

UFRRJ
INSTITUTO DE AGRONOMIA
CURSO DE PÓS-GRADUAÇÃO EM AGRONOMIA
CIÊNCIA DO SOLO

TESE

**Análise Espaço-temporal e Predição de Atributos do
Solo em Seropédica - RJ**

Hugo Hermsdorff das Neves

2017



**UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO
INSTITUTO DE AGRONOMIA
CURSO DE PÓS-GRADUAÇÃO EM AGRONOMIA
CIÊNCIA DO SOLO**

**ANÁLISE ESPAÇO-TEMPORAL E PREDIÇÃO DE ATRIBUTOS DO SOLO
EM SEROPÉDICA - RJ**

HUGO HERMSDORFF DAS NEVES

Sob a Orientação do professor

Marcos Bacis Ceddia

e

Co-orientação dos professores

Daniel Fonseca de Carvalho

e

Ole Wendroth

Tese submetida como requisito parcial para obtenção do grau de **Doutor**, no Curso de Pós-Graduação em Agronomia, Área de Concentração em Ciência do Solo.

Seropédica, RJ
Abril de 2017

Universidade Federal Rural do Rio de Janeiro
Biblioteca Central / Seção de Processamento Técnico

Ficha catalográfica elaborada
com os dados fornecidos pelo autor

N 513a	<p>Neves, Hugo Hermsdorff das, 1980- Análise espaço-temporal e predição de atributos do solo em Seropédica – RJ / Hugo Hermsdorff das Neves, 2017. 100 f..</p> <p>Orientador: Marcos Bacis Ceddia. Tese (doutorado) – Universidade Federal Rural do Rio de Janeiro, Curso de Pós-Graduação em Agronomia – Ciência do Solo, 2017.</p> <p>1. Análise Spectral. 2. State Space. 3. Funções de pedotransferência. 4. Estabilidade Temporal. 5. Água no solo. I. Ceddia, Marcos Bacis, 1968-, orient. II. Universidade Federal Rural do Rio de Janeiro. Curso de Pós-Graduação em Agronomia – Ciência do Solo. III. Título.</p>
--------	--

É permitida a cópia parcial ou total desta tese, desde que seja citada a fonte.

UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO
INSTITUTO DE AGRONOMIA
CURSO DE PÓS-GRADUAÇÃO EM AGRONOMIA - CIÊNCIA DO SOLO

HUGO HERMSDORFF DAS NEVES

Tese submetida como requisito parcial para obtenção do grau de **Doutor**, no Curso de Pós-Graduação em Agronomia, área de Concentração em Ciência do Solo.

TESE APROVADA EM 22/02/2017.

Marcos Bacis Ceddia. Dr. UFRRJ
(Orientador)

Marcos Gervásio Pereira. Dr. UFRRJ

Helena Saraiva Koenow Pinheiro. Dr. UFRRJ

Gustavo de Mattos Vasques. Ph.D. Embrapa Solos

Guilherme Kangussu Donagemma. Dr. Embrapa Solos

DEDICATÓRIA

Aos meus pais com muito carinho. Agradeço pela dedicação, esforço e carinho.

A minha companheira de vida e esposa Maria Gabriela. Sou eternamente grato pelo seu companheirismo e pelos momentos em que insistiu para que eu continuasse estudando.

A minha irmã Fernanda, você é muito especial para mim.

Aos meus amigos e amigas.

AGRADECIMENTOS

Ao Prof. Dr. Marcos Bacis Ceddia pela orientação e pelos momentos de diálogos e socialização da indignação da situação política que o Brasil vive;

Ao meu coorientador Prof. Dr. Daniel Fonseca de Carvalho que me acolheu nos momentos que precisei;

Ao Prof. Dr. Ole Wendroth que confiou em nosso trabalho e nos recebeu na Universidade de Kentucky, Lexington, EUA. Sou muito grato por sua dedicação, generosidade e acolhimento;

Agradeço muito ao Colégio Técnico da Universidade Federal Rural do Rio de Janeiro (CTUR), em especial ao Diretor Prof. Ricardo Crivano Albieri, pela confiança e oportunidade para cursar o doutorado;

Aos professores e funcionários do CTUR por terem me apoiado durante este período;

A UFRRJ e ao CPGA-CS, pela oportunidade e ensinamentos;

A Universidade de Kentucky (EUA), pela receptividade e ensinamentos;

A CAPES, pela bolsa de estudos no doutorado sanduíche;

E a todos e todas que participaram, direta ou indiretamente, da construção deste trabalho, mesmo não sendo citados, são peças importantes para a sua realização.

RESUMO GERAL

NEVES, Hugo Hermsdorff das. **Análise espaço-temporal e predição de atributos do solo em Seropédica - RJ.** 100f. Tese (Doutorado em Agronomia, Ciência do Solo). Instituto de Agronomia, Universidade Federal Rural do Rio de Janeiro, Seropédica, RJ, 2017.

A necessidade de aumentar a eficiência do uso dos recursos naturais na agricultura e a necessidade de otimizar a geração de dados tem levado ao desenvolvimento de tecnologias que consideram a importância da variabilidade espacial e temporal no planejamento do manejo do solo e no desenvolvimento de ferramentas matemáticas que objetivem a geração de dados com um menor custo com maior rapidez. Os objetivos deste trabalho foram: analisar a variabilidade espaço-temporal da umidade do solo em uma área de produção agrícola; estudar os fatores que contribuem na variabilidade espacial do carbono, através da análise dos semivariogramas, análise espectral e “*state space*”; desenvolver uma função de pedotransferência para estimar a capacidade de retenção de água nos solos de Seropédica-RJ. No Capítulo I foi realizado o monitoramento da umidade do solo através de um grid amostral, em três profundidades considerando o espaço e o tempo. A umidade do solo apresentou um padrão de distribuição espacial ao longo do tempo. A correlação entre o conteúdo de água no solo e conteúdo de argila variou com a profundidade e com a magnitude do conteúdo de água do solo. Durante a estação úmida é necessário intensificar a densidade de amostragem a fim de estimar o conteúdo médio de água no solo. Capítulo II: amostras de solo foram coletadas na forma de um transecto, onde se analisaram características químicas e a distribuição de partículas. A variabilidade espacial do carbono e a influência dos demais atributos do solo e da paisagem em sua distribuição foi analisada através da semivariância, análise espectral e da análise “*state space*”. Elevação, carbono e argila apresentaram autocorrelação no espaço independente da direção do transecto analisada. Os valores prévios de argila apresentaram as melhores predições quando comparadas com os as predições realizadas com os outros atributos. Estes resultados apontam a aplicabilidade do uso destas técnicas estatísticas no estudo das variáveis do solo na paisagem agrícola. Capítulo III: elaboraram-se funções de pedotransferência com a finalidade de se estimar a retenção da água na capacidade de campo, retenção à 80 kPa e no ponto de murcha permanente. Os atributos elevação, argila e areia apresentaram boa correlação com a retenção de água. A capacidade de predição da função não variou com o número de pontos utilizados para se gerar a função. Não houve diferença significativa dos coeficientes de determinação das equações que utilizaram um maior número de atributos das equações que utilizaram menor número de atributos. As funções mostraram boa capacidade de predizer as características físico-hídricas da região.

Palavras chaves: Carbono. Água no solo. Estabilidade temporal. Análise espectral. *State Space*. Funções de pedotransferência.

GENERAL ABSTRACT

NEVES, Hugo Hermsdorff das. **Spatio-temporal analysis and prediction of soil attributes.** 100p. Thesis (Doctor Science in Agronomy, Soil Science). Instituto de Agronomia, Universidade Federal Rural do Rio de Janeiro, Seropédica, RJ, 2017.

In order to increase the natural resources efficiency use in agriculture and optimize the dataset generation, the soil science is developing technologies that consider the importance of spatial and temporal variability in soil management planning and developing mathematical tools to estimate soil attributes at low costs and fast. The aims of this study were: understand the spatial and temporal variability of soil water content in an agricultural area; describe and understand the factors which contribute to the spatial distribution of SOC using autoregressive state space models and spectral analysis; to elaborate functions in order to estimate the soil moisture related to the field capacity, 80 kPa and permanent wilting point. Chapter I: soil moisture was monitored in a regular grid, at three depths considering space and time. Chapter II: soil samples were collected in a transect scheme. The soil fertility and texture were analyzed. The spatial variability of soil organic carbon was influenced by texture and the position at the landscape. It was analyzed using semivariograms, spectral analysis and state space. Elevation, soil organic carbon and clay content showed autocorrelation over the space. Previous values of clay exhibited best prediction quality compared to other soil attributes. These results demonstrated the applicability of state space and spectral analysis in studying the soil attributes in the landscape. Chapter III: a pedotransfer function was developed in order to estimate the soil moisture related to the field capacity, 80 kPa and permanent wilting point. Elevation, clay and sand content showed a correlation with soil water retention. The number of data used to generate the function did not change the function ability to estimate the soil water retention. We did not observe difference between determination coefficients of the equations which used more attributes than the equations that used a few attributes. These results demonstrated the applicability of the elaborated equations in predicting soil water retention. Soil Water Content exhibited temporal stability and the correlation between SWC and clay content varied both with the depth and the magnitude of SWC. During the wet season it is necessary to intensify the sampling density to estimate the SWC.

Kew words: Soil organic carbon. Soil water content. Spectral analysis. State space. Pedotransfer functions.

SUMÁRIO

1. INTRODUÇÃO GERAL	1
2. REVISÃO DE LITERATURA.....	3
2.1. Caracterização do Meio Físico da Área de Estudo e Posição na Toposequência das Coletas de Dados	3
2.2. Abordagens Espaciais e Temporais	4
2.2.1 Autocorrelação e correlação cruzada.....	4
2.2.2 Semivariogramas e semivariogramas cruzados.....	6
2.2.3 Análise espectral.....	7
2.2.4 Análise “State space”.....	9
2.2.5 Funções de pedotransferência para determinação da retenção da água no solo.....	10
3. CAPÍTULO I SPATIAL AND TEMPORAL PATTERNS OF SOIL WATER CONTENT IN AN AGROECOLOGICAL PRODUCTION SYSTEM.....	14
3.1 RESUMO.....	15
3.2 ABSTRACT	16
3.3 INTRODUCTION	17
3.4 MATERIAL AND METHODS	18
3.4.1 The study site, experimental layout, soil analysis and soil water monitoring	18
3.4.2 Statistical analysis.....	19
3.3. RESULTS AND DISCUSSION.....	21
3.3.1 The soil texture and soil water content across plot.....	21
3.3.2 Temporal and spatial variability of SWC and its correlation along the time	24
3.3.3 The correlation between SWC and clay content over time	33
3.4. CONCLUSIONS	37
3.5. ACKNOWLEDGEMENTS	37
3.6. REFERENCES	38
4. CAPÍTULO II STATE SPACE APPROACH TO ANALYZE SPATIAL DISTRIBUTION OF SOIL ORGANIC CARBON.....	40
4.1 RESUMO.....	41
4.2 ABSTRACT	42
4.3 INTRODUCTION	43
4.4 MATERIAL AND METHODS	45
4.4.1 Studied area, experimental design and soil sampling.....	45
4.5 RESULTS AND DISCUSSION.....	49
4.5.1 Spatial variability of soil properties.....	49
4.5.2 Spectral analysis of soil organic carbon and other soil properties	50
4.5.3 Crosscorrelation functions of soil organic carbon and other soil properties.	55
4.5.4 State space models of soil organic carbon.....	61
4.6 CONCLUSIONS	65
4.7 ACKNOWLEDGEMENTS	65
5. CAPÍTULO III	66
FUNÇÕES DE PEDOTRANSFERÊNCIA PARA DETERMINAÇÃO DA RETENÇÃO DA ÁGUA NO SOLO PARA A REGIÃO DE SEROPÉDICA, RJ.....	66
5.1 RESUMO.....	67

5.2 ABSTRACT	68
5.3 INTRODUÇÃO	69
5.4. MATERIAL E MÉTODOS	70
5.4.1 Localização e caracterização da área de estudo.....	70
5.4.2 Distribuição, coleta dos pontos amostrais e geração do banco de dados.	70
5.4.3 Análises físicas	71
5.4.5 Geração de funções a partir dos métodos de regressão linear	74
5.5. RESULTADOS E DISCUSSÃO.....	76
5.5.1 Elaboração das funções de pedotransferência	76
5.5.2 Função de pedotransferência para estimar os valores da capacidade de campo, retenção da água a 80kPa e ponto de murcha permanente para profundidade de 00 a 0,30 m.	83
5.5.3 Validação da função a partir de dados externos	90
5.6 CONCLUSÕES.....	94
6. CONCLUSÕES GERAIS	95
7. REFERÊNCIAS BIBLIOGRÁFICAS	96

1. INTRODUÇÃO GERAL

A capacidade de geração de dados das características dos solos, das culturas, da produção agrícola, da água no solo, entre outros atributos, aumentou nos últimos anos. Tecnologias que determinam a produtividade da cultura durante a colheita, máquinas que aplicam fertilizantes a taxas variadas, rede de sensores proximais, sensoriamento remoto são algumas das tecnologias que tem ajudado a ciência na geração de dados. Boa parte destas tecnologias usa como informação a posição do ponto amostral. Portanto, esses dados agora estão sendo trabalhados a partir de sistemas de informação geográficas contribuindo com a espacialização, podendo gerar mapas temáticos. Alguns atributos do solo variam de um local para outro com algum grau de organização, ou seja, exibe uma continuidade no espaço e podem ser estimados com base nas características dos pontos vizinhos.

O advento destas tecnologias faz com que a ciência também utilize metodologias de análise de dados que considerem a posição amostral. Segundo Nielsen et al. (1999), o uso da estatística clássica para relacionar e explicar fenômenos neste tipo de abordagem tem levado a resultados pobres. Segundo os autores, isso pode ser explicado pelo fato da função resposta de determinada variável não ser constante e nem consistente ao longo de uma área agrícola. A função resposta é variável devido ao que os autores denominam de “*underlying processes*”, ou seja, outros processos no solo que estão ocorrendo ao mesmo tempo da variável estudada interferindo no resultado final.

Dentre estas metodologias de análise, a semivariância pode ser utilizada para se estudar o comportamento de um atributo no espaço e analisar se o mesmo apresenta dependência espacial, ou seja, a sua distribuição no espaço não é aleatória. Havendo dependência espacial, o atributo poderá ser estimado nos locais não amostrados pelo método da krigagem. Além disso, através do cálculo da semivariância cruzada, é possível analisar se duas variáveis apresentam comportamento de correlação no espaço, avalia-se o grau de semelhança de variação de duas variáveis no espaço. Caso isso ocorra, a distribuição espacial de uma variável poderá ser explicada pela outra. Exemplo disso pode ser a variação do teor de areia com a infiltração de água no solo, ou a variação da areia com o teor de carbono.

A análise espectral examina séries de dados e determina quais frequências de ondas que mais contribuem para o total da variância contribuindo na determinação de padrões cíclicos ao longo do espaço ou do tempo. Também é utilizada para discernir processos em diferentes escalas nas pesquisas em solo, podendo ser utilizada para relacionar processos que estão ocorrendo na mesma frequência.

A análise “*state space*” tem sido utilizada para gerar modelos capazes de descrever processos ao longo da paisagem e com base nos valores prévios observados de determinada variável, ser capaz de prever o comportamento desta ou de outra variável no tempo ou no espaço. Sendo usada como um interpolador.

A análise do padrão temporal da distribuição espacial contribui para estudar se em um conjunto de pontos ocorre a estabilidade temporal de uma série espacial. Por exemplo, um dado local no campo tenderá a possuir uma quantidade de água que permanecerá na mesma posição do ranque ao longo do tempo. Ou seja, analisa se um ponto que apresentou a maior quantidade de água em um determinado tempo t_1 manteria a mesma posição de ser o ponto mais úmido no ranque em um tempo t_2 . Outro exemplo seria, avaliar se um determinado ponto apresentou umidade referente ao valor médio no tempo t_1 continuaria representando o valor médio da umidade no tempo t_2, t_3, \dots, t_n .

Apesar dos avanços nas metodologias de medição e na ampliação do acesso aos equipamentos, a caracterização das propriedades hidráulicas dos solos é relativamente lenta, as amostragens são trabalhosas, consomem muito tempo e, portanto possuem um elevado custo. As “*funções de pedotransferência*” foram estudadas no intuito de transformar dados que possuímos em dados que necessitamos. A junção destas funções, junto com as análises descritas anteriormente é importante ferramenta para a ciência do solo.

Neste sentido, este trabalho aplicou estas análises no estudo dos atributos dos solos. No capítulo I, a estabilidade temporal da distribuição espacial da umidade do solo foi avaliada. No capítulo II, a distribuição espacial do carbono do solo foi avaliada através das técnicas estatísticas que consideram a posição espacial, como a semivariância, a análise espectral e a “state space analysis”. No capítulo III, funções de pedotransferência foram desenvolvidas para contribuir na estimativa da retenção de água do solo para a capacidade de campo, retenção a 80 kPa e ponto de murcha permanente.

2. REVISÃO DE LITERATURA

A necessidade de aumentar a eficiência do uso dos recursos naturais na agricultura tem levado os pesquisadores da Ciência do Solo a considerar a importância da variabilidade espacial no planejamento do manejo do solo. Tecnologias que consideram a importância da variabilidade espacial e temporal estão sendo desenvolvidas no intuito de ajudar os agricultores a manejar os solos de acordo com as necessidades e deficiências regionalizadas (Nielsen et al., 1999). Além disso, pesquisadores têm utilizado de ferramentas estatísticas que consideram a importância do conhecimento da posição espacial do ponto amostral na área de estudo, para explicar a distribuição de determinado atributo do solo na paisagem ou explicar o comportamento de determinado fenômeno de acordo com o tratamento aplicado (Morkoc et al., 1985; Timm et al., 2000; Wendroth et al., 2011; Yang e Wendroth, 2014).

A dificuldade e os custos para a geração de dados têm levado os pesquisadores a desenvolverem modelos matemáticos, ou também conhecido por métodos indiretos, para estimarem propriedades hidráulicas dos solos a partir de características dos solos mais rotineiramente medidas (Wosten et al., 2001).

2.1. Caracterização do Meio Físico da Área de Estudo e Posição na Topossequência das Coletas de Dados

A área de estudo está localizada na Baixada Fluminense, no município de Seropédica, RJ. O clima é classificado como Aw (classificação de Koppen) caracterizado pelas altas temperaturas e chuvas durante o verão e por temperaturas medianas durante o inverno, com média anual de 24,5°C.

O relevo é caracterizado pela ocorrência de pequenas colinas intercaladas com planícies (Embrapa, 1999). A topossequência encontrada nas encostas do município segue um padrão bem definido. Segundo Embrapa (1999), Silva et al. (2001), Ceddia et al. (2009) na parte mais baixa da paisagem os solos encontrados foram classificados como associação de Gleissolo e Cambissolo, sendo que na maioria das vezes esses solos são mal drenados, apresentando estrutura maciça (Figura 1). No terço inferior e médio são encontrados solos classificados como Planossolo, sendo estes com granulometria predominantemente arenosa. Na parte superior da paisagem encontram-se os solos classificados como Argissolos, com maior presença de argila em sua textura.

As amostras coletadas referentes ao Capítulo I estão situadas no terço inferior da paisagem, ou seja, nos Planossolos. As amostras do Capítulo II foram coletadas na parte baixa da paisagem e na transição da parte baixa com o terço inferior. As amostras dos capítulos I e II foram realizadas nos solos do Sistema Integrado de Produção Agroecológica (SIPA). As amostras do Capítulo III foram coletadas em toda a topossequência encontrada na região de Seropédica, RJ. As amostras do Capítulo III foram coletadas dentro do SIPA e nos solos da Universidade Federal Rural do Rio de Janeiro, representando uma maior abrangência geográfica.

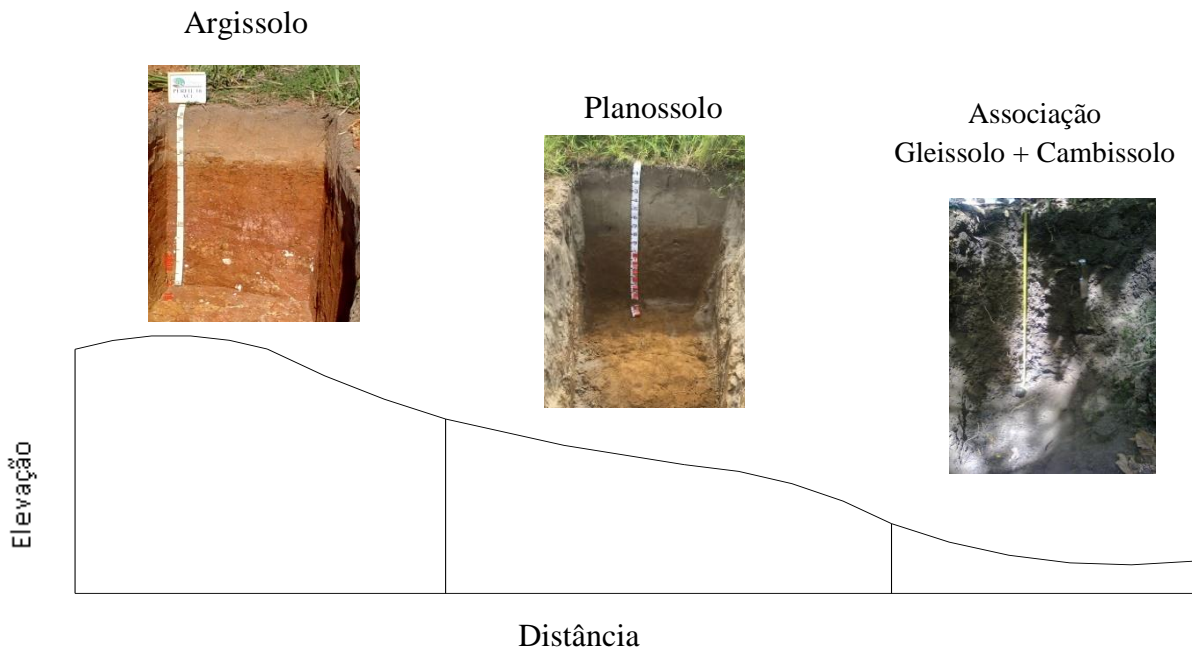


Figura 1. Toposequência dos solos de Seropédica, RJ.

2.2. Abordagens Espaciais e Temporais

As análises de dados tradicionais utilizadas nas pesquisas agropecuárias na maioria das vezes se limitam aos desenhos aleatórios a fim de estudar o efeito dos tratamentos sobre o manejo das culturas, sobre os solos, etc. As áreas dos tratamentos são estabelecidas com objetivo de torná-las as mais homogêneas possíveis evitando assim a influência da variabilidade espacial (Nielsen et al., 1999). Assume-se que as observações são independentes umas das outras. Entretanto, nem sempre as propriedades dos solos são aleatoriamente distribuídas ao longo da área, podendo apresentar estrutura espacial. Geralmente, amostras coletadas próximas uma das outras são mais similares (Nielsen e Wendroth, 2003). Neste estudo, duas abordagens sobre a análise da dependência espacial serão trabalhadas, o autocorrelograma e o semivariograma.

2.2.1 Autocorrelação e correlação cruzada

A medida do comprimento da associação linear entre pares de observações (autocorrelação) é útil para definir a relação espacial entre os pontos observados, em outras palavras, a distância espacial em que há relação entre os valores observados. Segundo Nielsen et al. (1997), o conceito de dependência ou autocorrelação é útil para responder as seguintes questões: “*How far apart should observations be taken, how large an area is represented by a single observation, or what size of observation is most appropriate?*” O autocorrelograma é a representação gráfica dos valores de autocorrelação versus distância entre os pares de medidas (Figura 1). No autocorrelograma observam-se os valores de autocorrelação no eixo y à medida que a distância entre os pares de observações vão aumentando. No eixo x observa-se a distância entre os pares de dados. Os valores de autocorrelação diminuem na medida em que a distância entre os pares de observações aumentam. Isso significa que a relação espacial diminui com o aumento da distância. As observações estão relacionadas umas as outras até a distância entre as observações, não possuem unidade, ou seja, se os passos representam um metro, a distância de correlação é de 3 metros.




Figura 2. Exemplo de autocorrelograma

Considerando um conjunto de observações da propriedade A de determinado solo, coletadas no intervalo de 1 metro em um transecto. Obtém-se o valor do atributo A na posição x_1 , designado como $A_1(x_1)$, $A_2(x_2)$, ..., $A_n(x_n)$. O coeficiente de autocorrelação para os pares de dados separados pela distância h é calculado a partir da equação 1:

$$r(h) = \frac{cov[A_i(x), A_i(x+h)]}{\sqrt{var[A_i(x)]} \sqrt{var[A_i(x+h)]}} \quad (1)$$

onde, cov e var são covariância e variância, respectivamente.

