteristics: bridging the gap between available basic soil data and missing soil hydraulic characteristics. **Journal Of Hydrology**, [s.l.], v. 251, n. 3-4, p. 123-150, out. 2001. Elsevier BV. [http://dx.doi.org/10.1016/s0022-1694\(01\)00464-4](http://dx.doi.org/10.1016/s0022-1694(01)00464-4). Disponível em:

<https://www.sciencedirect.com/science/article/pii/S0022169401004644>. Acesso em: 25 abr. 2020.

WU, Qiong; GUO, Fengxiang; LI, Hongqing. Wavelet-Based Correlation Identification of Scales and Locations between Landscape Patterns and Topography in Urban-Rural Profiles: case of the jilin city, china: Case of the Jilin City, China. **Remote Sensing**, [s.l.], v. 10, n. 10, p. 1653-1668, 17 out. 2018. MDPI AG. <http://dx.doi.org/10.3390/rs10101653>. Disponível em:

<https://www.mdpi.com/2072-4292/10/10/1653>. Acesso em: 25 abr. 2020.

XIN-ZHONG, Wang; GUO-SHUN, Liu; HONG-CHAO, Hu; ZHEN-HAI, Wang; QING-HUA, Liu; XU-FENG, Liu; WEI-HONG, Hao; YAN-TAO, Li. Determination of management zones for a tobacco field based on soil fertility. **Computers And Electronics In Agriculture**, [s.l.], v. 65, n. 2, p. 168-175, mar. 2009.

Elsevier BV. <http://dx.doi.org/10.1016/j.compag.2008.08.008>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0168169908002020>. Acesso em: 25 abr. 2020.

XIONG, X.; GRUNWALD, S.; CORSTANJE, R.; YU, C.; BLIZNYUK, N.. Scale-dependent variability of soil organic carbon coupled to land use and land cover. **Soil And Tillage Research**, [s.l.], v. 160, p. 101-109, jul. 2016. Elsevier BV. <http://dx.doi.org/10.1016/j.still.2016.03.001>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0167198716300253>. Acesso em: 25 abr. 2020.

YANG, Yang; JIA, Xiaoxu; WENDROTH, Ole; LIU, Baoyuan; SHI, Yangzi; HUANG, Tingting; BAI, Xue. Noise-Assisted Multivariate Empirical Mode Decomposition of Saturated Hydraulic Conductivity along a South-North Transect across the Loess Plateau of China. **Soil Science Society Of America Journal**, [s.l.], v. 83, n. 2, p. 311-323, mar. 2019. Wiley. <http://dx.doi.org/10.2136/sssaj2018.11.0438>. Disponível em: <https://acsess.onlinelibrary.wiley.com/doi/full/10.2136/sssaj2018.11.0438>. Acesso em: 25 abr. 2020.

YAO, Rong-jiang; YANG, Jing-song; WU, Dan-hua; LI, Fu-rong; GAO, Peng; WANG, Xiang-ping. Evaluation of pedotransfer functions for estimating saturated hydraulic conductivity in coastal salt-affected mud farmland. **Journal Of Soils And Sediments**, [s.l.], v. 15, n. 4, p. 902-916, 8 jan. 2015. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s11368-014-1055-5>. Disponível em: <https://link.springer.com/article/10.1007/s11368-014-1055-5>. Acesso em: 25 abr. 2020.

ZHANG, Libao; CHEN, Jie; QIU, Bingchang. Region-of-Interest Coding Based on Saliency Detection and Directional Wavelet for Remote Sensing Images. **Ieee Geoscience And Remote Sensing Letters**, [s.l.], v. 14, n. 1, p. 23-27, jan. 2017. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/lgrs.2016.2623670>. Disponível em: <https://ieeexplore.ieee.org/document/7748457>. Acesso em: 25 abr. 2020.

ZHANG, Qingyin; YAO, Yafei; JIA, Xiaoxu; SHAO, Mingan. Estimation of soil organic carbon under different vegetation types on a hillslope of China's northern Loess Plateau using state-space approach. **Canadian Journal Of Soil Science**, [s.l.], v. 94, n. 4, p. 667-677, 20 jul. 2017. Canadian Science Publishing. <http://dx.doi.org/10.1139/cjss-2017-0042>. Disponível em: <https://www.nrcresearchpress.com/doi/full/10.1139/cjss-2017-0042#.XqR23ylKjIU>. Acesso em: 25 abr. 2020.