A distância entre os vizinhos h é chamada de Lag. A distância na qual a correlação é significativa é denominada de comprimento de autocorrelação, alcance. O intervalo de confiança (IC) é calculado para determinar se os valores de autocorrelação são significantes. Uma maneira de se calcular o IC é utilizando a equação abaixo, onde, “p” é a probabilidade acumulativa (ex. 1,96 para 95% de probabilidade) para o desvio padrão normalizado, e “n” é o número de observações (equação 2):

$$IC = \pm \frac{p}{\sqrt{n}} \quad (2)$$

A relação espacial entre dois atributos do solo é determinada a partir dos valores de correlação cruzada. A análise da correlação cruzada revela em qual distância ou em que tempo, as medida estão relacionadas umas as outras, considerando suas posições no espaço ou no tempo. A associação linear entre dois pares de observações de duas variáveis é calculada a partir da seguinte equação (3):

$$r(h) = \frac{cov[A_i(x), B_i(x+h)]}{\sqrt{var[A_i(x)]} \sqrt{var[B_i(x+h)]}} \quad (3)$$

O correlograma cruzado é a representação gráfica dos valores da correlação cruzada versus a distância de observação. No correlograma cruzado observam-se os valores da correlação cruzada no eixo y, a medida que a distância entre os pares de observações vão aumentando. No eixo x observa-se a distância entre os pares de dados. A distância na qual a correlação cruzada é significativa é denominada de comprimento de correlação, alcance (Figura 3). Relações positivas apresentam valores positivos de correlação cruzada e relações negativas apresentam valores negativos de correlação cruzada. No passo zero o valor da correlação cruzada expressa a análise de correlação de Pearson.

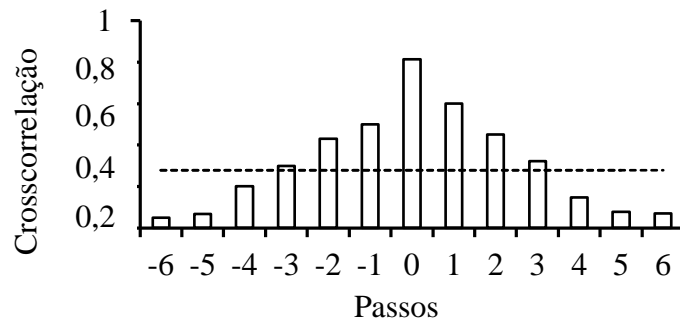


Figura 3. Exemplo de correlograma cruzado.

2.2.2 Semivariogramas e semivariogramas cruzados

Outra maneira de determinar a estrutura espacial das observações é calculada a partir da análise dos valores da *semivariância*. A análise através da função espacial de autocovariância para um conjunto de observações contribui na quantificação se o processo espacial dos atributos estudados é estruturado ou aleatório (Wendroth et al., 2011). A função espacial de autocovariância tem sido relacionada ao semivariograma (Olea, 1991). Os valores obtidos pelo cálculo da semivariância, quando plotados no semivariograma, manifestam se o conjunto de dados apresenta estrutura espacial. O semivariograma é uma importante ferramenta para análise do comportamento da semivariância ao longo do espaço, sendo uma importante ferramenta para identificar processos que estão ocorrendo nas paisagens (Webster e Oliver, 2001). Caso uma variável apresente um padrão cíclico no espaço, os valores de semivariância aumentarão e diminuirão com a distância. Repetidas oscilações nos valores dos semivariogramas ou nos valores da autocorrelação, indicam que o conjunto de dados apresenta um padrão de comportamento cíclico (Wendroth et al., 2011). A semivariância é calculada a partir da seguinte equação:

$$\gamma(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [A_i(x_i) - A_i(x_i + h)]^2 \quad (4)$$

onde, $A_i(x_i)$ é a medida no ponto i , $A_i(x_i + h)$ é a medida do atributo no ponto i separado pela distância h , N é o número de pares de observações separadas pela distância h .

O semivariograma é a representação gráfica do cálculo da semivariância e sua estrutura é composta pelo efeito pepita (C_0), patamar ($C = C_0 + C_1$), alcance (a). Ao semivariograma experimental calculado a partir das observações, associam-se modelos teóricos de semivariograma, definidos pelo tipo de modelo (linear, esférico, gaussiano, exponencial, potencial) e os parâmetros numéricos efeito pepita, patamar e alcance (Figura 4).

O efeito pepita revela a descontinuidade do semivariograma para distâncias menores do que a menor distância entre as amostras. O efeito pepita é causado por variabilidade em pequena escala, por erro de amostragem, de determinação, ou do limite do equipamento. O patamar é aproximadamente igual à variância dos dados. O alcance refere-se à distância na qual $\gamma(h)$ atinge o patamar e representa a distância limite de dependência espacial. Dentro dos limites do alcance, as medições são correlacionadas umas às outras, o que permite que se façam interpolações para espaçamentos menores do que os amostrados. Devido a isso, o alcance é utilizado para avaliar o grau de continuidade espacial dos dados. Além do alcance, as medições apresentam distribuição espacial aleatória e podem ser consideradas independentes entre si e a estatística clássica pode ser aplicada sem restrições.

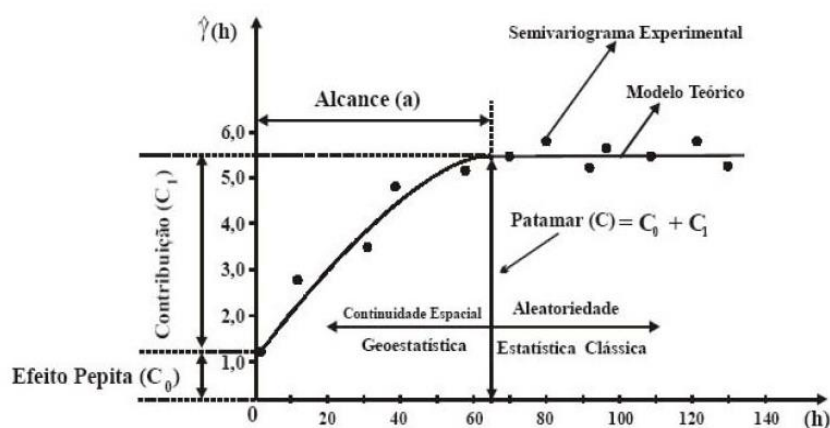


Figura 4. Semivariograma experimental, modelo teórico e seus componentes (Silva, 2007).

A análise da correlação espacial entre duas variáveis pode ser determinada a partir do cálculo dos semivariogramas cruzados. Os quais ilustram a relação espacial entre duas variáveis quando a distância entre os pontos analisados aumentam. Os semivariogramas cruzados (equação 5) são determinados a partir da seguinte equação (Yates and Warrick, 2002):

$$\hat{\gamma}(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} \{A_i(x_i) - A_i(x_i + h)\} \{B_i(x_i) - B_i(x_i + h)\} \quad (5)$$

onde, A_i é a variável A no ponto i , $A_i(x_i + h)$ é a variável A na distância $i + h$, e B_i é a variável B no ponto i , $B_i(x_i + h)$ é a variável B na distância $i + h$, N é o número de pares de observações.

Similarmente ao semivariograma, o semivariograma cruzado é a expressão gráfica do cálculo da semivariância cruzada. Como no correlograma cruzado, os valores dos semivariogramas cruzados podem ser positivos ou negativos em função da relação entre os dois atributos.

2.2.3 Análise espectral

Segundo Nielsen e Wendroth (2003), a análise espectral é utilizada para reconhecer padrões cíclicos observados nas propriedades dos solos e em comunidades de plantas que foram observadas em intervalos regulares ao longo do espaço ou do tempo. A análise espectral examina séries de dados e determina quais frequências de ondas que mais contribuem para o total da variância, assumindo um determinado valor ou média da variável observada (Nielsen, 1989). A análise manifesta a contribuição das oscilações em um pico em determinado período (λ) ou o inverso a frequência (f). Sendo que $\lambda = 1/f$. Considerando que certos atributos do solo comportam-se com padrões cíclicos conforme descrito pela figura 4a, sendo um atributo variando na escala 1 (y_1) e outro na escala 2 (y_2). A adição das oscilações y_1 e y_2 gerou a oscilação referente a figura 5b. A análise espectral do processo y_1 resulta na figura 5c, onde o pico existente representa a variação na escala 1, observado na figura 5a. A contribuição das escalas 1 e 2 na formação da oscilação da figura 5b pode ser discernida pela análise espectral representada pela figura 5d.




Figura 5. Processos espaciais cíclicos variando na escala y_1 e y_2 (a), soma dos processos y_1 e y_2 gerando y_3 (b), análise espectral para o processo y_1 (c), análise espectral para y_3 (d) (adaptado de Wendroth et al., 2011).

Bazza, Shumway e Nielsen (1988), Kachanoski e de Jong (1988) foram um dos primeiros cientistas do solo a usarem a análise espectral para discernir processos em

diferentes escalas nas pesquisas em solo. Mais recentemente alguns trabalhos têm utilizado da análise espectral para estudar os processos nos solos. Sen (2009) analisou as flutuações no tempo dos fluxos dos rios a partir das análises espectrais. Si e Zeleke (2005) investigaram através desta análise a relação entre as propriedades hidráulicas saturadas e as propriedades físicas dos solos. Wendroth et al. (2011) instalou um experimento para estudar a movimentação de solutos nos solos em escala de campo e usou da análise espectral para analisar a influência do solo e dos tratamentos sobre essa movimentação. Schwen et al. (2012) e Yang et al. (2013) também estudaram a movimentação do brometo em solos em escala de campo, porém sob diferentes condições de manejo de solo. Ding et al (2013) estudaram em quais escalas a evapotranspiração e os fatores que a controla em diferentes ecossistemas. Esta análise mostra-se promissora para o estudo das características agrícolas e ambientais que possuem o comportamento cíclico. Além disso, parece ser promissora nos estudos com tratamentos.

2.2.4 Análise “State space”

A produtividade das culturas e as propriedades dos solos variam ao longo do espaço, sendo possível a sua descrição por sistemas autoregressivos multivariados a partir da análise “state space” (Wendroth et al., 1992). A análise “state space” foi introduzida por Kalman (1960) e Kalman e Bucy (1961) com o objetivo de filtrar dados erráticos em conjunto de dados elétricos com o objetivo de extrair sinais mais claros a fim de prever os sinais futuros baseados nos dados históricos. A análise “state space” foi utilizada por Shumway e Stoffer (1982) para “homogeneizar”, “suavizar” e prever séries econômicas observadas no tempo. Na ciência do solo, essa abordagem foi utilizada por diversos autores, destacando Morkoc et al. (1985), Nielsen e Alemi (1989), Wendroth et al. (1992), além de outros autores e trabalhos. No Brasil, podemos citar os trabalhos de Dourado Neto (1999), Timm et al (2000), Timm et al. (2003), Timm et al. (2004) e mais recentemente os trabalhos de Aquino et al. (2015) e Awe et al. (2015).

Na análise “state space”, considera-se que o dado medido, ou um conjunto de variáveis medidas em um local i , pode estar relacionado ao dado, ou conjunto de variáveis medidas no local $i-h$, onde a distância $h = 1, 2, 3, \dots$. Esta distância de relação pode ser quantificada pelos valores calculados da autocorrelação ou pela correlação cruzada, conforme discutido anteriormente. O comportamento de uma variável situada na posição i pode ser explicado pelo comportamento da mesma variável ou de um conjunto de variáveis situadas na posição $i-1$. Segundo Nielsen e Wendroth (2003), a análise “state space” pode ser utilizada como um método de interpolação, como a krigagem e a co-krigagem no domínio do espaço e do tempo. Além disso, esta análise pode ser utilizada para prever pontos dos atributos que estão fora do domínio de dados utilizados para geração do modelo. No domínio do tempo, ele pode ser utilizado para predição de eventos futuros.

Durante o trabalho com o conjunto de dados para a geração dos modelos considera-se a existência de dois tipos de erros. O primeiro vem do erro relacionado à observação. A origem deste erro pode estar relacionada ao equipamento, ao método de análise do solo, à coleta, ao domínio da amostra. O segundo erro está relacionado ao modelo. A observação da variável é uma estimativa do valor verdadeiro. A análise consiste de uma equação de observação e uma equação de estado. A equação de observação pode ser descrita por:

$$Y_i = M_i Z_i + v_i \quad (6)$$

onde, o vetor observado Y_i está relacionado ao vetor de estado Z_i ou desenho matricial M_i e não correlacionado e normalmente distribuído vetor do erro com média zero v_i (Shumway, 1988). A medida não necessariamente tem de ser levada como totalmente verdade, mas considerada como uma medida indireta (Nielsen e Wendroth, 2003).

A equação de estado, comumente usada no modelo “state space” de primeira ordem, considera o estado da variável ou um conjunto de variáveis na posição i com respeito ao estado da variável no local $i-1$ (Shumway, 1988).

$$Z_i = \phi Z_{i-1} + w_i \quad (7)$$

em que, Z_i é o vetor de estado de um conjunto de p variáveis na posição i , ϕ matriz de transição do coeficiente de estado e w_i é o erro não correlacionado com média zero.

2.2.5 Funções de pedotransferência para determinação da retenção da água no solo

A capacidade de retenção da água é uma importante característica dos solos e ela é fortemente determinada pela distribuição dos poros dos solos, que por sua vez é influenciada pelo manejo do solo. A retenção da água no solo é influenciada fundamentalmente pelos processos de *capilaridade* (fenômeno relacionado aos poros) e pela *adsorção* (relação entre a água e as superfícies das partículas do solo). Ambas as forças explicam a retenção e controlam o movimento da água no solo. A curva que caracteriza a retenção de água no solo é definida como a relação entre volume de água retido e a energia potencial (Wosten e Van Genuchten, 1988).

O conhecimento da quantidade de água retida em determinado potencial é importante para auxiliar o manejo da água. A frequência e a quantidade de água a ser aplicada nos sistemas de irrigação dependem fundamentalmente do volume de água armazenada no solo. A água disponível (AD) representa o volume de água que um solo poderia reter entre a “capacidade de campo” (CC) e o “ponto de murcha permanente” (PMP) (Reichardt, 1990, Bernardo et al., 2006). Este cálculo, embora antigo, é usado até os dias de hoje, principalmente em projetos de irrigação, onde é necessário estimar a lâmina de água armazenada no solo e a quantidade a ser irrigada para se restabelecer a capacidade de campo. Porém, este conceito ainda é motivo de controvérsias, pois a água armazenada neste intervalo não está disponível para as plantas da mesma maneira. Pode ocorrer que parte da água esteja armazenada em determinada tensão em que esta água não esteja disponível às plantas. Assim, a planta apresentará estresse hídrico (Cassel & Nielsen, 1986).

A partir da introdução de novos conceitos relacionando o potencial total da água do solo, condutividade hidráulica e fluxo no solo e na planta, tornou-se claro que a interação solo-planta é dinâmica e que os conceitos estáticos de PMP, AD, CC, não se adaptam ao verdadeiro comportamento da água no solo. Mesmo considerando estes novos conceitos, não se alterou o valor quantitativo da água disponível no solo, mas entendeu-se que a disponibilidade da água do solo não era determinada exclusivamente por propriedades do solo e sim outros fatores como as características da planta e do ambiente. Surgia então o conceito de sistema Solo-Planta-Atmosfera. Esta abordagem considera a relação entre estes três componentes como algo contínuo. Assim, a disponibilidade de água para as plantas considera que o movimento da água à atmosfera, através das plantas, se dá em resposta ao gradiente de potencial, o qual decresce quando passa do solo para a planta e por fim para a atmosfera. Desta forma, o fluxo de água ocorre em um sistema solo-planta-atmosfera contínuo e dinâmico, governado por fatores do solo, da planta e da atmosfera. Assim, pode-se constatar

que o modelo estático baseado nos conceitos de CC, PMP e AD, é uma simplificação dos fatores envolvidos no processo de captação de água pelas plantas.

Portanto, a caracterização da retenção de água por determinado solo é muito importante para o planejamento da irrigação, para o manejo da água nos sistemas agrícolas e no zoneamento de culturas. Para melhorar a eficiência do uso dos recursos hídricos é fundamental a adoção de sistemas de irrigação mais eficazes na aplicação da lâmina de água, além do conhecimento das propriedades físico hídricas dos solos agrícolas e da agrometeorologia (Carvalho e Oliveira, 2012). Além disso, o conhecimento sobre a variabilidade espacial da retenção da água dos solos também pode auxiliar na eficiência do uso da água. A variabilidade espacial da água no solo possui um comportamento complexo que inclui aspectos de organização e aleatoriedade, e esta é resultado da distribuição espacial das propriedades dos solos, topografia, evapotranspiração (Merz and Plate, 1997). Para Longshamps et al. (2015) algumas questões são importantes como, a variabilidade espacial da umidade do solo é ou não é significativa; qual o alcance espacial da água disponível e a terceira questão de interesse é o estudo da dinâmica do conteúdo de água no tempo.

Compreendendo a limitação do conceito estático da capacidade de campo (CC), neste estudo adotou-se o critério em que a CC representa a umidade em que a água está retida contra a força da gravidade, tal que a condutividade (movimento da água) torna-se desprezível. Considerou-se o valor de potencial de 10 kPa (100 cm de coluna d'água) como referente para a capacidade de campo. A água facilmente disponível (AFD) foi considerada como a umidade retida a 100kPa (1000cm de coluna d'água). O ponto de murcha permanente (PMP) foi considerado como a quantidade de água retida a 1500 kPa.

Apesar dos avanços nas metodologias de medição e na ampliação do acesso aos equipamentos, a caracterização das propriedades hidráulicas dos solos é relativamente lenta, as amostragens são trabalhosas, consomem muito tempo e, portanto possuem um elevado custo. Por isso, cientistas ligados à ciência dos solos estudaram métodos matemáticos com a finalidade de desenvolver modelos para prever as propriedades hídricas dos solos. As funções elaboradas, ou mais especificamente, as “*funções de pedotransferência*” (FPT) (Bouma, 1989) foram muito estudadas pelos cientistas dos solos nos últimos anos podendo ser descrita como “funções preditivas que transformam os *dados que possuímos* em *dados que precisamos*”. As funções de pedotransferência são expressões matemáticas que estimam propriedades dos solos mais difíceis de medir a partir de propriedades dos solos mais fáceis ou que são mais regularmente medidas (McBratney et al., 2002). A revisão de literatura sobre funções de pedotransferência destinada ao trópico úmido elaborada por Botula et al. (2014) relata que a distribuição das partículas (areia, silte, argila) é o preditor mais utilizado, ocorrendo em 100% das funções estudadas. O conteúdo de matéria orgânica ou carbono orgânico foi utilizado em 54,8% e a densidade do solo em 38,7% das funções estudadas. Segundo Minasny e Hartemink (2011) as funções devem ser elaboradas com a finalidade de prever algo mais difícil de medir a partir de algum atributo do solo mais fácil de medir.

Apesar da importância do tema, pode-se considerar que os estudos sobre as funções de pedotransferência estão mais avançados para os solos situados nas áreas de clima temperado do que os solos tropicais. Segundo Schaap (2005) e Botula et al. (2014) os estudos sobre os métodos indiretos de geração de dados sobre as características hidráulicas dos solos tropicais ainda são muito incipientes. Portanto, este tema ainda possui grande relevância para os solos situados nos trópicos, já que os estudos sobre funções de pedotransferência são poucos e a base de dados sobre as características hidráulicas destes solos ainda são limitadas. O uso de funções de pedotransferência, elaboradas a partir de um banco dados de solos situados no clima temperado, com a finalidade de estimar propriedades hídricas nos solos tropicais pode levar a resultados pouco acurados. A razão para isso são as diferenças nas

propriedades físicas encontradas entre estes solos. Diferenças nas características e nas quantidades da argila, quantidade de silte, densidade do solo, diferenças nos valores da capacidade de troca catiônica são algumas características que os solos tropicais diferem dos solos localizados no clima temperado que fazem com que as propriedades hídricas difiram entre os solos (Hodnet e Tomasella, 2002; Minasny e Hartemink, 2011). Barros e van Lier (2014) fizeram uma boa revisão bibliográfica sobre o histórico das funções elaboradas no Brasil.

Grande parte das funções de pedotransferência desenvolvidas para predição das propriedades físico-hídricas dos solos é baseada em modelos de regressão linear ou polinomiais (Vereecken e Herbst, 2004). As regressões múltiplas são ferramentas estatísticas muito frequentes utilizadas na predição de determinada variável resposta (y_i) a partir de um determinado número de atributos preditores (x_i). De maneira geral, as equações de regressão podem ser escritas como:

$$y_i = a + \sum b_i x_i + e \quad (8)$$

onde, “a” é o intercepto, “b” os coeficientes de regressão, “ x_i ” os atributos preditores e “e” o desvio da estimativa. Como as FPT elaboradas a partir de equações são utilizadas para determinar o valor de uma variável dependente, há a necessidade de que ambas as variáveis apresentem correlação.

As análises indicadas para avaliar a correlação entre as variáveis segundo Vereecken e Herbst (2004) são diversas. Gráficos de distribuição, plotando diferentes propriedades de interesse versus a variável resposta são muito úteis para detectar relações e tendências, além de valores extremos. Os gráficos de distribuição também dão a informação com relação ao tipo de correlação e o comportamento que existe entre as variáveis, ou seja, se ela é linear ou não-linear. O teste de correlação de Pearson também é uma ferramenta estatística que pode ser utilizada para apontar as correlações entre as variáveis. Na escolha das variáveis independentes e no processo de geração da função é importante observar: prever algo mais difícil de medir a partir de um banco de propriedades dos solos mais fáceis de medir, usar uma variável independente que tem explicação física com a variável dependente (Minasny e Hartemink, 2011). Após análises de correlação é necessário avaliar a existência de valores discrepantes, ou “outliers”. A escolha de apagar os valores discrepantes deve estar apoiada pela certeza de que as observações estão incorretas Vereecken e Herbst (2004).

Após análise e pré-tratamento dos dados realiza-se a construção do modelo propriamente dito. O passo mais importante é a escolha das variáveis que entrarão na equação. Os modelos de regressão são construídos de maneira interativa, ou seja, a pessoa que está trabalhando o modelo toma decisões durante sua construção. Isto pode ser feito através de um conhecimento prévio ou por análise dos desvios gerados após construção do modelo utilizando técnicas de análise. De maneira geral, os seguintes métodos são utilizados: todos os modelos possíveis, “backward”, “seleção “forward”, método passo a passo. O importante é tomar o cuidado para não eliminar covariáveis que são potenciais preditores das variáveis de interesse. Existem diversos softwares capazes de construir estes modelos, podemos citar dois que são muito utilizados e são livres: o pacote “Action” que trabalha dentro do Excel e o programa “R”.

Considerando a necessidade de avaliar as funções elaboradas, geralmente utiliza-se a metodologia da validação cruzada (“cross validation”). A qual consiste na divisão dos em desenvolvimento e validação. Os dados agrupados no desenvolvimento são utilizados para a geração da função, enquanto os dados agrupados na validação são utilizados para avaliar a capacidade de predição da função.

A confiabilidade de uma função de pedotransferência é avaliada pela comparação entre os dados medidos e os dados preditos a partir de um conjunto de dados distinto dos utilizados na geração da função (Wosten et al., 2001). Dentre as equações existentes para avaliar os valores medidos e preditos, ressaltamos três que usualmente são utilizadas, o erro médio absoluto (Mean Absolut Error – MAE), a raiz do erro quadrático médio (Root Mean Square Error – RMSE) e o coeficiente de determinação (R^2).

$$MAE = \frac{1}{n} \sum_{i=1}^n (P_i - O_i) \quad (9)$$

$$RMSE = \left(\frac{1}{n} \sum_{i=1}^n (P_i - O_i)^2 \right)^{-0,5} \quad (10)$$

onde, n corresponde ao número de observações realizadas, P_i corresponde aos valores estimados a partir das equações e O_i valores observados.

3. CAPÍTULO I

SPATIAL AND TEMPORAL PATTERNS OF SOIL WATER CONTENT IN AN AGROECOLOGICAL PRODUCTION SYSTEM

Document accepted for publication in “Scientia Agricola”.

Neves, H.H., Mata, M.G.F., Guerra, J.G.M., Carvalho, D.F., Wendroth, O., Ceddia, M.B.,
Spatial and temporal patterns of soil water content in an agroecological production system.
Scientia Agricola, 2017. (in press)

3.1 RESUMO

O padrão espacial e temporal do conteúdo de água do solo pode melhorar a compreensão dos processos da água no solo, bem como a melhoria do manejo da água. A distribuição da água no solo depende da variabilidade espacial dos atributos do solo, da vegetação e das características da paisagem. O objetivo deste estudo foi avaliar: i) o padrão da variabilidade espacial e temporal em um sistema agroecológico; ii) entender os fatores que afetam a variabilidade espacial da água no solo; iii) verificar se as zonas úmidas e secas conservam sua posição espacial ao longo do tempo; iv) avaliar a possibilidade do uso desta informação para reduzir o número e a intensidade de amostragem. O experimento foi conduzido em uma área com 2502 m², onde um grid regular com 10 m entre pontos foi instalado. Sensores do tipo “Time Domain Reflectometer” foram instalados em cada ponto nas profundidades de 0,05m, 0,15m e 0,30m para monitorar o conteúdo de água no solo. O monitoramento ocorreu durante 18 dias em 2014 (jan, fev, mar) e durante 9 dias em 2014/2015 (dez e jan). O conteúdo de água no solo, nas três profundidades, seguiu um padrão similar e sistemático, sendo maior em camadas mais profundas. O conteúdo de água no solo apresentou estabilidade temporal e a correlação entre o conteúdo de água no solo e conteúdo de argila variou com a profundidade e com a magnitude do conteúdo de água do solo. Durante a estação úmida é necessário intensificar a densidade de amostragem a fim de estimar o conteúdo médio de água no solo. Durante a estação seca, a correlação de Spearman permaneceu alta indicando a necessidade um menor esforço de amostragem. As zonas secas tenderam a conservar mais a posição espacial quando comparadas com as zonas úmidas.

Palavras chaves: Séries temporais. TDR, Padrão espacial. Padrão temporal. Agroecologia.

3.2 ABSTRACT

Spatial and temporal patterns of soil water content (SWC) can improve the understanding of soil water processes but also the water management along the field. The spatial distribution of SWC depends on the spatial variability of soil attributes, vegetation and landscape features. The aim of this study was to evaluate: i) the spatial and temporal variability pattern in an agroecological system; ii) understand the factors affecting the spatial variations of SWC; iii) find out if wet and dry zones conserve their spatial position; iv) evaluate the possibility to use this information both to reduce the number of SWC measurements. The experiment was carried out in an area of 2502 m², where a regular grid with spacing of 10 meters was laid out. At each point, Time Domain Reflectometer sensors were installed at 0.05, 0.15, 0.30 m depth to monitor the SWC during 18 days in 2014 (jan, feb and mar) and 9 days in 2014/2015 (dec and jan). The Soil Water Content, at the three soil depths, followed a similar and systematic pattern, being highest in the deepest layers. Soil Water Content exhibited temporal stability and the correlation between SWC and clay content varied both with the depth and the magnitude of SWC. During the wet season it is necessary to intensify the sampling density to estimate the SWC. During the dry season the Spearman rank correlation remained high indicating a small sampling effort necessary. The driest zones tend to conserve more their spatial position compared to wettest zones.

Key words: Time series. TDR. Spatial pattern. Temporal pattern. Agroecology.

3.3 INTRODUCTION

The soil water content (SWC) is the main limiting factor for plant growth (Letey, 1985) and the knowledge about the spatial and the temporal variability of soil water in the field is critical to improve the management of water. Soil water content shows a typical spatial pattern over time. This phenomenon is called temporal stability and it is described as the temporal persistence of a spatial pattern. Based on the temporal stability it would be possible to reduce the number and the frequency of observations in time to monitor the SWC (Vachaud et al., 1985).

This methodology is used to understand the soil water dynamics at the field scale (Kachanoski and de Jong, 1988; Pachepsky et al., 2005; Wang et al., 2013). The idea is to determine which points represent the mean of SWC and which other points represent one or two standard deviation from the mean (Vachaud et al., 1985). Measuring SWC at these points would allow to estimate the mean of SWC and the magnitude of its variance. Sensors located at these strategic points could be used to manage the soil water (Van Pelt and Wierenga, 2001; Starr, 2005).

The spatial distribution of SWC is expected to be related with soil texture (Hu et al., 2008; da Silva et al., 2001; Greminger et al., 1985), soil organic carbon (da Silva et al., 2001), landscape features (Western et al., 1999; Hu et al., 2008; Ceddia et al., 2009) and vegetation (Reynolds, 1970). However, the spatial correlation between SWC, soil physical properties and landscape changes over time. The reason for these changes is associated with the magnitude of SWC and its variance and depends on whether the soil is in a drying or wetting phase (Kachanoski and de Jong, 1988; Wendroth et al., 1999).

Despite the efforts to understand the spatial and temporal variability of SWC, some questions remain. In some studies SWC was monitored only for one season (Hupet and Vanclooster, 2002; Hu et al., 2010; de Souza et al., 2011). However, as the field conditions changes along the time and space, it is not well known whether spatial pattern remains the same over time.

Considering the importance of the spatial and temporal variability on the soil water, the aims of this study were: i) improve the understanding about the factors affecting the spatial variability of SWC; ii) evaluate if the spatial variability of SWC persists along the time; iii) evaluate the possibility to use the spatial and temporal stability of SWC both to reduce the number of SWC sensors in the field and to increase the intervals of measurements.

3.4 MATERIAL AND METHODS

3.4.1 The study site, experimental layout, soil analysis and soil water monitoring

The experiment was carried out at the Integrated System of Agroecological Production (ISAP), which is located at the municipality of Seropédica-Rio de Janeiro State/Brazil (Figure 1). The climate of the region is classified as Aw (Köppen classification system), with the domain of high temperatures in the summer and mild in the winter, annual average of 24.5°C, with rainfall concentrated from November to March, with annual average of 1213 mm. The crop year is divided into two seasons, one beginning in October lasting until March, when corn is grown and the other from April until September, when vegetables are grown. At the beginning of the year, the soil is plowed at 0.20 m depth and beds (1.1 m width) are formed which stay for the entire year and are the same for all crops.

An area of 2502 m² was cultivated with corn, where a regular square grid with 10 meter spacing was installed. Considering this layout, the experiment consisted of 30 sampling locations (Figure 1). For each of the 30 sampling location UTM coordinates were measured using a GPS with differential correction (GPS TRIMBLE PRO XP). Soil samples were collected for soil texture analysis at depths of 0.05, 0.15, and 0.30 m. Soil textural composition was quantified using the sieving and pipette method (Embrapa, 1997). Besides, in each point and at the same soil depth, a total of 90 soil sensors were installed, parallel to the soil surface, and the dielectric constant (Ka) was monitored using a time domain reflectometry (TDR100 Campbell Sci.). The volumetric soil water content (SWC) was calculated (cm³ cm⁻³) using the Topp equation (Topp et al., 1980). The soil water content was measured on 18 days during the first year (15, 16, 17, 19, 20, 22, 23, 24, 26 January; 11, 12, 14, 16, 21, 22, 24, 27 February; 3 March 2014) and on 9 days during the second year (15, 16, 17, 18 December 2014; 5, 7, 10, 12, 19 January 2015). The sensors were installed in January 2014, remained until March when they were uninstalled for soil tillage. In December 2014 the sensors were reinstalled at the same points. Along the two periods of monitoring, the precipitation was measured hourly by an automated meteorological station located approximately 1000 m from study area.




Figure 1. The study site and the plot layout with regular grid at ISAP, Seropédica-RJ.

3.4.2 Statistical analysis

Descriptive statistics (mean, variance, maximum and minimum value, standard deviation and coefficient of variation) were calculated and used to evaluate the magnitude of data dispersion. Spearman's rank correlation coefficient was calculated with the aim of correlating the soil water content at different times and its relation with other soil properties.

The relative mean difference (δ_{ij}) was calculated and presented graphically in order to show the rank of wettest, driest and mean points in the area for each year. This technique ranks the measurement locations based on the relative difference from the spatial mean (Vachaud et al., 1985). The relative mean difference was calculated by (eq. 1):

$$\delta_{ij} = \frac{\Delta_{ij}}{\bar{s}_j} \quad (1)$$

where Δ_{ij} is calculated by the difference between the measurements in each point (i) at day (j) and the mean measurement for day (j), and \bar{s}_j represents the field mean soil water storage for a particular day (j). For each location, the average and standard deviation of δ_{ij} , were calculated and graphically presented. With this analysis we determined the average, wettest and driest

spots. Whether these locations persist over time or not can be detected by the standard deviation of δ_{ij} . Values of δ_{ij} close to zero mean that their locations present the soil water content similar to the field average. Negative values of δ_{ij} mean that their locations are drier than the field average, while positive values of δ_{ij} mean that their locations are wetter than the field average. Moreover the nonparametric Spearman Rank correlation (r_s – eq. 2) was applied to evaluate the persistence of spatial patterns of soil water content at different times (temporal stability). The Spearman rank correlation was calculated as follows:

$$r_s = 1 - \frac{6 \sum_{i=1}^N (R_{ij} - R_{ij'})^2}{N(N^2 - 1)} \quad (2)$$

where R_{ij} is the rank of observed variable at location i and date j , $R_{ij'}$ is the rank of the same variable, at the same location, but on date j' , and N is the number of observations at a particular time.

Temporal stability implies a relationship between soil water storage at times t_1 and t_2 . A location that is relatively dry at time t_1 compared to other locations will remain relatively dry at time t_2 . The closer value of r_s to 1 more stable is the pattern observed in time. In other words, the rank for soil water content at each day remains similar over time.

The number of soil samples necessary to calculate the mean was determined by equation 3 (Petersen and Calvin, 1982).

$$n = \left(\frac{t * \sigma^2}{D^2} \right) \quad (3)$$

where t is the critical value of “ t ” (student, 5%); σ^2 is the variance and D is a specified limit.

3.3. RESULTS AND DISCUSSION

3.3.1 The soil texture and soil water content across plot

The highest average values of soil water content (SWC) were found at 0.30 m depth followed by the 0.15 m and the 0.05 m depth for both years (Table 1). The 0.30 m soil depth was higher in clay content and water retention capacity (Figure 2). It can explain, in part, the vertical differences in soil water content. On the other hand, the 0.05 and 0.15 m soil depth are more exposed to the evapotranspiration, reducing soil water content. The exposure to evapotranspiration processes can also explain the highest values for the coefficient of variation (CV), causing more rapid temporal changes of SWC at 0.05 and 0.15 m depth (Table 1). As reported by Brocca et al. (2007) and Hu et al. (2008), the CV tended to be higher when the soil water content decreased. Therefore, the soil water content was more homogeneous at the deepest layer (0.30 m) and the temporal dynamic was more evident close to the surface (Hupet and Vanclooster, 2002; Guber et al., 2008).

The SWC, Sd and CV also showed a systematic difference between the two periods of years monitored. The second year presented lower SWC and higher Sd and CV, at the three soil depths, than year 1 (exception only for CV at 0.30 m).

The spatial distribution of sand content at the three soil depths is presented in Figure 2 (a, b and c, respectively). The dominant texture class, at the three sample depths, was sandy and it greatly influenced the other soil attributes, resulting in low water retention and water availability. Sandy soil has higher macropores and lower specific surface area (SA) than clayed soils. The SA and, therefore, the clay content play important roles in the adsorption and desorption of water molecules. SA plays a dominant role for the adsorption of water molecules, i.e., the surface adsorptive forces greatly affect water retention (Petersen et al., 1996).

Table 1. Descriptive statistics for soil water content and texture.

	SWC (cm ³ cm ⁻³)			SWC (cm ³ cm ⁻³)			Sand (g kg ⁻¹)			Clay (g kg ⁻¹)		
	Year 1			Year 2			0.05	0.15	0.30	0.05	0.15	0.30
Mean	0.114	0.165	0.209	0.128	0.148	0.187	873.6	875.3	869.5	73.8	57.1	61.7
Minimum	0.060	0.084	0.147	0.068	0.077	0.131	814.5	822.6	691.8	50.1	23.0	10.0
Maximum	0.172	0.290	0.290	0.219	0.241	0.257	905	904.9	929.8	116.6	104.4	232.6
Sd	0.030	0.037	0.035	0.048	0.064	0.057	28.5	21.7	56.3	21.4	22.6	43.2
CV	28.1	33.2	19.6	37.6	33.2	19.2	3.2	2.4	6.5	29.1	39.6	70.0

SWC_Soil Water Content, Sd_Standard Deviation, CV_Coefficient of Variation

Systematically, and at all soil depths, the bottom part of the plot area had higher sand content than the upper part, mainly when compared to the upper left region (higher clay content). The sand contents at 0.05 and 0.15 m were very similar. The higher standard deviation was found at the 0.30 m depth, at 0.05 m it was slightly larger than at 0.15 m. This may result from the fact that the 0.30 m soil depth is coincident to the upper boundary of a transitional zone to an argillic horizon (B) in this Alfisol. The minimum value of sand content at 0.30 m soil depth confirms this soil characteristic (Table 1).




Figure 2. Contour maps for sand (g kg^{-1}) content 0.05m (a), 0.15m (b), 0.30m (c) and distribution of soil sample points with numbers.

3.3.2 Temporal and spatial variability of SWC and its correlation along the time

The average values of the SWC, considering the 30 monitored points, along the two periods of monitoring and, at the three soil depth, are presented in figure 3a and 3b. In all soil depths, the SWC increased and decreased simultaneously, following a similar pattern of variation. The average values of SWC at 0.30 m soil depth were always higher than at 0.15 and 0.05 m, respectively. In general, the SWC along the second year monitored was lower than the first year.

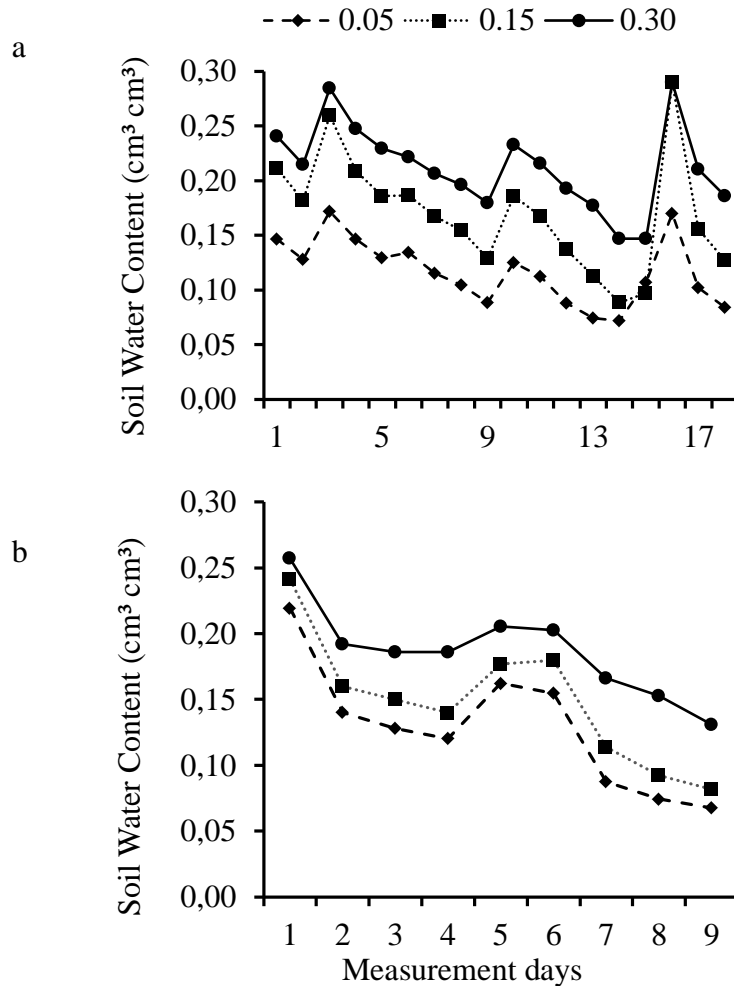


Figure 3. The average of Soil Water Content for each layer, first year (a), second year (b).

During the first year of monitoring (Figure 3a), the fourteenth (03/21/2014) and sixteenth (03/24/2014) sampling days presented the driest and the wettest, respectively. After the fourteenth day of measurement precipitation events occurred, 3.8mm, 10.2mm, 59.6mm and 2mm on following days (Figure 4). It explains the increase of SWC. From the sixteenth to the seventeenth day (03/27/2014), the SWC decreased quickly manifesting how fast is the water dynamics at the soil layer evaluated, which reflected the combined effect of the high sand content and evapotranspiration. Due to the high sand content, high volumes of macropores and low surface area, this soil has low water retention capacity. The macropores can cause rapid water movement (Beven and Germann, 1982). In the fourteenth day the water lamina at the 0 - 0.30m soil layer was 30.7mm. After a rain of 81.2 mm, it reached up to

74.99mm (sixteenth day) and, within an interval of two days (eighteenth day) it decreased to 39mm.

In the second period of SWC monitoring (Figure 3b), the fluctuation of SWC was relatively smaller and on days 1, 5 and 6, the highest soil water contents were observed. Clearly, the precipitation during this year was lower than in the first year which can be seen through the maximum precipitation values. The value of precipitation in the second year reached a maximum of only 11 mm, while in the first year the most part of precipitation's events surpass 11 mm, achieving a maximum of 88.6mm (Figure 4).

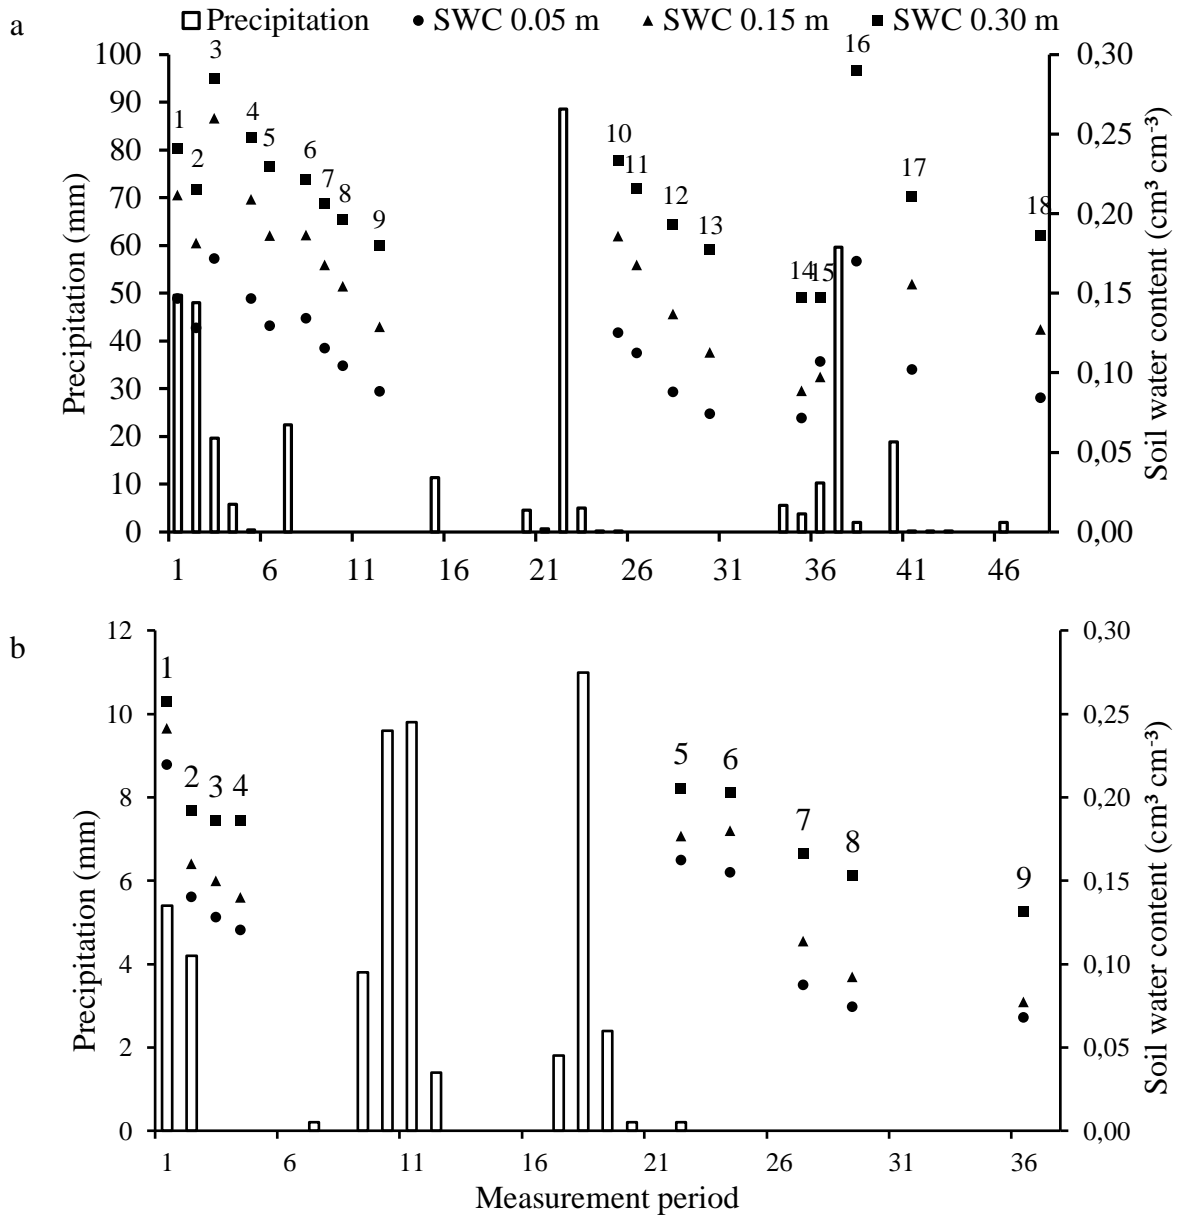


Figure 4. Values of precipitation for whole measurement period, for first (a) and second (b) years. Numbers above of points are respective measurement days of soil water content. Numbers under the “x” axis represents the monitoring period, 46 days for the first year and 36 for the second.

The variance decreased when the soil water content decreased for 0.05m and 0.15m for both year (Figure 5 a, b, d, e). This result implies that the soil water content distribution was more homogeneous under dry conditions. Therefore, the number of soil samples necessary to determine the mean of soil water under dry conditions will be lower than wet conditions (Figure 5 a, b, d, e). For 0.30m this correlation was not clear (Figure 5 c, f).