ZHANG, Xi; WENDROTH, Ole; MATOCHA, Christopher; ZHU, Junfeng. Estimating Soil Hydraulic Conductivity at the Field Scale With a State-Space Approach. **Soil Science**, [s.l.], v. 184, n. 3, p. 101-111, jun. 2019. Ovid Technologies (Wolters Kluwer Health). <http://dx.doi.org/10.1097/SS.0000000000000253>. Disponível em: [https://journals.lww.com/soilsci/Abstract/2019/06000/Estimating\\_Soil\\_Hydraulic\\_Conductivity\\_at\\_the.5.aspx](https://journals.lww.com/soilsci/Abstract/2019/06000/Estimating_Soil_Hydraulic_Conductivity_at_the.5.aspx). Acesso em: 25 abr. 2020.

ZHANG, Xi; ZHU, Junfeng; WENDROTH, Ole; MATOCHA, Christopher; EDWARDS, Dwayne. Effect of Macroporosity on Pedotransfer Function Estimates at the Field Scale. **Vadose Zone Journal**, [s.l.], v. 18, n. 1, p. 1-15, jan. 2019. Wiley. <http://dx.doi.org/10.2136/vzj2018.08.0151>. Disponível em: <https://acsess.onlinelibrary.wiley.com/doi/full/10.2136/vzj2018.08.0151>. Acesso em: 25 abr. 2020.

ZHANG, Yonggen; SCHAAP, Marcel G.. Estimation of saturated hydraulic conductivity with pedotransfer functions: a review: A review. **Journal Of Hydrology**, [s.l.], v. 575, p. 1011-1030, ago. 2019. Elsevier BV. <http://dx.doi.org/10.1016/j.jhydrol.2019.05.058>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0022169419305049>. Acesso em: 25 abr. 2020.

ZHAO, Chunlei; SHAO, Ming'an; JIA, Xiaoxu; NASIR, Mubasher; ZHANG, Chencheng. Using pedotransfer functions to estimate soil hydraulic conductivity in the Loess Plateau of China. **Catena**, [s.l.], v. 143, p. 1-6, ago. 2016. Elsevier

BV. <http://dx.doi.org/10.1016/j.catena.2016.03.037>. Disponível em:  
<https://www.sciencedirect.com/science/article/abs/pii/S0341816216301242>.  
Acesso em: 25 abr. 2020.

ZHAO, Ruiying; BISWAS, Asim; ZHOU, Yin; ZHOU, Yue; SHI, Zhou; LI, Hongyi. Identifying localized and scale-specific multivariate controls of soil organic matter variations using multiple Wavelet coherence. **Science Of The Total Environment**, [s.l.], v. 643, p. 548-558, dez. 2018. Elsevier BV.  
<http://dx.doi.org/10.1016/j.scitotenv.2018.06.210>. Disponível em:  
<https://www.sciencedirect.com/science/article/pii/S0048969718322873>. Acesso em: 25 abr. 2020.

ZHU, Hongfen; HU, Wei; JING, Yaodong; CAO, Yi; BI, Rutian; YANG, Wude. Soil organic carbon prediction based on scale-specific relationships with environmental factors by discrete Wavelet transform. **Geoderma**, [s.l.], v. 330, p. 9-18, nov. 2018. Elsevier BV.  
<http://dx.doi.org/10.1016/j.geoderma.2018.05.029>. Disponível em:  
<https://www.sciencedirect.com/science/article/abs/pii/S0016706118303197>.  
Acesso em: 25 abr. 2020.

ZIMMERMANN, Alexander; SCHINN, Dustin S.; FRANCKE, Till; ELSENBEER, Helmut; ZIMMERMANN, Beate. Uncovering patterns of near-surface saturated hydraulic conductivity in an overland flow-controlled landscape. **Geoderma**, [s.l.], v. 195-196, p. 1-11, mar. 2013. Elsevier BV.  
<http://dx.doi.org/10.1016/j.geoderma.2012.11.002>. Disponível em:  
<https://www.sciencedirect.com/science/article/abs/pii/S0016706112003898>.  
Acesso em: 25 abr. 2020.

ZIMMERMANN, Beate; ELSENBEER, Helmut; MORAES, Jorge M. de. The influence of land-use changes on soil hydraulic properties: implications for runoff generation: Implications for runoff generation. **Forest Ecology And Management**, [s.l.], v. 222, n. 1-3, p. 29-38, fev. 2006. Elsevier BV.  
<http://dx.doi.org/10.1016/j.foreco.2005.10.070>.