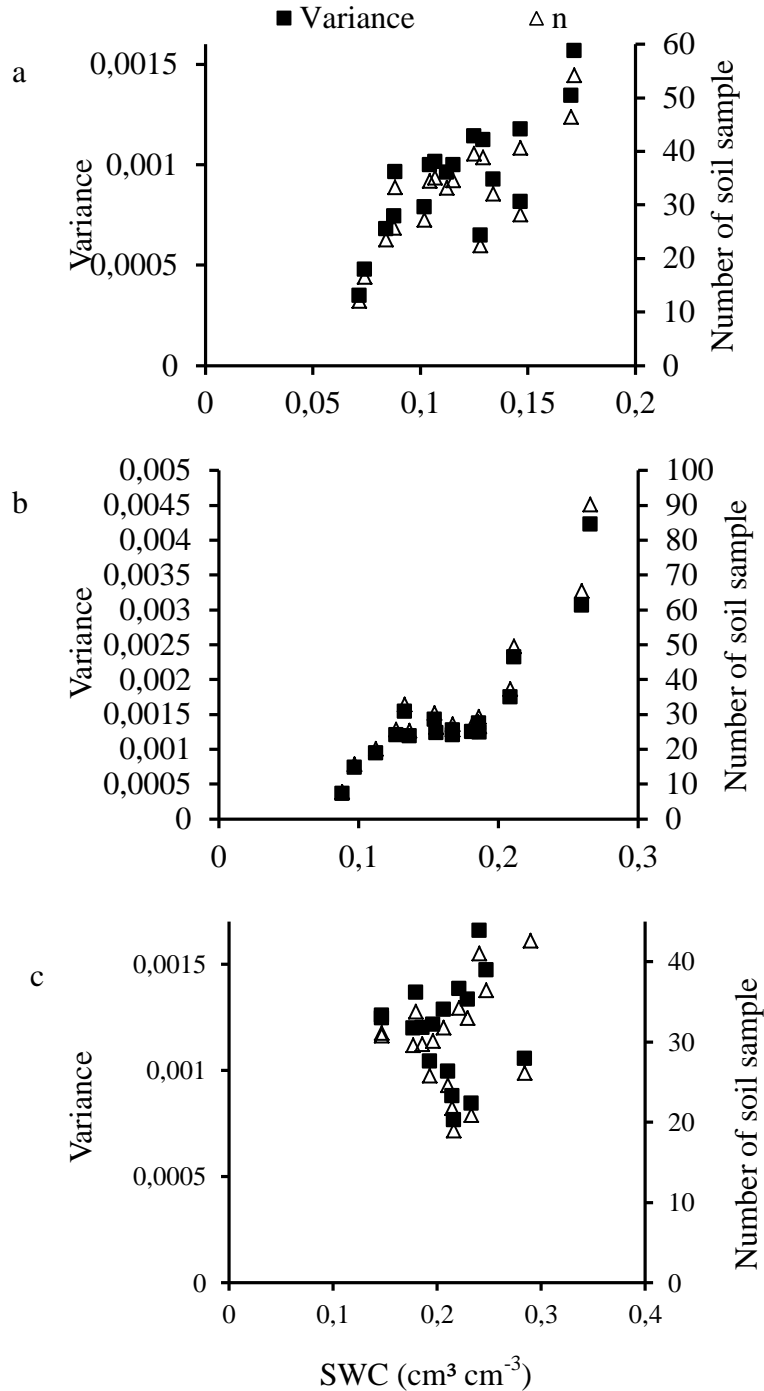
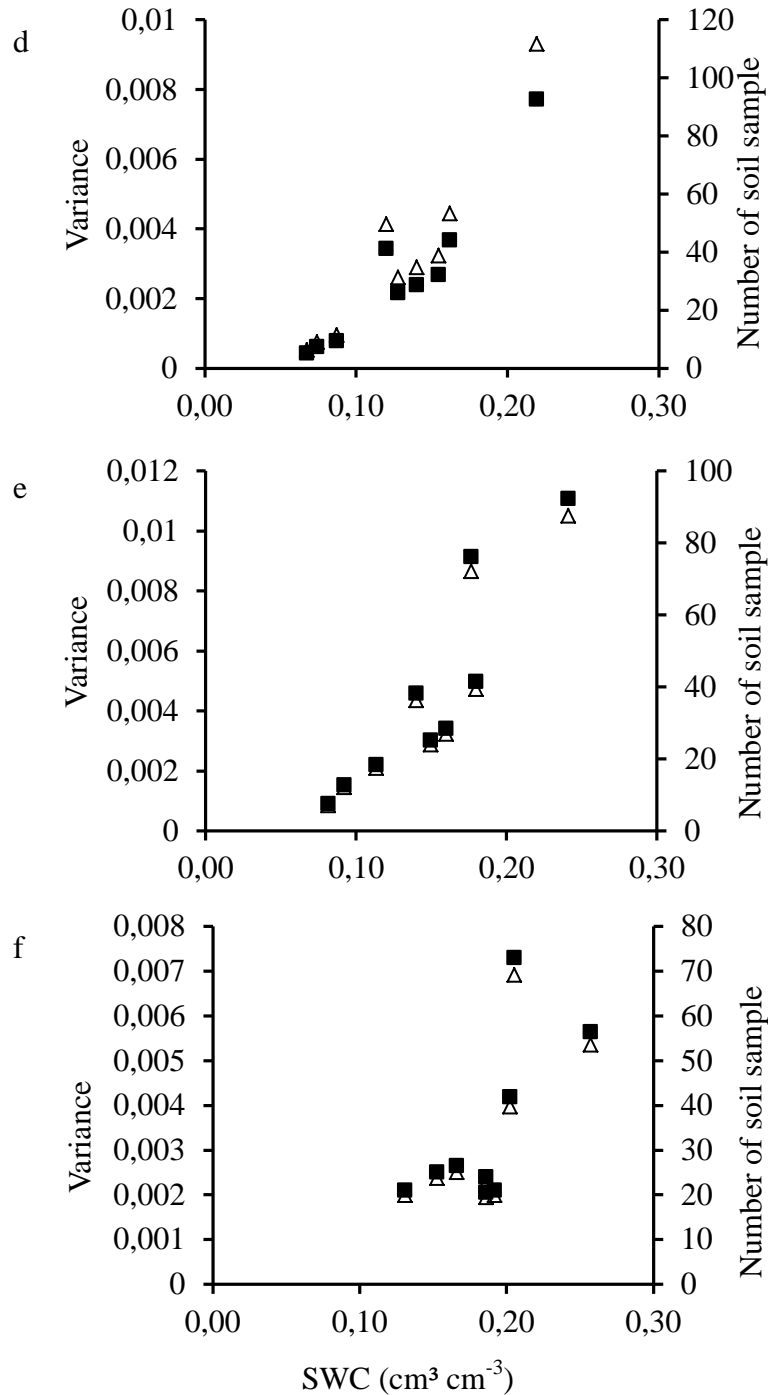


Figure 5. Correlation between soil water content and Variance ; soil water content and number of soil sample (n) during the year 1 (0.05m, a; 0.15m, b; 0.30m, c) and year 2 (0.05m, d; 0.15m, e; 0.30m, f) (continue).

Figure 5. Continuation.



The information about the behavior of the SWC in each of the 30 points monitored during the two years is shown in Figures 6a and 6b (Ranked relative mean difference) and Figure 7a and 7b (wettest, average and driest points). The points were classified as the average, the driest (considering moisture value below of 10% of the mean), and the wettest (considering moisture value above of 10% of the mean) along the study plot. For the first year of monitoring, points 30, 18 and 17 exhibited soil water content 30%, 26% and 21% drier than the average of soil moisture, respectively. On the other hand, points 26, 11, 25 showed 44%, 36% and 21% wetter than the average of soil moisture. At points 8, 1, 5, 7, 20,

22 the soil water content was close to the average value (Figure 6a). Those points close to the average represent the mean of soil water content. In other words, measuring soil water content at these points will provide an idea about the mean soil water content of the area on a particular day.




Figure 6. Ranked mean relative difference (δ_{ij}) for soil water content for first (a) and second year (b).

For the second year, points 18, 8, 17 and 19 exhibited soil water contents 47%, 38%, 31% and 31% drier than the average soil water content, respectively. Points 22, 25, 13, 12 were 62%, 52%, 46% and 36% wetter than the average. At points 6, 14, 28, 10 the soil water contents were close to the average (Figure 6b). Points 18 and 25 remained between the three driest and wettest points for both years. So we can use these points to monitor the driest and wettest values for soil water content, respectively, on any particular day.

In summary the points 18 and 25 show temporal stability and represent the driest and the wettest water content along the study site, respectively. However, the points representing the average soil water content were not the same for the first and the second year. Van Pelt and Wierenga (2001) made comparisons between years and noted that the temporal stability also changed along the years. These authors considered that removal and reinstallation of soil water content sensors could influence the measurements and therefore cause lack of

Table 2. Matrix of Spearman Rank correlation coefficient of soil water storage measurements for 0.00 – 0.30 m during the first year.

	Day 1	Day 2	Day 3	Day 4	Day 5	Day 6	Day 7	Day 8	Day 9	Day10	Day11	Day12	Day13	Day14	Day15	Day16	Day17	Day18	
Day 1	1.00																		
Day 2	0.94	1.00																	
Day 3	0.52	0.60	1.00																
Day 4	0.55	0.70	0.80	1.00															
Day 5	0.56	0.72	0.71	0.98	1.00														
Day 6	0.56	0.73	0.68	0.95	0.97	1.00													
Day 7	0.51	0.70	0.56	0.87	0.92	0.96	1.00												
Day 8	0.46	0.66	0.52	0.84	0.89	0.94	0.98	1.00											
Day 9	0.41	0.60	0.39	0.76	0.81	0.87	0.95	0.97	1.00										
Day10	0.48	0.63	0.80	0.86	0.82	0.83	0.75	0.73	0.66	1.00									
Day11	0.43	0.57	0.70	0.81	0.78	0.80	0.76	0.74	0.69	0.97	1.00								
Day12	0.37	0.51	0.52	0.63	0.62	0.67	0.69	0.70	0.67	0.84	0.91	1.00							
Day13	0.35	0.50	0.47	0.62	0.62	0.64	0.70	0.70	0.71	0.75	0.85	0.92	1.00						
Day14	0.33	0.47	0.36	0.55	0.56	0.64	0.70	0.71	0.74	0.67	0.79	0.86	0.93	1.00					
Day15	0.25	0.35	0.36	0.43	0.42	0.49	0.54	0.54	0.58	0.57	0.69	0.75	0.86	0.93	1.00				
Day16	0.62	0.67	0.80	0.87	0.80	0.77	0.66	0.61	0.51	0.82	0.75	0.53	0.49	0.43	0.33	1.00			
Day17	0.34	0.50	0.65	0.88	0.85	0.84	0.82	0.80	0.74	0.87	0.87	0.73	0.69	0.65	0.54	0.80	1.00		
Day18	0.21	0.37	0.48	0.66	0.63	0.63	0.69	0.66	0.66	0.66	0.71	0.71	0.71	0.68	0.64	0.51	0.82	1.00	

Spearman Rank correlations are significant in bold (alpha 0.05)

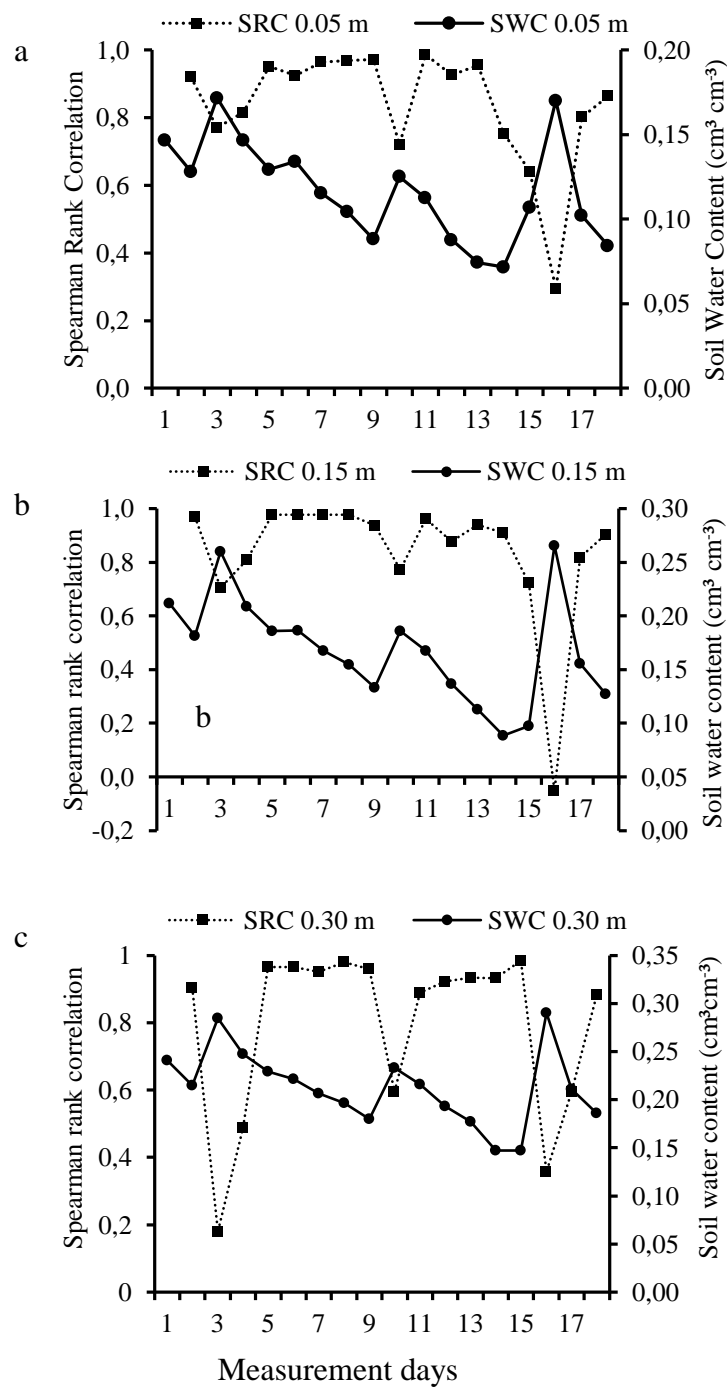



Figure 8. Relationship between soil water content and Spearman's rank correlation for 0.05m (a), 0.15m (b) and 0.30m (c) for first year and 0.05m (d), 0.15m (e) and 0.30m (f) for second year (continue).

Figure 8. Continuation.



The differences of the Spearman rank correlation coefficient between different days, according to the wettest and driest SWC, indicate that the number of soil water samples to monitor changes for different seasons. According to the finding in this study, the dry seasons (from May to August in the study site) will present lowest SWC variation, which means a longer interval with similar spatial patterns of SWC distribution. In this case, the interval between measurements of SWC could be longer and the number of measurements could be lower. In the wettest seasons (September to April), when the precipitation and evapotranspiration are higher, the SWC will change more frequently, demanding shorter intervals of soil water measurements.

Considering the above sentence, in the first year (Figure 8a, b, c), the period between days 3 and 9, highlighting the interval between days 4 to 6, the Spearman rank correlation coefficients remained highest for a long period of time, while the SWC decreased, for all soil depths, at about $0.084 \text{ cm}^3 \text{ cm}^{-3}$ for the 0.05 m depth, $0.13 \text{ cm}^3 \text{ cm}^{-3}$ for the 0.15 m depth and $0.105 \text{ cm}^3 \text{ cm}^{-3}$ for the 0.30 m depth. In proportional terms, the SWC decreased around 48% at 0.05m, 50% at 0.15m depth and 37% at 0.30m depth. The high values for Spearman rank correlation means that the SWC distribution in the space showed a pattern between these days (temporal stability), consequently measuring the water content at average points (points 8, 1, 5, 7, 20 and 22) we could estimate the SWC at other points up to day 9. On the other hand, if we consider day 1 as a reference, the decreasing Spearman rank correlation coefficients manifest after day 3 the measurements of that day was no longer related to day 1 (Figure 8a, b, c). In this case the spatial distribution of SWC for day 3 was not the same as day 1. This second example shows heterogeneous Spearman rank correlation coefficients during the wet season, which demands more frequent measurements in space and in time. The data of the second year (Figure 8d, e, f), despite being also in the wet season, can give a vision about what would have happened in the dry season. During the second period of monitoring, both the rain and the SWC were lowest. In this case, considering the day one as reference of SWC measurement (Table 3), Spearman rank coefficient value would remain high up to day 4 when it decreased before it increased again.

Table 3. Matrix of Spearman Rank correlation coefficient of soil water storage measurements for 0.00 – 0.30 m during the second year.

	Day 01	Day 02	Day 03	Day 04	Day 05	Day 06	Day 07	Day 08	Day 09
Day 01	1.00								
Day 02	0.98	1.00							
Day 03	0.97	0.99	1.00						
Day 04	0.96	0.98	0.99	1.00					
Day 05	0.89	0.88	0.87	0.88	1.00				
Day 06	0.91	0.91	0.91	0.92	0.97	1.00			
Day 07	0.88	0.89	0.91	0.92	0.90	0.94	1.00		
Day 08	0.86	0.88	0.91	0.91	0.85	0.91	0.98	1.00	
Day 09	0.83	0.84	0.87	0.88	0.77	0.83	0.88	0.93	1.00

Spearman Rank correlation are significant in bold (alpha 0.05)

3.3.3 The correlation between SWC and clay content over time

The Pearson correlation coefficient between soil water contents and clay content varied not only for different depths on the same day but also over time for both years (Figure 9). On some days the correlation was positive and significant while other days the correlation decreased and became insignificant. This phenomenon was associated with the magnitude of soil water content. When the soil dried after a rain, the correlation coefficient increased. Greminger et al. (1985) measured soil water content in a transect over time and found crosscorrelation between sand and soil water pressure head under dry conditions but under wet conditions the crosscorrelation coefficients were small and usually insignificant. We could observe this behavior in the first year at 0.05 m depths for the first ten sampling days. For 0.30m depth this behavior was evident for the entire period. The drier soil showed higher correlation coefficients value for 0.30m. At 0.15m depth we did not observe correlations between SWC and soil texture (Figure 9a, b, c).

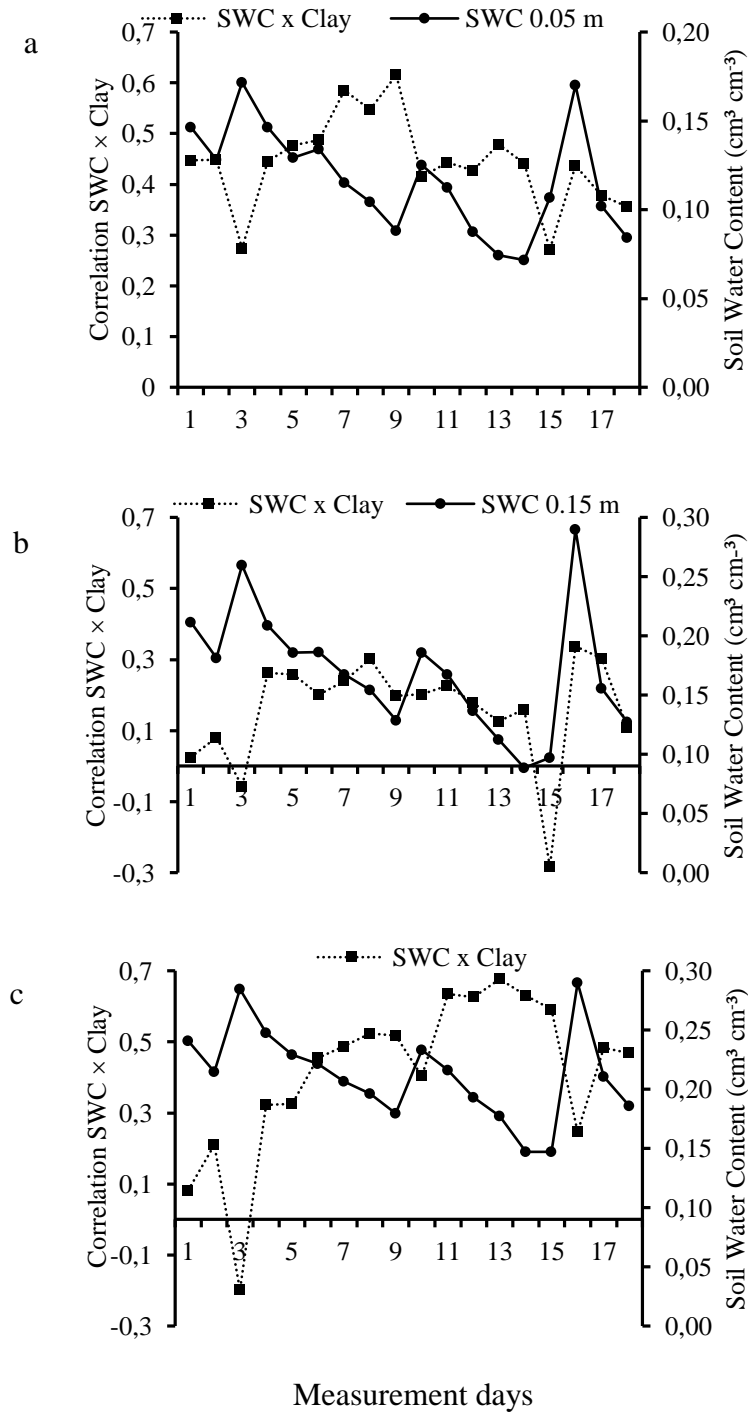
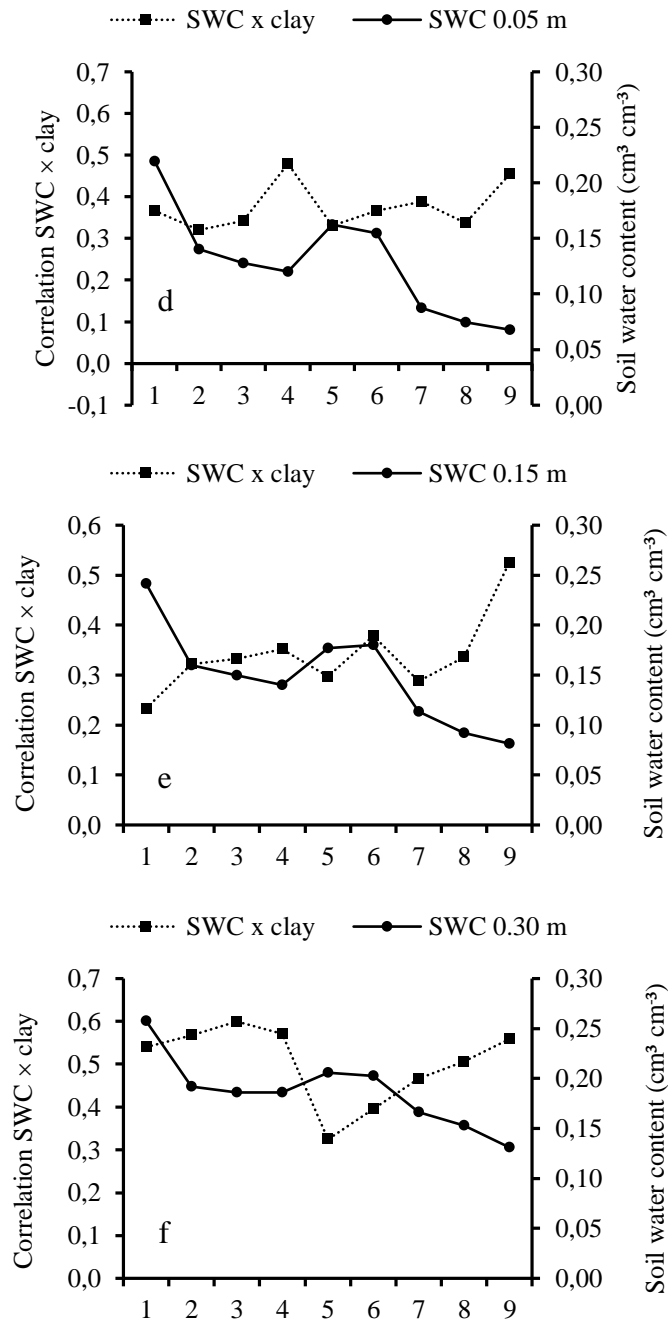


Figure 9. Values of correlation between soil water content x clay and soil water content for 0.05m (a), 0.15m(b) and 0.30m(c) at first year and 0.05m (d), 0.15m(e) and 0.30m(f) at second year (Continue).

Figure 9. Continuation.



For the second year, the correlation tended to increase, once the soil became dry after the end of rain event. The correlation was high for 0.30 m at all days, except days 5 and 6 (Figure 9f) after the soil became wet. At 0.15m the correlation coefficient was weak (Figure 9e). Therefore the distribution of clay content in the area could explain the distribution of water at 0.30m soil depth. Probably, the behavior of water distribution in the upper layers was more influenced by the evapotranspiration process and the contents of soil organic matter. Besides, as the first 0.20 m soil depth is more frequently plowed, it can also influence the soil water distribution, and consequently reduces the correlation between SWC and clay content.

These results imply that the influence of soil clay content depends on soil water content and whether the soil is in a drying or wetting phase. Total soil water potential consists of four components: matric, gravitation, pressure and osmotic potential. The importance of each component of total soil water potential changes with soil water content. When the soil gets wet during a rain, the gravitational potential is important because the soil water is “free” and in this case it is drained by macropores. In this case the soil macroporosity would govern the distribution of soil moisture. As the soil becomes dry, the soil surface and water surface interaction increase, therefore, at this soil moisture the clay content (adsorptive forces) and micropores (capillary forces) govern the soil water distribution. Soil matric potential gains importance. This physical phenomenon explains the observed change of correlation between soil water content and clay.

3.4. CONCLUSIONS

Our finds indicate that the soil water content showed a temporal stability between year 1 and 2 for both the driest and the wettest points along the study site. However, this pattern was not followed for the points representing the average soil water content. In this case we cannot use the average points of year 1 to estimate soil water in year 2. Probably the removal and reinstallation of sensors, as well as the tillage management of the study site, influenced the measurements and therefore contribute to the lack of continuity.

Considering short periods of time (within the years 1 and 2), the Spearman's rank correlation coefficients were statistically significant, confirming the temporal stability of the data. Consequently, within both the years, it is possible to use points representing the average of SWC, identified in the graph of "Relative mean difference", to estimate the SWC in others parts of the area.

Within a specific year of monitoring, the decrease of Spearman coefficient rank was associated to rainfall events, showing a cyclic pattern. Soon after rainfall the temporal stability decreased and when the soil begins to dry, the Spearman rank correlation increase again. Due this cyclic pattern, for wetter periods it is necessary to intensify the number sensors and the period of SWC monitoring in the area.

The Spearman correlation between soil water and clay contents varied not only with the depth but also with the soil moisture. The correlation is lower at upper layers, once it is more influenced by tillage practices, soil organic carbon changes and the evapotranspiration process. When the soil became drier, mainly at 0.30m soil layer where the clay content is higher, the correlation increased due to the preponderance of adsorptive and capillary forces over soil water distribution.

3.5. ACKNOWLEDGEMENTS

The authors thank to Brazilian Federal Agency for Support and Evaluation of Graduate Education - CAPES, under Science without Borders Program, for provide fund by "Special visiting researcher program" (number 152140). CAPES PVE-8888.030464/2013-01.

3.6. REFERENCES

- BEVEN, K., GERMANN, P., Macropores and water flow in soils. *Water Resources Research*. 18, p. 1311 – 1325, 1982.
- BROCCA, L., MORBIDELLI, R., MELONE, F., MORAMARCO, T., Soil moisture spatial variability in experimental areas of central Italy. *Journal of Hydrology*. 333, p. 356 – 373, 2007.
- CEDDIA, M.B., VIEIRA, S.R., VILLELA, A.L.O., MOTA, L.S., ANJOS, L.H.C., CARVALHO, D.F., Topography and spatial variability of soil physical properties. *Scientia Agricola*. 66, p. 338 – 352, 2009.
- DA SILVA, A.P., NADLER, A., KAY, B., Factors contributing to temporal stability in spatial patterns of water content in the tillage zone. *Soil Tillage Research*. 58, p. 207 – 218, 2001.
- DE SOUZA, E.R., MONTENEGRO, A.A.D.A., MONTENEGRO, S.M.G., DE MATOS, J.D.A., Temporal stability of soil moisture in irrigated carrot crops in Northeast Brazil. *Agricultural Water Management*. 99, p. 26 – 32, 2011.
- EMBRAPA, 1997. *Soil Analysis Methods. Manual de Métodos de Análise de Solo*, second ed. Centro Nacional de Pesquisa de Solos, Rio de Janeiro (in Portuguese).
- GREMINGER, P.J., SUD, Y.K., NIELSEN, D.R., Spatial variability of field-measured soil-water characteristics. *Soil Science Society of America Journal*. 49, p. 1075 – 1082, 1985.
- GUBER, A. K., GISH, T.J., PACHEPSKY, Y.A., VAN GENUCHTEN, M.T., DAUGHTRY, C.S.T., NICHOLSON, T.J., CADY, R.E., Temporal stability in soil water content patterns across agricultural fields. *Catena*. 73, p. 125 – 133, 2008.
- HU, W., SHAO, M.A., WANG, Q.J., REICHARDT, K., Soil water content temporal-spatial variability of the surface layer of a Loess Plateau hillside in China. *Scientia Agricola*. 65, p. 277 – 289, 2008.
- HU, W., SHAO, M., HAN, F., REICHARDT, K., TAN, J., Watershed scale temporal stability of soil water content. *Geoderma*. 158, p. 181 – 198, 2010.
- HUPET, F., VANCLOOSTER, M., Intraseasonal dynamics of soil moisture variability within a small agricultural maize cropped field. *Journal of Hydrology*. 261, p. 86 – 101, 2002.
- JÚNIOR, V.V., CARVALHO, M.P., DAFONTE, J., FREDDI, O.S., VIDAL VÁZQUEZ, E., INGARAMO, O.E., Spatial variability of soil water content and mechanical resistance of Brazilian ferralsol. *Soil Tillage Research*. 85, p. 166 – 177, 2006.
- KACHANOSKI, R.G., DE JONG, E., Scale Dependence and the Temporal Persistence of Spatial Patterns of Soil Water Storage. *Water Resources Research*. 24, p. 85 – 91, 1988.
- LETEY, J., Relationship between soil physical properties and crop production. *Adv. Soil Science*. 1, p. 277 – 294, 1985.
- NIELSEN, D.R., WENDROTH, O., *Spatial and Temporal Statistics – Sampling Field Soils and Their Vegetation*, first ed. CATENA VERLAG GMBH, Reiskirchen, Germany, 2003.
- PACHEPSKY, Y.A., GUBER, A.K., JACQUES, D., Temporal persistence in vertical distributions of soil moisture contents. *Soil Science Society of America Journal*. 69, p. 347 – 352, 2005.
- PETERSEN, R.G., CALVIN, L.D., SAMPLING. p. 33 – 51. In: Klute, A., *Methods of soil analysis, Part 1. Physical and Mineralogical Methods*. Madison, Wisconsin, USA, 1982.
- PETERSEN, L.W., MOULDRUP, P., JACOBSEN, O.H., ROLSTON, D.E., Relations between specific surface area and soil physical and chemical properties. *Soil Science*. 161, p. 9 – 21, 1996.

- REYNOLDS, S.G., Gravimetric method of soil moisture determination III. *Journal of Hydrology*. 11, p. 288 – 300, 1970.
- STARR, G.C., Assessing temporal stability and spatial variability of soil water patterns with implications for precision water management. *Agricultural Water Management*. 72, p. 223 – 243, 2005.
- SHUME, H., JOST, G., KATZENSTEINER, K., Spatio-temporal analysis of the soil water content in a mixed Norway spruce (*Picea abies* (L.) Karst.) – European beech (*Fagus sylvatica* L.) stand. *Geoderma*. 112, p. 273 – 287, 2003.
- TOPP, G.C., DAVIS, J.L., ANNAN A.P., Eletromagnetic determination of soil water content: measurements in coaxial transmission lines. *Water Resources Research*. 16, p. 574 – 582, 1980.
- VACHAUD, G.; SILANS, A.P., BALABANIS P., VAUCLIN, M., Temporal stability of spatially measured soil water probability density function. *Soil Science Society of America Journal*. 49, p. 822 – 828, 1985.
- VAN PELT, R.S., WIERENGA, P.J., Temporal Stability of Spatially Measured Soil Matric Potential Probability Density Function. *Soil Science Society of America Journal*. 65, p. 668 – 677, 2001.
- VIEIRA, S.R., GREGO, C.R., TOPP, G.C., Analyzing spatial and temporal variability of soil water content. *Bragantia*. 67, p. 463 – 469, 2008.
- WANG, X., PAN, Y., ZHANG, Y., DOU, D., HU, R., ZHANG, H., Temporal stability analysis of surface and subsurface soil moisture for a transect in artificial revegetation desert area, China. *Journal of Hydrology*. 507, p. 100 – 109, 2013.
- WENDROTH, O., POHL, W., KOSZINSKI, S., ROGASIK, H., RITSEMA, C.J. NIELSEN, D.R., Spatio-temporal patterns and covariance structures of soil water status in two Northeast-German field sites. *Journal of Hydrology*. 215, p. 38 – 58, 1999.
- WESTERN, A.W., GRAYSON, R.B., BLOSCHL, G., WILLGOOSE, G.R., MCMAHON, T.A., Observed spatial organization of soil moisture and its relation to terrain indices. *Water Resources Research*. 35, p. 797 – 810, 1999.

4. CAPÍTULO II

STATE SPACE APPROACH TO ANALYZE SPATIAL DISTRIBUTION OF SOIL ORGANIC CARBON

4.1 RESUMO

O carbono orgânico é um importante componente na manutenção da qualidade e da segurança do solo, para que o solo cumpra o papel de produção de alimentos, fibras, água, energia, sustentabilidade climática e contribua na manutenção da biodiversidade. A distribuição espacial do carbono no solo é influenciada por fatores como o conteúdo e o tipo de argila, manejo agrícola, características da paisagem, entre outros. Abordagens estatísticas que consideram a variabilidade espacial têm sido usadas para descrever a distribuição espacial dos atributos dos solos bem como identificar a causa e efeito da distribuição destes atributos na paisagem. Os objetivos deste estudo foram: estudar a distribuição espacial do carbono em uma paisagem agrícola e entender os fatores que contribuem na sua distribuição utilizando como método estatístico a função autoregressiva state space e a análise espectral; avaliar se contribuição dos valores prévios em estimar os próximos pontos é influenciada pela direção da análise dos dados. O experimento foi instalado numa pastagem, onde um grid amostral de 10m x 10m foi planejado. Amostras deformadas foram coletadas em cada ponto amostral e foi analisada a distribuição de partículas, carbono total e medição da elevação. O grid foi organizado na forma de transecto e os dados foram analisados em duas direções. O transecto 1 foi organizado no sentido do declive da paisagem e o transecto 2 foi organizado no sentido da curva de nível do terreno. Na paisagem estudada, são encontrados maiores valores de carbono na parte inferior da paisagem e este comportamento foi associado com a distribuição da argila. Elevação, carbono e argila apresentaram autocorrelação no espaço além de padrões cíclicos quando analisados pelo transecto 1. Elevação, carbono, argila aumentaram a distância de autocorrelação e cálcio apresentou autocorrelação no espaço quando analisados pelo transecto 2. Os valores prévios de argila apresentaram as melhores predições quando comparadas com os as predições realizadas com os outros atributos. Estes resultados apontam a aplicabilidade do uso destas técnicas estatísticas no estudo da distribuição das variáveis do solo na paisagem agrícola.

Palavras chaves: Carbono do solo. Semivariância. Análise espectral. State space.

4.2 ABSTRACT

The soil organic carbon (SOC) is an important component to the maintenance of the soil quality and soil security in order to fulfill your functions to produce food, fiber, water, contribute to energy and climate sustainability and to maintenance of biodiversity. SOC distribution is influenced by several factors as clay content and clay type, agricultural management and landscape features. Statistical approaches which consider the spatial variability of soil properties have been used to generate knowledge about the SOC dynamics over space and describe spatial and temporal processes. The aims of this study were (i) describe and understand the factors which contribute to the spatial distribution of SOC using autoregressive state space models and spectral analysis; (ii) verify if the direction of data analysis influence the contribution of previous values to estimate next points. The experiment was carried out in a grassland area where a regular grid with spacing of 10 m was laid out. The dataset was analyzed as transect in two directions. At each point soil texture, total soil organic carbon and elevation were measured. In the studied landscape were found highest SOC values and clay content in the lower part of the area. Elevation, SOC and clay content showed autocorrelation function in transect 1. Elevation, SOC and clay increased the spatial correlation and calcium showed an autocorrelation when analyzed in transect 2. Previous values of clay exhibited best prediction quality compared to other soil attributes. These results demonstrated the applicability of state space and spectral analysis in studying of the distribution of soil attributes in the landscape.

Key words: Soil organic carbon. Semivariance. Spectral analysis. State space.

4.3 INTRODUCTION

The soil organic carbon (SOC) is an important component to the maintenance of the soil quality and soil security in order to the soil to fulfill your functions to produce food, fiber, water, contribute to energy and climate sustainability and to maintenance of biodiversity (Katyal et al, 2001; McBratney et al., 2014). Since the soil is an important component to store carbon (Lal, 2004). SOC distribution is influenced by several factors as clay content and clay type (Burke et al., 1989; Hassinsky, 1994; Baldock and Skjemstad, 2000), agricultural management (Pinheiro et al., 2015; Lal, 2015) and landscape features (She et al., 2014; Ceddia et al., 2015). Describe the relationship between soil characteristics, landscape properties and SOC is important to help us to understand the carbon dynamics.

Most commonly, traditional statistical approaches have been used to describe SOC associations such as multiple and linear regressions. However SOC distribution is difficult to estimate because of limited knowledge about specific soil properties (Sombroek et al., 1993; Batjes, 1996) and considerable spatial variability of soil carbon even within the soil unit (Cerri et al., 2000). Based on spatial structure some statistical approaches such as, autocorrelation function, semivariograms, spectral analysis and state space analysis, have been used to generate knowledge about the SOC dynamics over space and describe spatial and temporal processes (Liu et al., 2012; She et al., 2014; Ceddia et al., 2015; Stevens et al., 2015; Rienzi et al., 2016). These methods assume that the soil attributes can be spatial dependents, with spatial structure. In other words, this kind of statistical approach evaluates the degree of association between pairs of values separated by a given distance (Nielsen and Wendroth, 2003). Besides, the semivariance behavior can be used for detecting landscape processes at different scales (Webster and Oliver, 2001; Wendroth et al, 2011). The spatial covariance behavior in this study was used to identify cause and effect of the SOC distribution in the landscape. Variance of soil properties along of sample design as well as the related processes can be decomposed among different scales (Kachanoski and De Jong, 1988) allowing reveal the underlying processes occurring in field soils (Nielsen and Allemi, 1989).

Space and time domain analysis have been applied to spatial and temporal soil and crop processes and expresses the observation variable in terms of linear function of its previous values or other related and a random error. It is used for estimating equally spaced univariate and multivariate processes (Nielsen and Allemi, 1989). The transition coefficient of each variable reflects the degree of its spatial correlation with the outcome (Morkoc et al., 1985). State space analysis have been used to identify the factors causing the underlying process such as describe the

spatial variability of soil solute (Schwen et al., 2012; Yang and Wendroth, 2014), describe the spatial series of probe calibration parameters (Wendroth et al, 2013), temporal variability of soil water content (Timm et al, 2011), evaluate the tillage and harvesting operation in soil properties (Rienzi et al., 2016). Despite of efforts to describe soil processes some questions remain. How does autocorrelation length change if we analyze the dataset in different directions? Does the contribution of previous values change for different directions of transect?

The aims of this study were (i) describe and understand the factors which contribute to the spatial distribution of SOC; (ii) verify if the direction of data analysis influence the contribution of previous values to estimate next points.

4.4 MATERIAL AND METHODS

4.4.1 Studied area, experimental design and soil sampling

The study was carried out at Integrated System of Agroecological Production (ISAP), located in Seropédica city, Rio de Janeiro State, Brazil. This area has high average temperatures 24.5°C and the annual average precipitation is 1200mm. The main soil in the area is classified as Alfisol, some parts of the area show not well drained zones. The area is located in the lower part of the landscape, which characterizes the area with high values of sand content, for more details about this landscape see Silva (2001) and Ceddia (2009). The studied area was being grown in the last years with grass (*Pennisetum purpureum*).

In order to study the spatial variability of soil organic carbon and distinguish the factors that contributed to the spatial distribution of soil organic carbon content, the area was divided in a 10 x 10 m grid (Figure 1) resulting in 50 sampling locations. To analyze the dataset using state-space methodology it was organized in one direction (Stevenson et al, 2001; Wendroth et al., 2003; She et al., 2014; Aquino et al.; 2015). The observations were designed in two transects (two directions) like indicated at figure 1. For each of the 50 sampling location UTM coordinates were located using a GPS with differential correction.

Soil were sampled at 0 to 0.20 m depth. Samples were air-dried and sieved. The values of soil organic carbon were determined using Walkley-Black method. Textural analysis was quantified using the pipette and sieve method (Embrapa, 1997).




Figure 1. Grid and transect scheme, transect 1 continuous line and transect 2 dashed line.

Before using spatial analysis, all data were scaled using the equation described by Hui et al., 1998 (equation 1). This equation normalize the data, in this case all of them would have a mean of 0.5 and standard deviation of 0.25. Therefore after normalization, the data are in the same magnitude. This procedure avoids numerical problems that can arise if two or more variables differ by order in their magnitude. In this case, the transition coefficients in the state space models reflect their contribution to the estimative. To determine the relative contribution of each variable is necessary to divide the corresponding transition coefficient by the sum of coefficients in the respective equation (Yang and Wendroth, 2014).

$$x'_i = \frac{x_i - (\bar{x} - 2\sigma_x)}{4\sigma_x}. \quad (1)$$

where, x_i is the data value, \bar{x} is the mean and σ is the standard deviation.

In this study samples were collected over the area and were distributed on regular grid. Therefore we could study the spatial dependence of soil properties. The autocorrelation function (ACF) were used to determine the correlation with itself considering the space or time (equation 2). The autocorrelation function estimates the degree of linear association between pairs of values separated by a given distance. In order to determine the confidence

interval (CI, equation 3) of autocorrelation to estimate the range of correlation the follow equation was used:

$$r(h) = \frac{\text{cov}[A_i(x), A_i(x+h)]}{\sqrt{\text{var}[A_i(x)]} \sqrt{\text{var}[A_i(x+h)]}} \quad (2)$$

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

where, cov is covariance and var is the variance, $A_i(x)$ is the value of the soil attribute “A” at point i, $A_i(x+h)$ is the value of the soil attribute “A” at point i plus distance h, p is the accumulated probability for test t at a 95% and n is the number of sample points (50).

The crosscorrelation function (CCF) was calculated in order to evaluate the spatial correlation between SOC and other soil variables (equation 4). The crosscorrelation function estimates the linear association between pairs of two variables separated by a given distance. Details about ACF, CCF concept and the framework for calculation see Nielsen and Wendroth (2003), Reichardt and Timm (2004). These analyses allow us to observe processes over the space.

$$r_c(h) = \frac{\text{cov}[A_i(x), B_i(x+h)]}{\sqrt{\text{var}[A_i(x)]} \sqrt{\text{var}[B_i(x+h)]}} \quad (4)$$

where, cov is covariance and var is the variance, $A_i(x)$ is the value of the soil attribute “A” at point i, $A_i(x+h)$ is the value of the soil attribute “A” at point i plus distance h, $B_i(x)$ is the value of the soil attribute “B” at point i, $B_i(x+h)$ is the value of the soil attribute “B” at point i plus distance h, p is the accumulated probability for test t at a 95% and n is the number of sample points (50).

Experimental semivariograms (equation 5) were calculated in order to reveal the spatial structure of soil attributes and the behavior of the variance over transect. It is useful to study the behavior of attributes as a function of distance and can indicate periodic variation behavior at a particular scale (Wendroth et al., 2011). The ACF and semivariograms can be used to identify cyclic patterns of a soil processes which possibility the use of “Spectral Analysis” to analyze the frequency domain variance components (Nielsen and Wendroth, 2003). The semivariogram is important to identify processes that are occurring in the landscapes in different scales (Webster e Oliver, 2001).

$$\gamma(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [A_i(x_i) - A_i(x_i + h)]^2 \quad (5)$$

in which N is the number of observations pairs separated by distance h, $A_i(x_i)$ denotes observation A_i at location x_i , $A_i(x_i + h)$ denotes observation A_i at location x_i plus h distance. The spatial covariance between two variables was calculated by cross-semivariograms (equation 6), showing the spatial relationship of two soil attributes with increasing lag distance (Yates and Warrick, 2002).

$$\hat{\gamma}(h) = \frac{1}{2N(h)} \sum_{j=1}^{N(h)} \{A_i(x_i) - A_i(x_i + h)\} \{B_i(x_i) - B_i(x_i + h)\} \quad (6)$$

in which N is the number of observations pairs separated by distance h, $A_i(x_i)$ denotes observation A_i at location x_i , $A_i(x_i + h)$ denotes observation A_i at location x_i plus h distance, $B_i(x_i)$ denotes observation B_i at location x_i , $B_i(x_i + h)$ denotes observation B_i at location x_i plus h distance.

The frequency domain variance was calculated using Spectral and Co-Spectral analysis (Shumway, 1988). Cyclic patterns in soil properties observed at ACF can be discerned by a spectral analysis (Nielsen and Alemi, 1989). The power spectra $S(f)$, which is based on Fourier transformation was calculated with (equation 7):

$$S(f) = 2 \int_0^{\infty} r(h) \cos(2\pi fh) dh, \quad (7)$$

where f is the frequency of the periodic observation and autocorrelation function $r(h)$ is integrated with respect to the lag distance. The power spectrum as a variance peak S show a periodicity, occurring at an associated frequency f which is the inverse of the wavelength λ reflecting the scale of variation. Common periodic fluctuations in two dataset can be detected with the co-spectrum $Co(f)$ integrating the cross-correlation function $r_c(h)$ (equation 8),

$$Co = 2 \int_0^{\infty} r_c(h) \cos(2\pi fh) dh \quad (8)$$

where the $r_c(h)$ is combined in one common side of the cross-correlation function through $r_c(h) = 0.5[rc(h > 0) + rc(h < 0)]$. This procedure reinforces any cyclic variations described by a cosine function and eliminates cyclic variations described by a sine function. The quadrature spectrum $Q(f)$ identifies the lag at which two variables reach their maximum cross-correlation and is calculated by equation 9:

$$Q(f) = 2 \int_0^{\infty} r_c(h) \sin(2\pi fh) dh \quad (9)$$

Cross spectral analysis consists of two components: co-spectrum and quad-spectrum. Co-spectrum identifies those spatial frequencies for which two sets of observations are correlated, and the quad spectrum is important because it identifies the lag between two dataset which are correlated at the same frequency (Nielsen and Wendroth, 2003).

The calculated distance which represents a cyclic behavior is determined by the following equation, where T is period and f frequency:

$$T = f^{-1} \quad (10)$$

Autoregressive state space model is based on estimate of a variable at location i compared to its value at $i-h$. Where h is a lag between two locations. The state space models consist of an observation equation and a state equation (Shumway and Stoffer, 1982). The observation equation is described by equation 11:

$$Y_i = M_i Z_i + v_i \quad (11)$$

where, Y_i is the observed vector and it is related to the true state vector by measurement matrix M_i and an error v_i . The error is uncorrelated and mean value zero (Shumway, 1998; Nielsen and Wendroth, 2003). The state equation can be described by equation 12:

$$Z_i = \phi Z_{i-1} + w_i \quad (12)$$

where, Z_{i-1} is the state vector, ϕ the $p \times p$ transition matrix of state coefficient and w_i the uncorrelated zero mean error vector. The autoregressive state space model were solved with Kalman filter and expectation maximization algorithm described by Shumway and Stoffer (1982).

4.5 RESULTS AND DISCUSSION

4.5.1 Spatial variability of soil properties

Spatial distribution of soil organic carbon, elevation, clay, sand for transect 1 are shown in figure 2a, b, c, d and for transect 2 in figure 3a, b, c, d. The SOC showed a cyclic pattern for transect 1 (Figure 2a) but did not show this behavior for transect 2 (Figure 3a). The mean value was 8.98 g kg^{-1} and the minimum and maximum values were 4.5 and 21 g kg^{-1} (Table 1). The elevation showed a clear cyclic behavior (Figure 2b) when used transect 1. When the dataset was organized as transect 2 the cyclic behavior was not so clear and the values of the elevation decreased from point 1 to 50 (Figure 3b). It will influence the values of semivariance and the autocorrelation as we will discuss latter. The mean value of elevation was 25.84 m, the maximum and the minimum were 29.66 and 23.02 m.

The mean value of clay content was 90.6 g kg^{-1} , the maximum and the minimum values were 161 and 23 g kg^{-1} . The clay content showed a cyclic pattern when used transect 1, since the spatial distribution of soil properties in the area is related to the landscape position (Silva, 2001; Ceddia, 2009). In the lower part of the area there are higher clay content than upper part (Figure 2c) and this characteristic is important to determine other soil attributes. We can observe a tendency of clay values decreases over transect (point 1 to 50) and a tendency of sand values increase in the same direction (figure 2d). The sand content showed mean value of 870.52 g kg^{-1} , minimum and maximum values were 783 and 923 g kg^{-1} . For transect 2 the values of clay content were lower in the beginning of the dataset and increasing over the area (Figure 3c). This behavior happened because the first part of the data is situated in the highest part of the area.

Table 1. Descriptive statistics of soil and landscape attributes

	Elevation (m)	Clay (g kg^{-1})	Sand (g kg^{-1})	SOC (g kg^{-1})
Mean	25.84	90.60	870.52	8.98
SD	1.49	32.92	33.21	3.32
Maximum	29.66	161.00	923.00	21.00
Minimum	23.02	23.00	783.00	4.50
Median	25.49	85.50	873.50	8.70
CV	5.78	36.33	3.81	36.98

SD _ Standard deviation, CV _ Coefficient of variation.

The SOC showed spatial autocorrelation for one lag (10 m) (figure 2e). The ACF decreased until lag 8 (80 m) and increased until lag 14 (140 m). The semivariance of SOC reached the maximum values at 70/80 m and showed low values at 140 m region describing a cyclic pattern over space (Figure 2i). Elevation showed spatial autocorrelation for two lags (20m) and showed a cyclic pattern. With further increasing lag distance the autocorrelation function of elevation decreased until lag 7 (70 m) and increased until lag 14 (140 m). After that the autocorrelation decreased again (figure 2f). We can observe the same behavior in the calculated semivariogram (Figure 2j). The semivariance of elevation reached the maximum value at 70 m and decreased until 140 m, when one cycle was completed. After 140m increased until 200 m and decreased until 280 – 290 m, when two cycles were completed. Repetitive oscillations in the autocorrelation function referred to a cyclic behavior of observations (Wendroth et al., 2011). The periodic pattern of elevation is result of transect position. The first point of transect is at upper part of the area, the next points are at the lowest

part of the area. After these points, elevation increase again until point 14. The next points continue with same pattern of distribution.

Clay content showed a spatial autocorrelation for one lag (figure 2g). The ACF and semivariograms of clay showed a cyclic pattern at 13/14 lags or 140 m (Figure 2g, 2k). The sand content did not show a spatial autocorrelation and the semivariogram exhibited a pure nugget effect, which indicates no spatial structure (figure 2h, 2l).

These results indicate that SOC and Clay content could be correlated on space with elevation and could be scale dependent. Moreover the spatial distribution of clay content could determine the spatial distribution of SOC in the area. The sampling interval was able to demonstrate the spatial relation between observations for some soil properties and it showed the cyclic pattern. Considering the transect 2, the autocorrelation function of SOC and Clay content increased for two lags (20 m). If we compare to transect 1 the spatial dependence was higher (Figure 3e, 3g). Therefore the change in direction of transect changed the spatial correlation. Elevation showed spatial autocorrelation for ten lags (100m, Figure 3b). Compared to transect 1 the ACF of elevation increased at transect 2. It can be explained because in the beginning of transect 2 the values of elevation are more similar than the elevation values in transect 1. Sand did not show a spatial dependence (Figure 3h).

The semivariance values of SOC and clay for transect 2 were lower in the beginning of transect than the transect 1 for both soil attributes (Figure 3i, 3k). The values of autocorrelation function for SOC and clay were spatial related for two lags, in the third lag the correlation decreased and from fourth lag onward the correlation increased again. This behavior is important to observe because it will influence the importance of clay to predict SOC when autoregressive functions will be calculate. The values of semivariance for elevation at transect 2 were lower than the transect 1 in the beginning of the dataset (Figure 3n). Sand showed a cyclic pattern for semivariance values (Figure 3l). Both directions (transect 1 and 2) and sampling interval were able to demonstrate the spatial correlation between observations.

4.5.2 Spectral analysis of soil organic carbon and other soil properties

The frequency domain analysis of the spatial function was determined using Spectral and Cross-spectral analyses based on normalized data to explore the variation scales of soil properties. For transect 1, a distinct peak in the power spectra for SOC showed at the frequency $f = 0.0703$, corresponding to the wavelength $\lambda = 142.2$ m, or 14 lags approximately (figure 2m). The power spectrum for elevation and clay content showed peaks at the frequency $f = 0.0703$ and 0.0742 , corresponding to the wavelength $\lambda = 142.2$ and 134.7 m, or 13-14 lags (figure 2n, 2o). These values of wavelength corresponding to the cyclic pattern of autocorrelation function and semivariograms. This lag corresponds the distance between the first point at highest position of the area going to the lowest part of the area and returning to the highest part of the area (Figure 3b). It indicates the repetitive fluctuation of studied soil properties. Sand did not show a distinct peak (Figure 2p).

The frequency domain analysis of the spatial function for transect 2 found a distinct peak for elevation at the frequency $f = 0.0859$, corresponding to the wavelength $\lambda = 110 - 120$ m, but others peaks at different frequencies were found too (Figure 3n). The power spectrum for clay showed a peak at wavelength $\lambda = 77.6 - 80$ m (Figure 3o); SOC showed different peaks indicating that the frequency was not so clear (3m). The distribution of sand showed a distinct peak at frequency $f = 0.125$, corresponding to wavelength $\lambda = 80$ m (Figure 3p). The estimated frequency domain for the studied properties did not show a pattern which corresponds to the same wavelength. Therefore, for transect 2 the dataset did not show a repetitive fluctuations at the same scale.

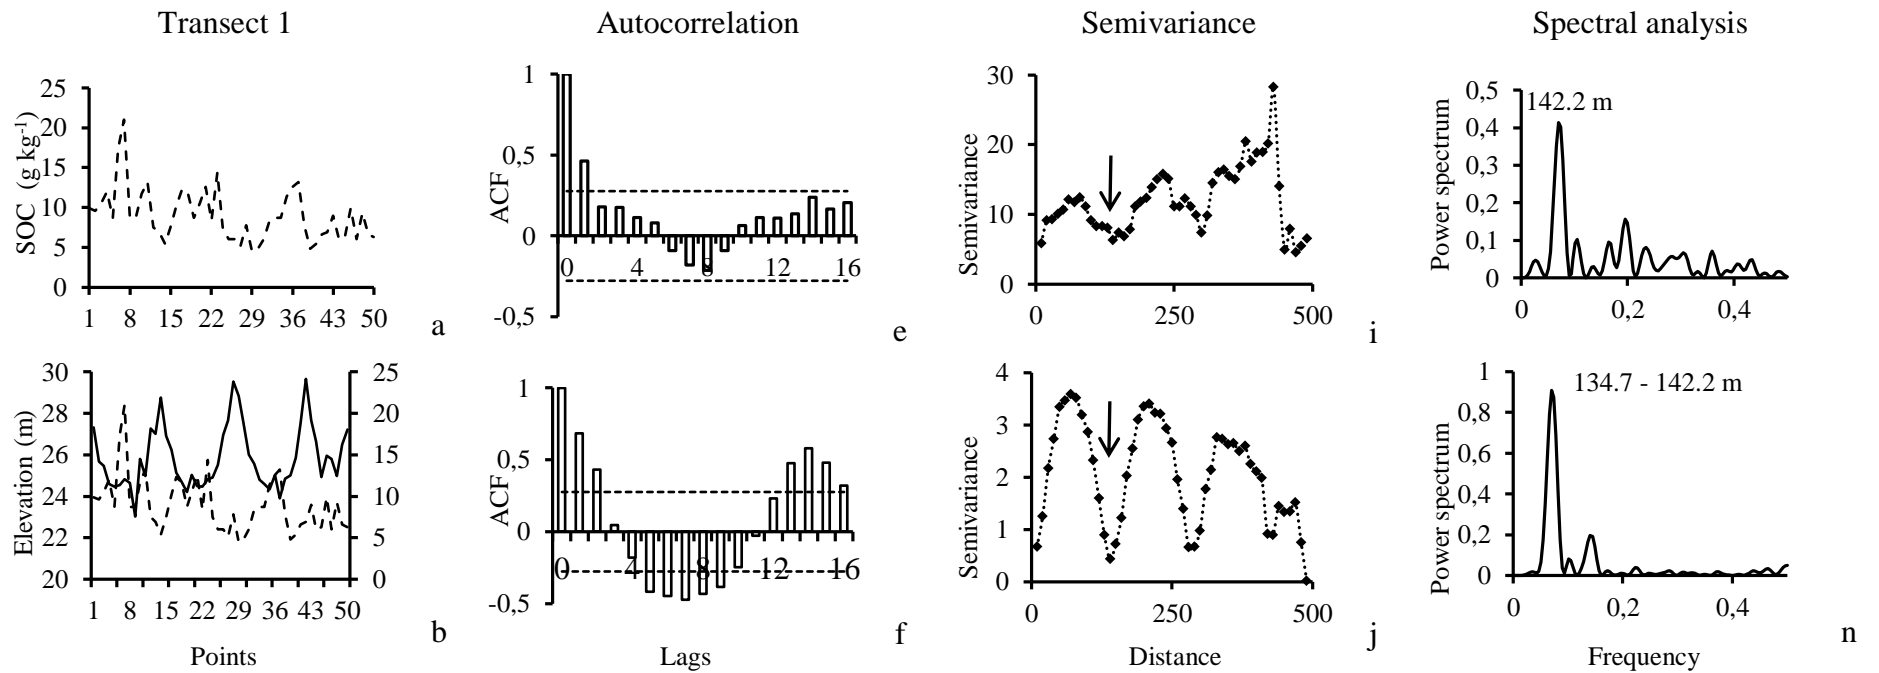
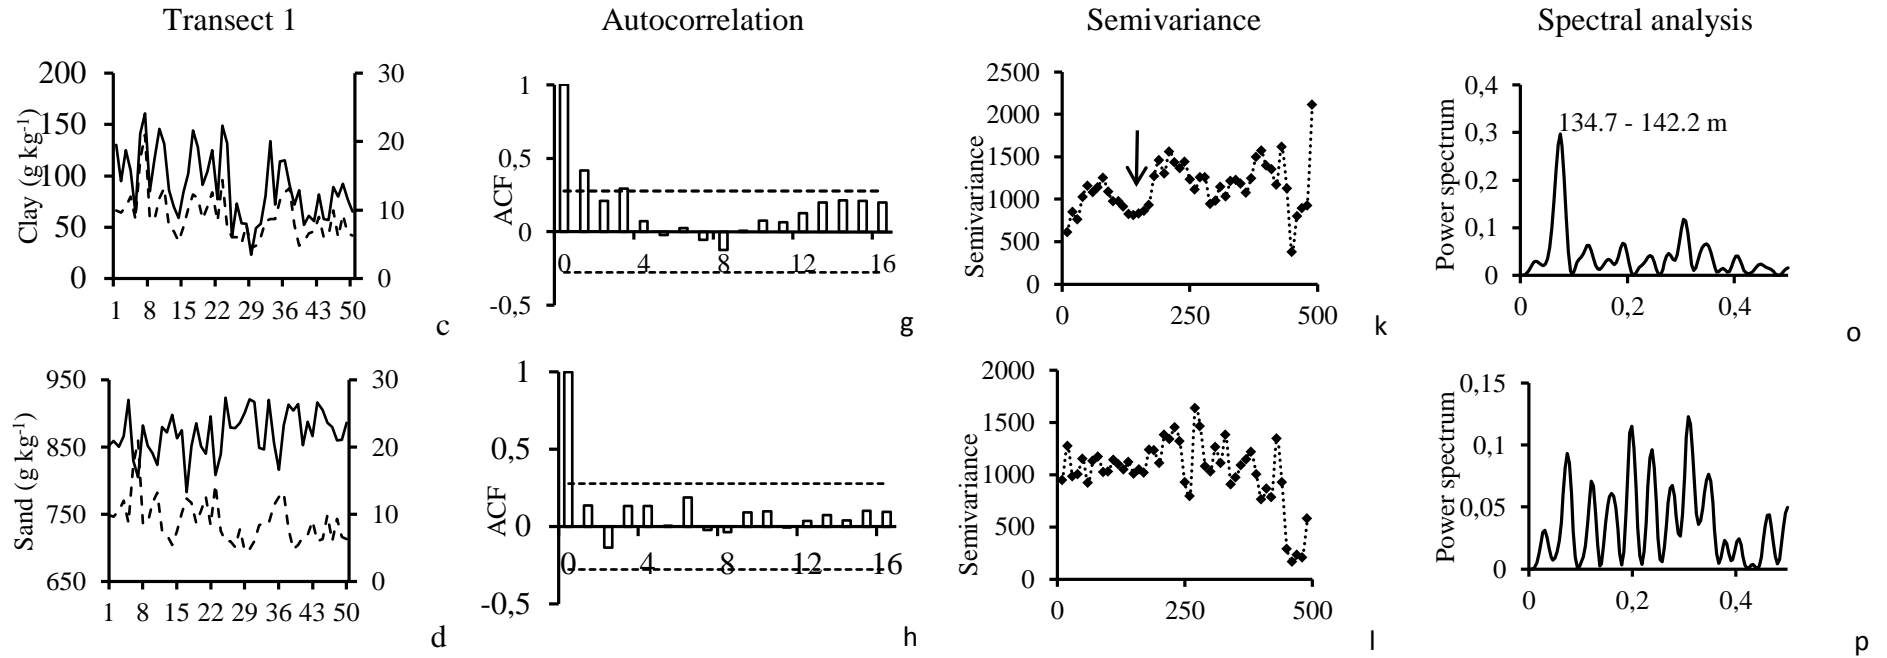


Figure 2. Distribution over the transect 1 of soil organic carbon (a), elevation (b), clay (c), sand (d); autocorrelation function of soil organic carbon (e), elevation (f), clay (g), sand (h); semivariogram of soil organic carbon (i), elevation (j), clay (k), sand (l); power spectrum soil organic carbon (m), elevation (n), clay (o), sand (p), dashed lines means the t test of ACF significance.

Figure 2.Continuation



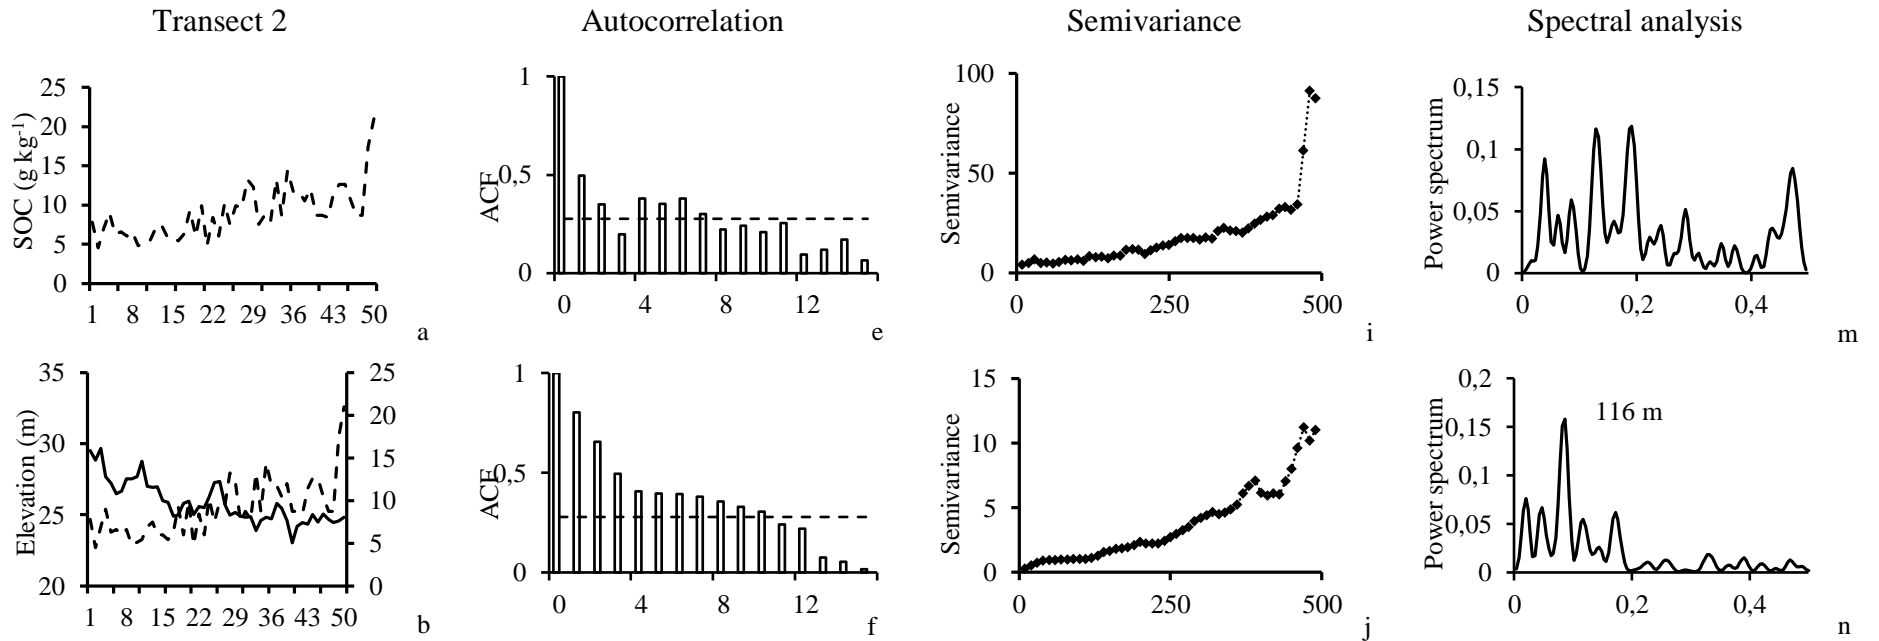


Figure 3. Distribution over the transect 2 of soil organic carbon (a), elevation (b), clay (c), sand (d); autocorrelation function of soil organic carbon (e), elevation (f), clay (g), sand (h); semivariogram of soil organic carbon (i), elevation (j), clay (k), sand (l); power spectrum soil organic carbon (m), elevation (n), clay (o), sand (p), dashed lines means the t test of ACF significance.


Figure 3. Continuation

Transect 2


Autocorrelation

Semivariance


Spectral analysis




c




g




k




o




d



h



l



p

4.5.3 Crosscorrelation functions of soil organic carbon and other soil properties.

Crosscorrelation functions, experimental cross-semivariograms and co-spectral analysis were calculated to analyze how these soil properties are spatially related. SOC and clay content were spatially and negatively correlated with elevation at 2 lags for transect 1 (Figure 4a, 4b). A decrease of elevation caused an increase of carbon and clay content. Elevation showed a cyclic pattern with SOC and clay content as showed at cross-semivariance values (Figure 4e, 4f). The cross-semivariance between elevation, SOC and clay reached the maximum value at 70 m and decreased until 140 - 150 m, when one cycle was completed. Therefore these properties varied at same scale.

SOC was spatially and positively correlated with clay content at 1 lag (Figure 4c). Therefore, the distribution of SOC in the landscape is related with the spatial distribution of clay content and indirectly by elevation. SOC was not spatially correlated with sand (figure 4d). Elevation, clay content are variables could be used to predict the SOC using state space models and these variables could be used to explain the spatial distribution of SOC over the studied area. The CCF for these variables showed repetitive fluctuations over space.

In order to analyze the repetitive fluctuations of SOC, clay, elevation the co-spectrum and quad-spectrum were calculated and presented in figure 4. A major peak in the co-spectrum between SOC and elevation occurred at the frequency $f = 0.0703$ and 0.0742 , corresponding to the wavelength $\lambda = 142.2$ and 134.7 m (figure 4i). The negative peak indicated a negative correlation between these two variables at this variation scale. In this case the negative correlation is related to soil texture (Figure 4k). At highest parts of the area, there are lowest quantities of clay (figure 2c), therefore the values of SOC were lower. At these frequencies the quad-spectrum values were close to zero (figure 4k) and phase values for these frequencies were -0.009 and -0.017 indicating that there were not lags between these two variables. In other words, the peak of frequency of these two variables occurs at the same lag. The major peak in the co-spectrum between SOC and clay occurred at the frequency $f = 0.0703$, corresponding to the wavelength $\lambda = 142.2$ m (figure 4k). The positive peak showed a positive correlation between these two variables. At this frequency the quad-spectrum values were close to zero and phase value for this frequency was -0.0098 , there were not lags between these two variables. Sand and SOC showed a negative peak corresponding to the wavelength $\lambda = 134 - 142.2$ m (Figure 4l).

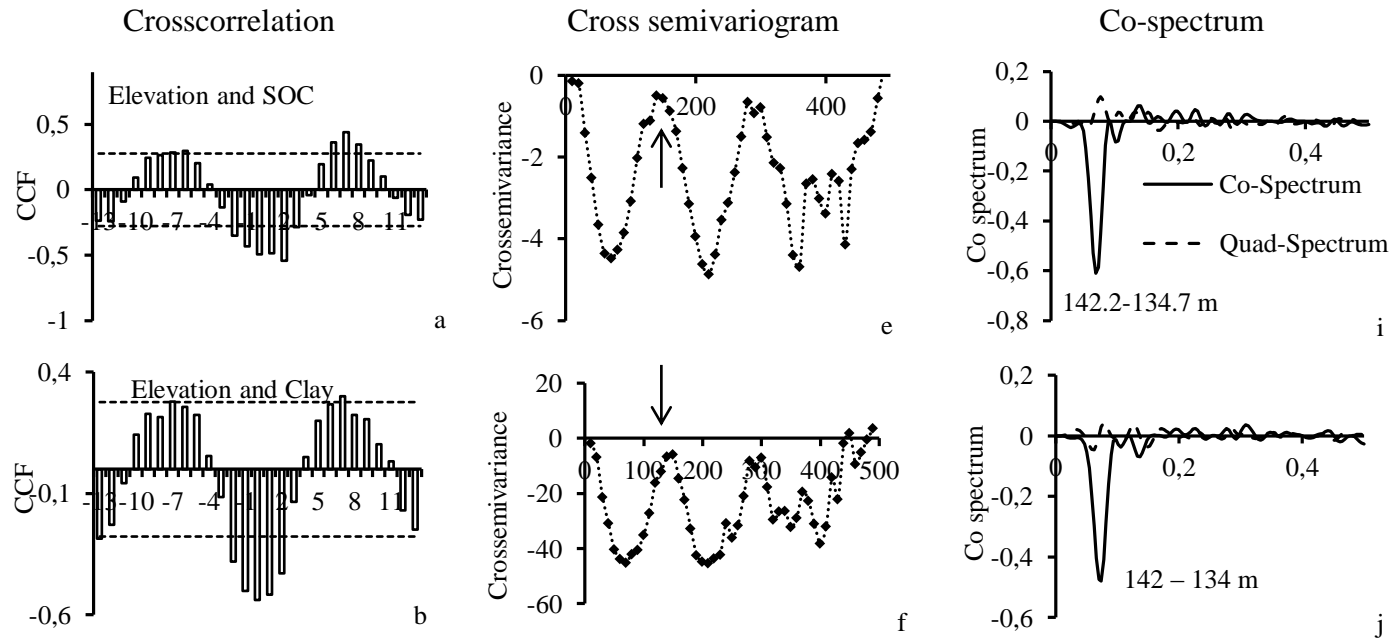
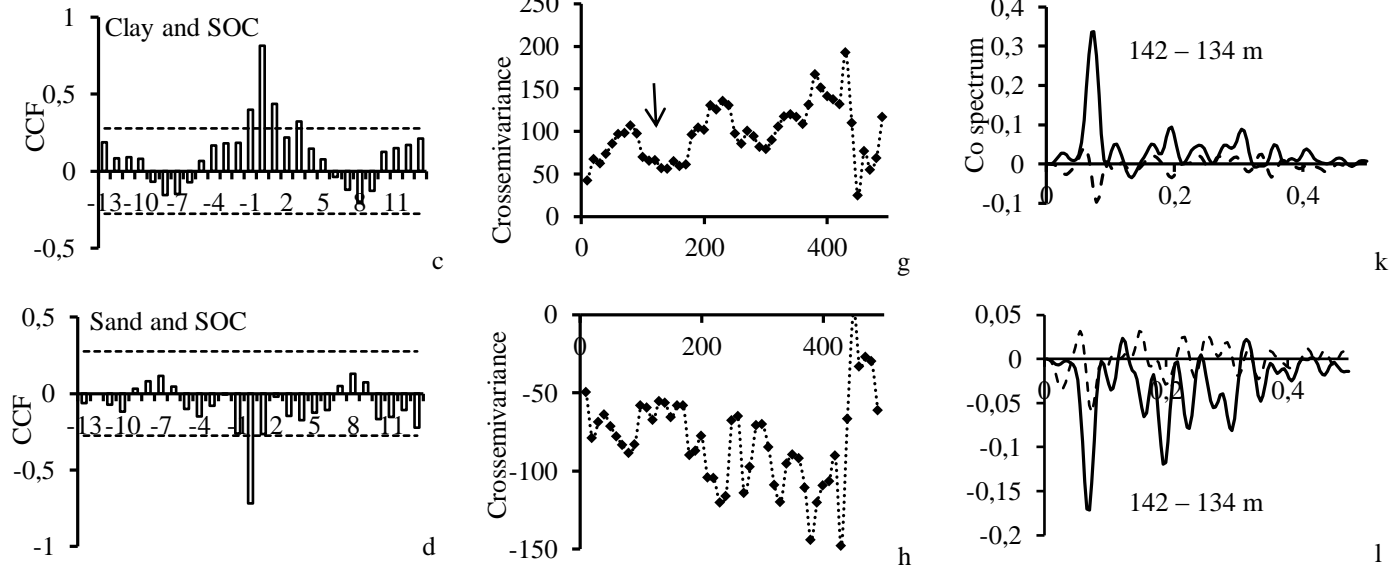


Figure 4. Crosscorrelation function for Elevation and SOC (a), Elevation and Clay (b), Clay and SOC (c), Sand and SOC (d); cross-semivariance for Elevation and SOC (e), Elevation and Clay (f), Clay and SOC (g), Sand and SOC (h); co-spectral for Elevation and SOC (i), Elevation and Clay (j), Clay and SOC (k), Sand and SOC (l), for transect 1.

Figure 4. Continuation



Considering the transect 2 the values of elevation were spatially and negatively correlated with SOC and Clay content at 12 and 10 lags (figure 5a, 5b). The spatial dependence between these variables considering transect 2 increased if compared to the transect 1. The cross-semivariance between elevation, SOC and clay showed small values in the first steps (Figure 5e, 5f). It happened because the differences between neighboring values were small, reflecting in the cross-semivariance values. SOC was spatially and positively correlated with clay content at 2 lags, increasing the relationship in space if compared to transect 1 (Figure 5c). For the first steps of cross-semivariogram between clay and SOC the semivariance values at transect 2 were lower than transect 1 (Figure 5g). Therefore, at both transects the spatial variability and the distribution of SOC in the landscape are related with the spatial distribution of clay. SOC was not spatially correlated with sand considering the cross-correlation function (Figure 5d). All cross-semivariograms showed a big value of semivariance at the last steps. It happened because the difference between the first points in the transect 2 and the last are very large. The co-spectrum analysis did not show a distinct peak corresponding a correlated wavelength between variables (Figure 5i, 5j, 5k, 5l).

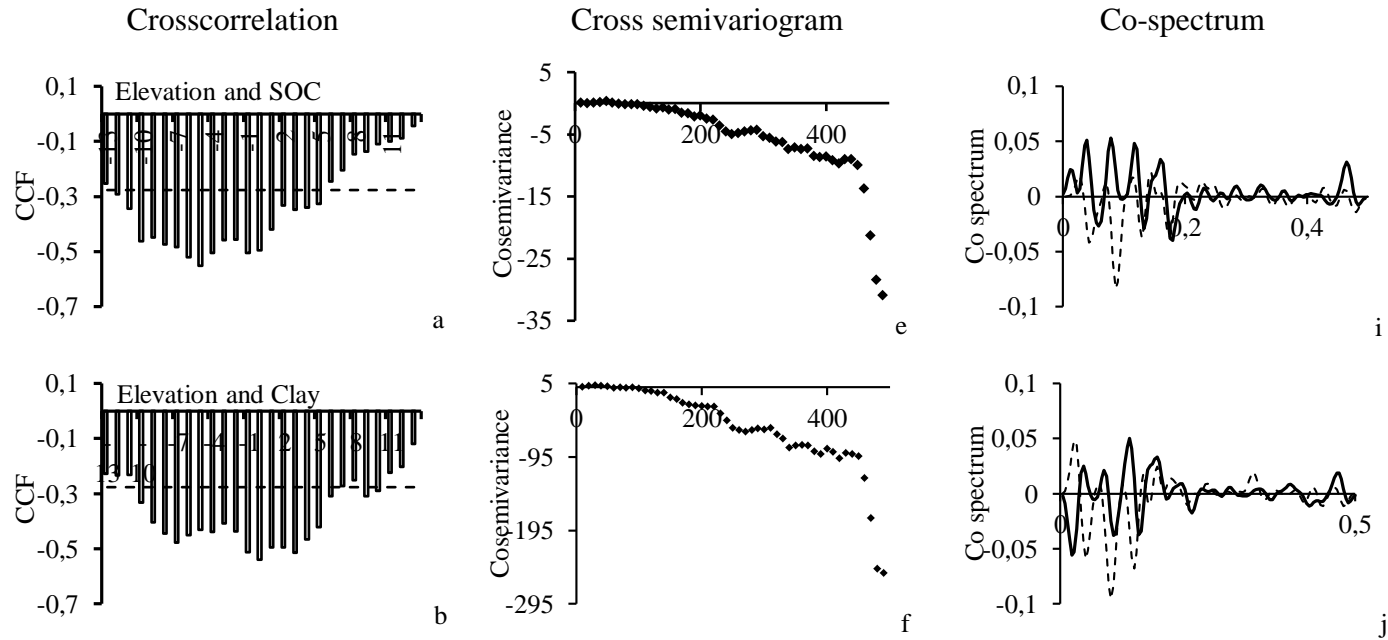
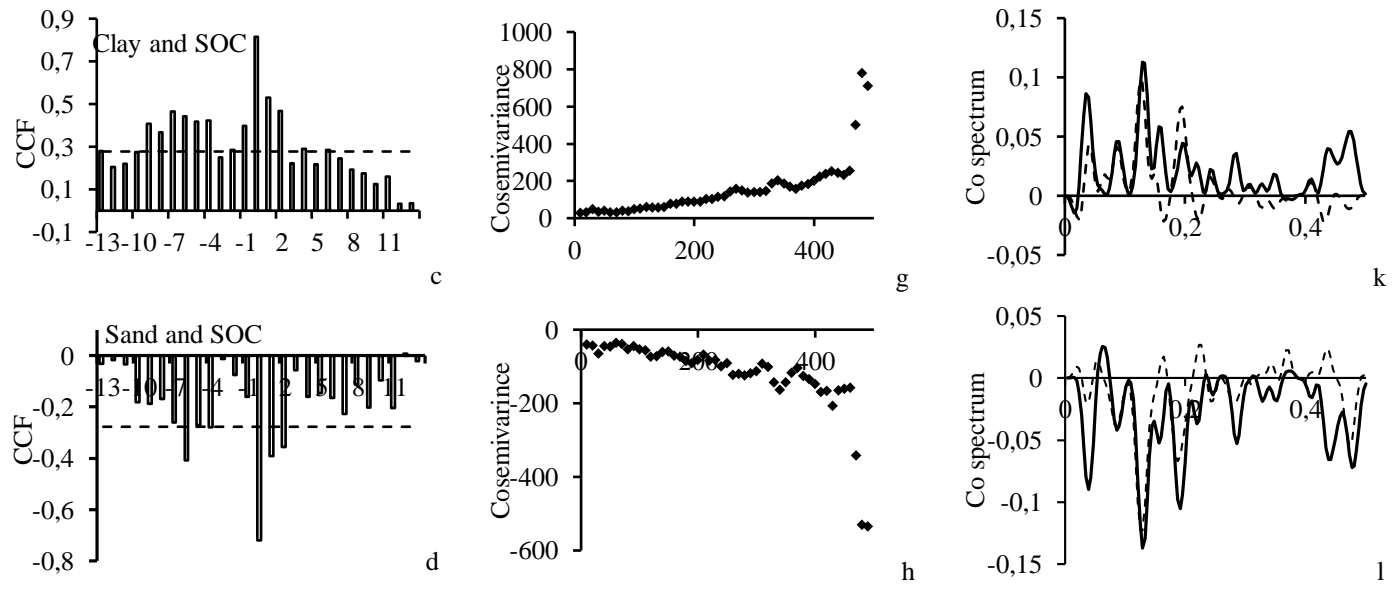


Figure 5. Crosscorrelation function for Elevation and SOC (a), Elevation and Clay (b), Clay and SOC (c), Sand and SOC (d); cross-semivariance for Elevation and SOC (e), Elevation and Clay (f), Clay and SOC (g), Sand and SOC (h); co-spectral for Elevation and SOC (i), Elevation and Clay (j), Clay and SOC (k), Sand and SOC (l), for transect 2.

Figure 5. Continuation



4.5.4 State space models of soil organic carbon

The calculated ACF for SOC, elevation, clay content showed a spatial structure and showed a crosscorrelation over space as discussed previously. Therefore, we can use these variables to describe the spatial processes of SOC to explore the major influencing factors. Autoregressive state-space models were applied for SOC and it showed the lowest value of AIC when it used clay content, elevation + clay as regression variables (Table 1) for transect 1. At transect 2 equations that used clay content as independent variable showed the highest values of coefficient of determination (Table 2).

The bivariate equation which used only clay described 99% of the variance at both transects. The equation that used elevation + clay (transect 1 and 2) as regressions variables described 99% of the variance too (Table 2). The coefficient of determination was 0.47 when elevation was used as regression variable at transect 1 and it increased to 0.64 at transect 2. Based on the magnitudes of transition coefficients the underlying processes that affect the soil organic carbon distribution could be identified. The transition coefficient of previous variables can be used to know the contribution of each variable to estimate the present value of the interesting variable (Morkoc et al., 1985; Yang and Wendroth, 2014; Awe et al., 2015). The data transformation is important to investigate the contribution of variables to estimate the present values (Dourado Neto et al., 1999). Considering a bivariate state space model the transition coefficient of C_{i-1} was 0.916 when elevation and previous carbon were used to predict SOC values. When clay content and previous carbon were used to predict SOC values the C_{i-1} transition coefficient decrease to 0.602. Therefore the importance of clay content was higher than the elevation at transect 1. The transition coefficient of clay content at transect 1 was 0.311 and it increased to 0.902 at transect 2. Therefore the clay content importance increased. The direction influenced the transitions coefficients and the importance of previous values. In this case the small variance in the beginning of the transect 2 could be responsible for these results. The addition of elevation in the equations did not improve the estimative of SOC for both transects.

If we compare linear regression with state space analysis, we observed that state space equations described SOC better than any respective linear regression equations (Table 3). Similar results was found by Timm et al. (2004) and Awe et al (2015).

Table 2. Transition coefficients for the optimal state-space equation of SOC using carbon content (C_{i-1}), elevation ($Elev_{i-1}$) and clay ($Clay_{i-1}$).

Autoregressive State Space Analysis	R ²	AIC
Transect 1		
SOC = 0.916* C_{i-1} + 0.079* $Elev_{i-1}$	0.47	-223.45
SOC = 0.602* C_{i-1} + 0.311* $Clay_{i-1}$	0.99	-238.48
SOC = (-0.708* C_{i-1}) + 0.121* $Elev_{i-1}$ + 1.564* $Clay_{i-1}$	0.99	-377.67
Transect 2		
SOC = 1.033* C_{i-1} + (-0.008)* $Elev_{i-1}$	0.64	-276.99
SOC = 0.102* C_{i-1} + 0.902* $Clay_{i-1}$	0.99	-272.71
SOC = 0.053* C_{i-1} + 0.049* $Elev_{i-1}$ + 0.912* $Clay_{i-1}$	0.99	-434.86

Table 3. Linear regression to describe SOC values.

Linear regression models	R2
$SOC = 5.566 - 3.286 * Elev$	0.29
$SOC = 20.06 - 6.51 * Sand$	0.52
$SOC = -0.44134 + 0.7105 * Clay$	0.66
$SOC = 20.678 - 2.279 * Elev - 5.625 * Sand$	0.65
$SOC = 0.5883 - 0.6562 * Elev + 0.6568 * Clay$	0.67
$SOC = 5.5413 + 0.5621 * Clay - 1.9380 * Sand$	0.68
$SOC = 10.1081 - 1.1633 * Elev + 0.3992 * Clay - 2.3458 * Sand$	0.70

The observed and estimated values of SOC using state space models and coefficient of determination (r^2) for scaled SOC are showed at figure 6. At these examples were used 50% of the dataset, in this case we take out 1 point of two positions. The marked points are scaled observed data, dotted line are the estimated values using state space model and the continue line represent the standard error for further and for less. The ability of the equation to estimate SOC when used previous values of SOC and Elevation decreased from 0.47 to 0.43 (Figure 6a). For this equation the transition coefficient of previous SOC remained almost the same but the transition coefficient of elevation decreased from 0.079 to 0.008. The relative contribution of elevation in order to estimate SOC was about 8% when used a 100% of data but decreased to below 1% when used 50% of data. The relative contribution of previous SOC was about 92% when used a 100% of data and was 91% when used 50% of data (considering previous values of C and elevation).

When used previous values of SOC and clay content the coefficient of determination decreased from 0.99 to 0.82 (Figure 6b). The transition coefficient of previous SOC decreased from 0.602 to 0.366. The reliability of state space equations by ignoring 50% of the SOC data was found following the gradual reduction of magnitude of the transition coefficient of SOC and coefficient of determination. Similar results also were found by Timm et al. (2011) and Awe et al. (2015).

When a trivariate state space model was used a considerable changes of transitions coefficients occurred and the coefficient of determination decrease from 0.99 to 0.88 (Figure 6c). The transition coefficient of elevation remained with a low value. The transition coefficient of SOC was negative and the coefficient of clay was higher than 1.

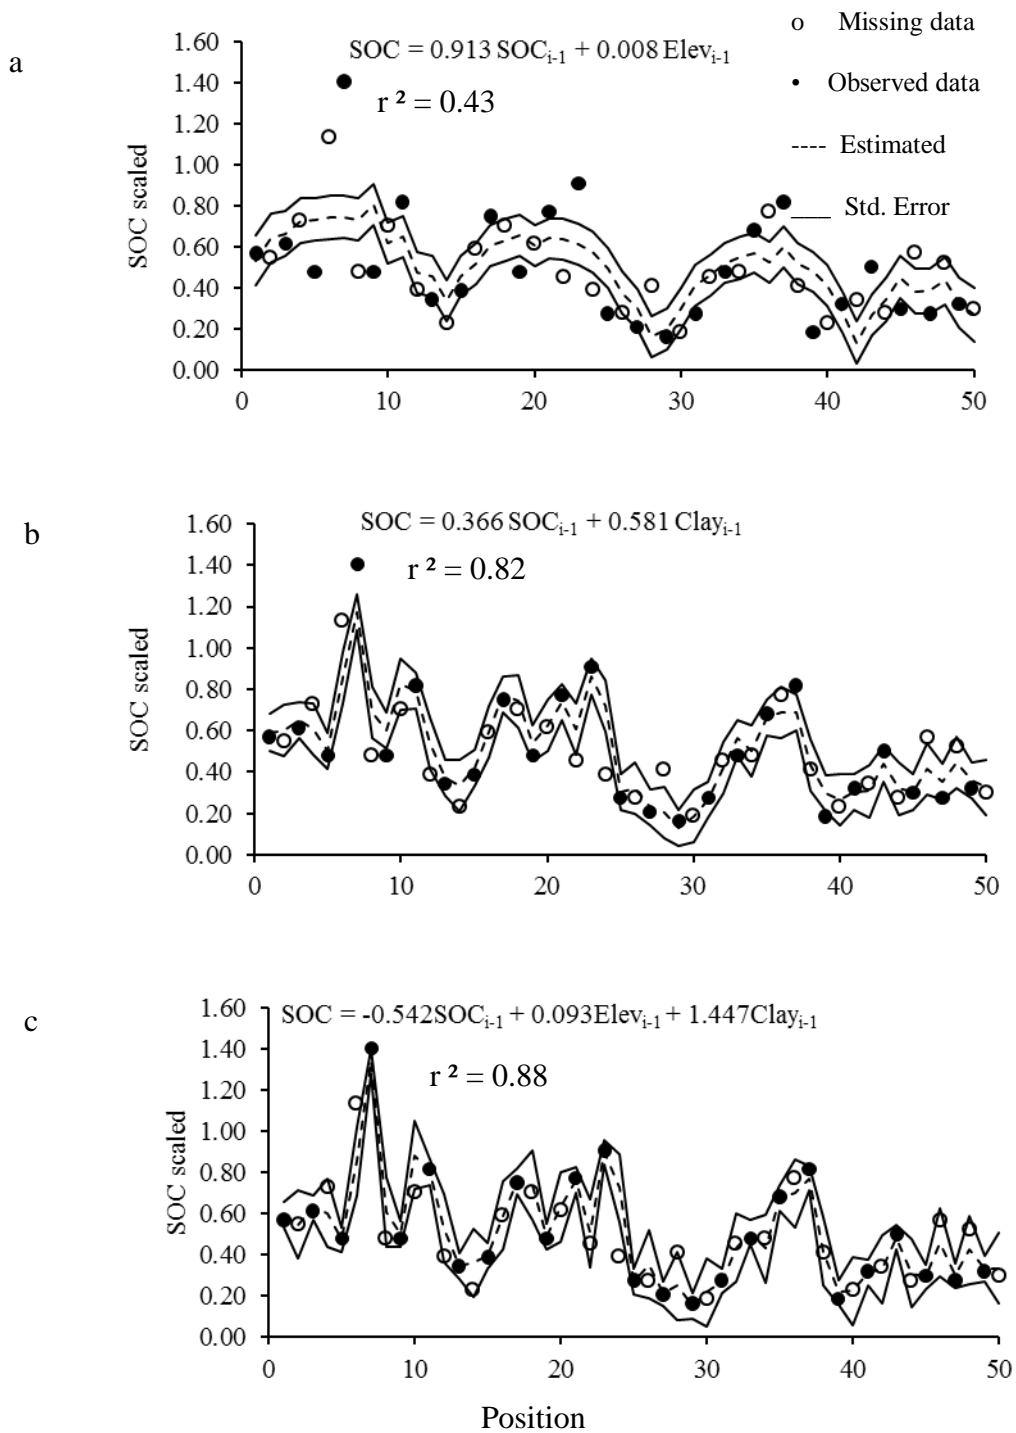


Figure 6. State space analysis of scaled soil organic carbon of 50% of dataset.

Considering 50% of dataset in the transect 2, the ability of the state equation estimate SOC when used previous values of SOC and Elevation decreased from 0.64 to 0.51 (Table 4). When used previous values of SOC and clay content the determination coefficient decreased from 0.99 to 0.78 (Table 4). The transition coefficient of previous SOC with 100% of dataset was 0.102 and increased to 1.061. The transition coefficient of clay was 0.902 and decreased

to -0.055. In general the determination coefficient decreased more in transect 2 than the transect 1 when considering 50% of dataset.

Table 4. Transition coefficients for the optimal state-space equation of SOC using 50 % of dataset of carbon content (C_{i-1}), elevation ($Elev_{i-1}$), clay ($Clay_{i-1}$) for transect 2.

Autoregressive State Space Analysis	r^2	AIC
$SOC = 1.022 * C_{i-1} + (-0.0007) * Elev_{i-1}$	0.51	-317.63
$SOC = 1.061 * C_{i-1} + (-0.055) * Clay_{i-1}$	0.78	-331.68
$SOC = 0.168 * C_{i-1} + 0.028 * Elev_{i-1} + 0.802 * Clay_{i-1}$	0.83	-543.42

4.6 CONCLUSIONS

Spatial statistical tools can be used to analyze spatial distribution of SOC in grassland and can be used to understand which soil properties are contributing with the spatial distribution of SOC.

Sample design was able to show the spatial relation and scale dependence of some soil properties and correlated each other. Therefore we can use it to explain the spatial distribution of some soil properties.

The landscape is important in spatial distribution of SOC, clay and sand. The importance of each soil property varied. Previous clay content was more important to estimate SOC than elevation.

The direction of transect influenced the autocorrelation values. The spatial correlation tended to increase at transect 2. The direction of transect influenced the transitions coefficients magnitude and the contribution of each soil property in order to estimate SOC. However the direction did not influence the prediction of SOC when clay was used in the equation. When elevation was used the direction influenced the prediction of SOC.

The state-space approach provided a comprehensive description of SOC and the relative contribution of each variable could be estimated.

4.7 ACKNOWLEDGEMENTS

The authors thank to Brazilian Federal Agency for Support and Evaluation of Graduate Education - CAPES, under Science without Borders Program, for provide fund by “Special visiting researcher program” (number 152140). CAPES PVE-8888.030464/2013-01.

5. CAPÍTULO III

FUNÇÕES DE PEDOTRANSFERÊNCIA PARA DETERMINAÇÃO DA RETENÇÃO DA ÁGUA NO SOLO PARA A REGIÃO DE SEROPÉDICA, RJ

5.1 RESUMO

As informações das propriedades físico-hídricas (hidráulicas) dos solos são requeridas por diversos campos da ciência, sendo estas utilizadas nos estudos da movimentação de solutos nos solos, drenagem, no manejo da água destinado a irrigação, quantificar o efeito do manejo do solo sobre suas propriedades físicas, em alguns modelos matemáticos que estudam o movimento da água nas bacias hidrográficas entre outros. Porém, sua determinação requer muito tempo de laboratório e de coletas de campo. São custosas de se medir e podem mudar com o tempo devido alteração nas características físicas dos solos. A modelagem matemática aplicada às ciências agrárias ganha cada vez maior importância, já que ela pode auxiliar na determinação destes parâmetros físico hídricos com mais rapidez e menores custos. Ela vem sendo realizada com objetivo de prever as propriedades físico-hídricas dos solos que são mais difíceis de medir, a partir de propriedades mais fáceis de medir. As funções elaboradas são chamadas de “*funções de pedotransferência*”. Neste sentido, o objetivo deste trabalho foi elaborar funções de pedotransferência capazes de prever o conteúdo de água do solo referente à tensão da água na capacidade de campo, 80 kPa e ponto de murcha permanente. Um banco de dados com 367 pontos amostrais gerado no Sistema Integrado de Produção Agroecológica foi utilizado na geração destas funções. O banco de dados foi subdividido em 75%, 50% e 30% dos dados com objetivo de gerar a função (treinamento) e 25% dos dados foram utilizados na validação da mesma. Utilizou-se também um banco de dados externo a este para validar a função. Os atributos elevação, argila e areia apresentaram boa correlação com a retenção de água para os três pontos estudados, enquanto densidade do solo não apresentou correlação com a retenção de água. A capacidade de predição da função não variou com o número de pontos utilizados para se gerar a função. Não houve diferença significativa dos coeficientes de determinação das equações que utilizaram um maior número de atributos das equações que utilizaram menor número de atributos. Sendo que as equações que utilizaram areia e argila como variável independente não foram significativamente melhores que as equações que utilizaram somente a areia como variável independente. As funções mostraram boa capacidade de prever as características físico-hídricas da região.

Palavras chaves: Funções de pedotransferência. Retenção de água no solo. Capacidade de campo. Ponto de murcha permanente.

5.2 ABSTRACT

The hydraulic and physical information of the soils are demanded by a lot models in soil science. It is used to study the solute infiltration in the soils, drainage, water management and irrigation, to study the effect of soil management on soil physical properties, mathematical models, among others. But the determination of these properties demands a lot of time of laboratory and field work. These analyses are expensive and the values can change with the time and space. Mathematical models applied in agriculture can help us to determine soil physical parameters quickly and cheaper. It has been used to estimate soil physical properties which are difficult to measure from soil properties easiest to measure. The equations are called by “**pedotransfer functions**”. The aim of this study was to elaborate functions in order to estimate the soil moisture related to the field capacity, 80 kPa and permanent wilting point. A dataset with 367 points collected at Integrated System of Agroecological Production was used to create the functions. The dataset was divided in 75%, 50% and 30% in order to training the functions and 25% of the data were used to validate the function. A external dataset was used to validate the function too. Elevation, clay and sand content showed a correlation with soil water retention. Bulk density did not showed a correlation with soil water retention. The number of data used to generate the function did not change the function ability to estimate the soil water retention. We did not observe difference between determination coefficients of the equations which used more attributes than the equations that used a few attributes. The equations that used sand as independent variable showed a good ability to estimate water retention. These results demonstrated the applicability of the elaborated equations in predicting soil water retention.

Key words: Pedotransfer functions. Soil water retention. Field capacity. Permanent wilting point.

5.3 INTRODUÇÃO

Informações sobre as propriedades físico-hídricas (hidráulicas) dos solos são requeridas por várias áreas de pesquisa: ciências agrícolas, engenharia civil, hidrologia, engenharia ambiental, ecologia, etc. Dentre as propriedades hidráulicas mais estudadas, duas se destacam: a curva de retenção de água no solo (CRA), a qual ilustra a relação entre o potencial matricial da água no solo e o volume de água encontrado no mesmo (cm^3 de H_2O / cm^3 de solo); e a condutividade hidráulica do solo que estuda o movimento da água no solo em ambiente saturado e não saturado (van Genuchten e Nielsen, 1985). As características físico-hídricas têm aplicação no estudo de predição do movimento de solutos no solo, nos estudos de drenagem, na disponibilidade de água às plantas, quantificar o efeito do manejo do solo sobre as propriedades físicas dos solos e em alguns modelos matemáticos que estudam o movimento da água nas bacias hidrográficas (Timlin et al, 2004).

Apesar de serem informações importantes, a determinação das propriedades físico-hídricas em laboratório requer muito tempo, desde a coletas de amostras indeformadas de solo a posterior determinação. São custosas de se medir e podem mudar no tempo e no espaço sobretudo devido ao manejo do solo. Além disso, devido à natureza altamente variável das propriedades físico-hídricas no espaço, são necessárias grandes quantidades de amostras para conseguir caracterizar apropriadamente a variabilidade espacial.

Estudos mostram que a dificuldade relatada pode ser resolvida a partir da modelagem matemática. Na ciência do solo, a modelagem matemática vem sendo feita para prever as propriedades físico-hídricas dos solos de mais difícil medição, a partir de propriedades mais fáceis de medir. As funções elaboradas são chamadas de “*funções de pedotransferência*”. O termo função de pedotransferência (FPT) foi primeiramente usado por Bouma (1989) e na essência transformam dados que temos em dados que queremos (Wosten et al., 2001). O estudo das FPT é campo ainda em crescimento, revisões podem ser lidas em Rawls (1991), Pachepsky et al. (1999), Wosten et al. (2001), Barros e Van Lier (2014), Botula et al. (2014).

O modelo utiliza propriedades do solo de fácil medição (Lin et al., 1999), sendo necessária uma base de dados que represente as características dos solos de determinada região. Segundo Wosten et al. (2001), os estudos de funções de pedotransferência predizem funções retiradas dos bancos de dados e as aplicam para os dados que necessitamos.

As regressões lineares são usadas para explicar ou estimar o comportamento de determinada variável, denominada de variável dependente, a partir de variáveis explicadoras ou independentes. Portanto, ambas variáveis devem apresentar correlação. As FPTs possuem a habilidade de predição, ou seja, são expressões matemáticas capazes de estimar certas propriedades dos solos a partir de outras regularmente medidas (McBratney et al., 2002).

A textura, densidade do solo, teor de carbono, porosidade tem sido utilizados por diversos autores como atributos independentes para, a partir destes, estimar propriedades hídricas dos solos através das equações de pedotransferência (Minasny et al., 1999; McBratney et al. , 2002; Tomasella et al., 2003; Merdun et al, 2006). Já que estes atributos usados como variáveis independentes possuem relação com a capacidade dos solos reterem água. Estas funções têm apresentado razoáveis resultados para um amplo número de aplicações. Portanto, o objetivo deste trabalho foi desenvolver funções de pedotransferência a partir de um banco de dados levantado no Sistema Integrado de Produção Agroecológica (SIPA) capaz de estimar o conteúdo de água do solo referente à tensão da água na capacidade de campo, 80 kPa e ponto de murcha permanente. A partir do reconhecimento do conteúdo de água retida na capacidade de campo e no ponto de murcha permanente pode-se realizar o manejo racional da água nos sistemas agrícolas. Assim, a partir das informações da retenção de água no solo, o planejamento e uso dos recursos hídricos podem ser potencializados.

5.4. MATERIAL E MÉTODOS

5.4.1 Localização e caracterização da área de estudo

O estudo foi realizado no Sistema Integrado de Produção Agroecológica (SIPA), localizado no município de Seropédica, Estado do Rio de Janeiro, Brasil. O clima da região é classificado como Aw (Sistema de classificação Köppen), com predomínio de elevadas temperaturas no verão e temperaturas médias no inverno (Embrapa, 1999), possuindo temperatura média anual de 24.5°C, as chuvas são concentradas no período entre Novembro a Março com média anual de precipitação de 1213 mm. Na área de estudo predominam-se os solos classificados como Planossolos e Argissolos (Embrapa, 1999). O SIPA possui área total de 59 ha, sendo parte desta área destinada a realização de experimentos com produção vegetal, parte destinada ao cultivo de pastagem destinada a produção de gado leiteiro e outra área destinada a reserva ambiental. Mais detalhes a respeito das características dos solos da região são encontrados em Silva (2001) e Ceddia (2009).

As amostragens foram feitas na área destinada a realização dos experimentos e na área de pastagem totalizando 6,24 ha (Villela, 2009). Abrangendo as principais classes de solos (Argissolo, Planossolo, Cambissolo) e as principais classes texturais (areia, areia franca, franco arenosa e franco argilosa) encontradas na “toposequência” típica da região de Seropédica.

5.4.2 Distribuição, coleta dos pontos amostrais e geração do banco de dados.

Para caracterizar a distribuição espacial dos atributos físicos dos solos encontrados na área estudada, no ano de 2001 foi realizada uma campanha de coleta de amostras. A distribuição espacial dos pontos amostrais foi realizada através de um grid irregular (Figura 1). Para cada um dos pontos amostrais, as coordenadas UTM foram medidas usando um GPS com correção diferencial. Permitindo, portanto, a geração de mapas temáticos.

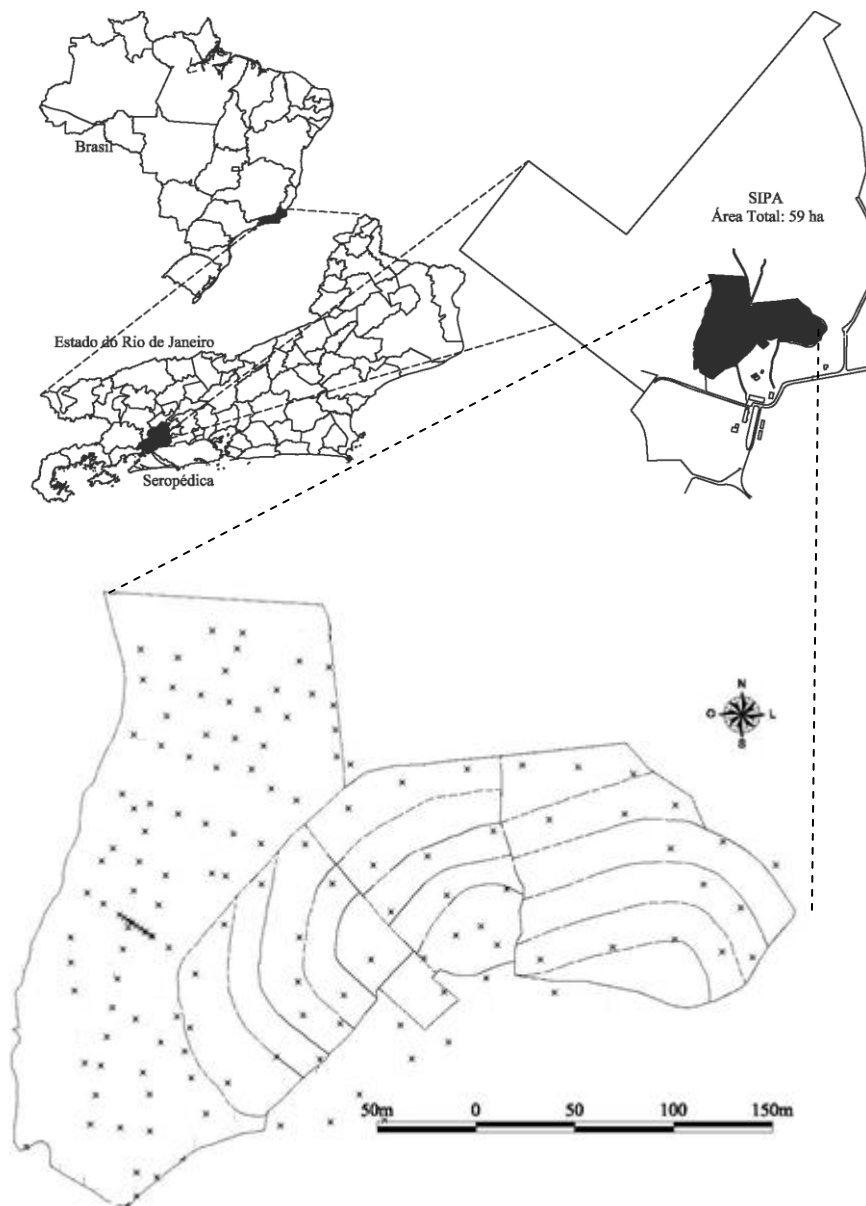


Figura 1. Localização do SIPA e distribuição dos pontos amostrais na área de estudo (Adaptado de Villela, 2009).

5.4.3 Análises físicas

Nos pontos amostrais foram realizadas coletas de amostras indeformadas de solos nas profundidades de 0,00 a 0,10m, 0,10 a 0,20m e 0,20 a 0,30m com a finalidade de se medir as seguintes características físicas: capacidade de retenção de água na tensão de 10 kPa (neste estudo considerado como a tensão da água no solo referente à capacidade de campo), capacidade de retenção de água na tensão de 80 kPa (considerando o limite da leitura do tensiômetro), capacidade de retenção de água na tensão de 1500 kPa (neste estudo considerado como a tensão da água no solo referente ao ponto de murcha permanente). Após determinação das características físico-hídricas, as amostras foram secas para determinação da granulometria pelo método da pipeta e densidade da partícula pelo método do balão volumétrico e a densidade do solo ($\text{kg} \cdot \text{dm}^{-3}$), seguindo o manual de análises de solos da Embrapa (Embrapa, 1997). Também foram medidos os valores da elevação do terreno (m) em

cada ponto amostral. A água facilmente disponível (AFD) foi calculada a partir da subtração dos valores de umidade do solo ($\text{cm}^3 \cdot \text{cm}^{-3}$) encontrada na tensão de 10kPa pela umidade encontrada a 80kPa ($\text{AFD} = \Theta_{10\text{kPa}} - \Theta_{80\text{kPa}}$). A água disponível total (ADT) foi determinada a partir da subtração dos valores de umidade do solo ($\text{cm}^3 \cdot \text{cm}^{-3}$) encontrada na tensão de 10kPa pela umidade encontrada a 1500kPa ($\text{ADT} = \Theta_{10\text{kPa}} - \Theta_{1500\text{kPa}}$). A retenção da água no solo foi determinada em câmara de pressão, Extrator de Richards.

As curvas de retenção de água no solo foram ajustadas pelo método proposto por Van Genuchten (1980), considerando o valor do parâmetro “m” como sendo $m = 1 - (1/n)$. Os parâmetros da curva foram estimados através do software RETC (versão 6.02).

5.4.4 Análise estatística e elaboração da função de pedotransferência.

O conjunto de dados utilizado para a elaboração das funções de pedotransferência contou com 325 amostras. Os pontos de coleta de solos foram distribuídos por toda a área de estudo (Figura 1) constituindo um sistema de amostragem aleatória simples (Yamamoto e Landim, 2013).

A primeira etapa da elaboração das funções constituiu-se na análise preliminar dos dados com a finalidade de se avaliar a distribuição dos valores dos atributos e verificar a existência de valores atípicos ou “*out-liers*” (Vereecken e Herbst, 2004). Para isso dois procedimentos foram realizados. O primeiro foi a análise através dos gráficos denominados de “*boxplot*” ou diagrama de caixa. Esta análise verifica a distribuição empírica dos dados, considerando a divisão do conjunto de dados em quartis. Os valores dos atributos do solo encontrados nos pontos amostrais que ultrapassem os valores estipulados pelo limite inferior e pelo limite superior do “*boxplot*” são considerados “*outliers*”, ou seja, estes valores apresentam comportamento distinto dos demais. Por possuir comportamento distinto, estes valores são retirados do conjunto de dados para a geração da regressão. Este procedimento foi realizado através do pacote “*Action*”, o qual trabalha com o programa “Microsoft Excel”.

O segundo procedimento foi realizado através da plotagem dos atributos estudados nos gráficos de dispersão (“*scatter plot*”), analisando-se dois conjuntos de dados simultaneamente. Pontos que apresentaram comportamento distinto da grande maioria dos dados na relação entre os eixos “x” e “y”, foram considerados “*outliers*” e retirados do conjunto de pontos que foram utilizados para geração da função de pedotransferência (Figura 2).

O conjunto de dados utilizados no treinamento e validação da função distribuiu-se por todos os tipos de solos e todas as classes texturais encontradas na área do estudo.




Figura 2. Gráfico de dispersão entre as variáveis areia x umidade 10kPa (00-10cm) com objetivo de detectar valores atípicos.

Considerando a necessidade de se avaliar a capacidade de predição das funções elaboradas, utilizou a validação cruzada (“*cross-validation*”) como método estatístico para realizar esta análise. A validação cruzada consiste na divisão dos dados em *treinamento* e *validação*. O conjunto de dados agrupados no treinamento foram utilizados para elaboração da função de pedotransferência, enquanto que os dados agrupados na validação foram utilizados para avaliar a capacidade de predição da função elaborada. A divisão dos dados em desenvolvimento e validação foi realizada de maneira semi aleatória. A divisão foi semi aleatória já que se tinha a intenção de que todas as classes de solos e texturas estivessem distribuídas em ambos os conjuntos de treinamento e validação.

Os conjuntos de dados utilizados no treinamento da função de pedotransferência contaram com 75%, 50% e 30% do total de dados. O conjunto de validação contou com 25% dos dados. Os 25% dos dados utilizados para a validação foram os mesmos para os três conjuntos de dados utilizados no treinamento. Primeiramente foram selecionados 75% dos dados de treinamento e depois os 25% de validação. Após geração da função com os 75% dos dados, esse conjunto de dados foi sorteado novamente com o objetivo de gerar 50% dos dados. Após a geração da equação referente aos 50% dos dados, o mesmo foi sorteado novamente com objetivo de gerar 30% dos dados (Figura 3). Com objetivo de avaliar se a capacidade de predição da função estaria relacionada com o conjunto de dados sorteados, os mesmos foram sorteados três vezes para geração de três funções (I, II, III).

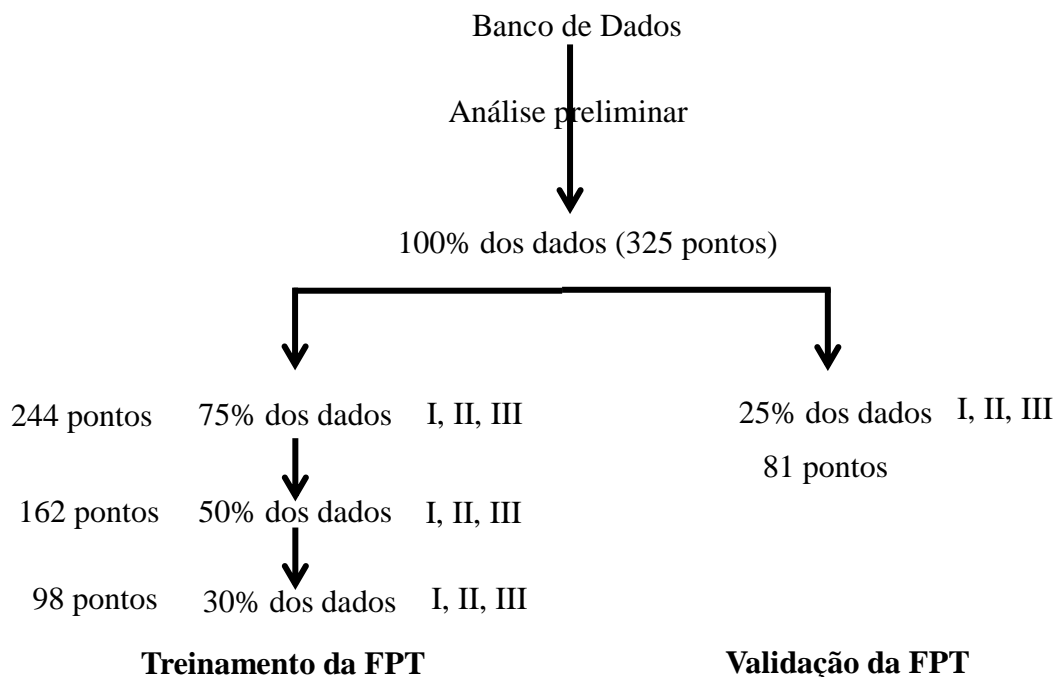


Figura 3. Esquema do desenvolvimento das funções de pedotransferência.

Um segundo método denominado de “validação externa” foi utilizado para avaliar a capacidade de predição das funções elaboradas. A validação externa neste estudo consistiu na utilização de dados que foram gerados fora do banco de dados utilizados para geração da função. Parte dos dados usados na validação foi gerada dentro do SIPA, como é o caso dos estudos realizados por Pereira (2006), Andrade et al. (2014) além dos dados medidos durante a realização deste estudo no Módulo Experimental de Produção de Hortaliças localizado no SIPA, porém fora da área de domínio do banco de dados inicial. Além destes, a validação foi realizada com dados gerados fora do SIPA a partir do estudo realizado por Jaccoud (1976).

5.4.5 Geração de funções a partir dos métodos de regressão linear

As funções foram elaboradas a partir de regressões lineares e foram geradas para se determinar a capacidade de retenção de água no solo na tensão da capacidade de campo (10kPa), capacidade de retenção de água a 80 kPa (considerando o limite da leitura do tensiômetro), capacidade de retenção de água no ponto de murcha permanente (1500kPa). As variáveis independentes consideradas neste estudo foram: conteúdo de areia (%), conteúdo de argila (%), densidade do solo ($\text{kg} \cdot \text{dm}^{-3}$), elevação (m) e a umidade retida na capacidade de campo (%), esta última variável utilizada para estimar os valores na tensão de 80kPa e 1500kPa.

Após análise preliminar dos dados e cálculo da estatística descritiva, o primeiro passo para a geração da função foi determinar quais variáveis independentes estariam relacionadas às variáveis dependentes. Para isso, foi calculada a análise correlação de Pearson. Além disso, foram elaborados gráficos de dispersão entre os atributos estudados. Estes gráficos foram importantes para demonstrar a natureza da relação entre os atributos. As variáveis dependentes foram consideradas no eixo y e as variáveis independentes no eixo x. Ambas as análises foram importantes para contribuir na escolha das variáveis regressoras.

A escolha das variáveis predictoras foi realizada pela adição e retirada manual das variáveis. Adicionou-se uma variável ao modelo e avaliou sua contribuição na predição da

variável dependente. Continuou-se com a adição de variáveis avaliando se sua capacidade de predição melhorou ou não. O teste F (0.05 de significância) foi utilizado para ajudar na escolha das variáveis independentes.

Após elaboração das funções realizou-se o estudo da dispersão dos resíduos. A normalidade dos resíduos é requisito fundamental para avaliar o ajuste da regressão para que seus resultados sejam mais confiáveis. Para isso utilizou-se o teste de Kolmogorov Smirnov, realizado no software “Action”.

Após desenvolvimento das funções, utilizaram-se as variáveis preditores do conjunto de dados destinados à validação para estimar as variáveis capacidade de campo (10 kPa), água retida na tensão de 80 kPa e ponto de murcha permanente (1500 kPa). Os valores estimados a partir das equações de regressão de linear foram comparados com os valores medidos. A diferença entre os valores medidos e calculados foram utilizados para determinação do erro médio absoluto (Mean Absolut Error – MAE), a raiz do erro quadrático médio (Root Mean Square Error – RSME) e coeficiente de determinação (r^2). Estes parâmetros foram utilizados para avaliar a capacidade de predição das funções.

$$MAE = \frac{1}{n} \sum_{i=1}^n |P_i - O_i| \quad (1)$$

$$RSME = \left(\frac{1}{n} \sum_{i=1}^n (P_i - O_i)^2 \right)^{-0,5} \quad (2)$$

onde, n corresponde ao número de observações realizadas, P_i corresponde aos valores estimados a partir das equações e O_i valores observados.

5.5. RESULTADOS E DISCUSSÃO

5.5.1 Elaboração das funções de pedotransferência

A estatística descritiva para as propriedades físicas e de retenção de água dos solos utilizados para a elaboração das funções de pedotransferência (Tabela 1) indica que os 75%, 50% e 30% dados utilizados para a geração das funções não são significativamente diferentes entre si e não são significativamente diferentes dos dados usados para validação da função 25%, conforme observado pela comparação entre os valores médios dos atributos. As quantidades referentes a areia e argila variaram de 55% a 97% ($550 \text{ g} \cdot \text{kg}^{-1}$ a $970 \text{ g} \cdot \text{kg}^{-1}$) e de 1% a 37% ($10 \text{ g} \cdot \text{kg}^{-1}$ a $370 \text{ g} \cdot \text{kg}^{-1}$); a densidade do solo entre 1,19 a $1,90 \text{ g} \cdot \text{cm}^{-3}$; a elevação variou entre 22,6 a 37,2 m, a capacidade de campo entre 3,20% e 36,1% ($0,032$ a $0,361 \text{ cm}^3 \cdot \text{cm}^{-3}$), a água retida a 80 kPa entre 1,4% e 31,8% ($0,014$ a $0,318 \text{ cm}^3 \cdot \text{cm}^{-3}$), o ponto de murcha permanente entre 0,8% e 23,7% ($0,008$ a $0,237 \text{ cm}^3 \cdot \text{cm}^{-3}$).

Observa-se no triângulo textural que nos solos estudados há a predominância da fração areia (Figura 4). A textura do solo estudado foi classificada como areia, areia franca, francoarenosa, franco-argiloarenosa, sendo a classificação areia a que ocorre com maior frequência nas três profundidades de amostragem (Figura 5). Este resultado está de acordo com as características dos solos encontrados no estudo realizado por Silva et. al (2001) e pelo levantamento de solos realizado na área do SIPA pela Embrapa (1999), indicando que as características físicas da área estudada é representativa das características dos solos encontrados na região de Seropédica, podendo portanto, ser utilizada para geração de funções de pedotransferência. Os solos na área do SIPA foram classificados como Planossolos, Gleissolos na parte baixa da área e Argissolos na parte mais alta da área (Embrapa, 1999).

Tabela 1. Estatística descritiva das propriedades físico-hídricas representativa dos três grupos de dados para os solos usados na geração e validação das funções de pedotransferência (continua).

	Estatística	Elevação	Ds	Areia	Argila	CC	80 kPa	PMP
75% I	Min.	26,2	1,2	55,0	1,0	3,2	1,4	1,1
	Máx.	37,6	1,9	97,0	34,0	36,1	31,4	23,7
	Média	30,7	1,6	83,7	10,7	12,4	9,1	6,4
	DP	2,3	0,1	10,2	8,6	7,6	6,7	4,9
	Norm.	NN	N	NN	NN	NN	NN	NN
50% I	Min.	26,2	1,3	55,0	1,0	3,2	1,5	1,1
	Máx.	37,6	1,9	97,0	34,0	33,9	26,9	23,7
	Média	30,8	1,6	83,4	10,8	12,6	9,2	6,8
	DP	2,3	0,1	10,5	8,6	7,5	6,6	5,1
	Norm.	NN	N	NN	NN	NN	NN	NN
30% I	Min.	26,2	1,3	58,0	1,0	3,2	1,5	1,1
	Máx.	37,6	1,9	97,0	34,0	30,3	24,8	22,5
	Média	30,8	1,6	83,6	10,8	12,5	9,0	6,8
	DP	2,4	0,1	10,8	8,9	7,5	6,5	5,4
	Norm.	NN	N	NN	NN	NN	NN	NN
25% I	Min.	26,2	1,2	57	1,0	3,7	1,9	0,8
	Máx.	37,6	1,8	97	37	32,5	27,5	23,5
	Média	30,6	1,6	84	10	12,1	8,9	6,6
	DP	2,4	0,1	10,5	9,2	7,5	6,7	5,1
	Norm.	NN	N	NN	NN	NN	NN	NN
75% II	Min.	26,2	1,2	57,0	1,0	3,2	1,5	0,8
	Máx.	37,6	1,9	97,0	37,0	32,5	27,5	23,5
	Média	30,7	1,6	83,8	10,6	12,3	8,9	6,2
	DP	2,3	0,1	10,2	8,8	7,4	6,5	4,7
	Norm.	NN	N	NN	NN	NN	NN	NN
50% II	Min.	26,2	1,2	57,0	1,0	3,2	1,5	0,8
	Máx.	37,6	1,9	97,0	37,0	32,5	27,5	23,5
	Média	30,7	1,6	83,8	10,9	12,4	9,0	6,3
	DP	2,4	0,1	10,7	9,2	7,7	6,6	4,9
	Norm.	NN	N	NN	NN	NN	NN	NN
30% II	Min.	26,2	1,2	58,0	1,0	3,2	1,5	1,1
	Máx.	37,6	1,8	97,0	35,0	32,5	27,5	22,5
	Média	30,8	1,6	83,5	11,5	12,7	9,3	6,8
	DP	2,5	0,1	11,1	9,4	8,0	6,8	5,4
	Norm.	NN	N	NN	NN	NN	NN	NN
25% II	Min.	26,2	1,3	55	2	3,7	1,4	1,1
	Máx.	37,6	1,8	97	31	36,1	31,8	23,7
	Média	30,9	1,6	83,4	10,3	12,6	9,5	6,6
	DP	2,5	0,1	10,8	8,7	8,3	7,5	5,3
	Norm.	NN	N	NN	NN	NN	NN	NN
75% III	Min.	26,2	1,2	55,0	1,0	3,2	1,4	1,1
	Máx.	37,6	1,9	97,0	35,0	33,9	29,5	23,7
	Média	30,9	1,6	83,1	11,0	12,7	9,3	6,7
	DP	2,3	0,1	10,2	8,6	7,3	6,4	4,9
	Norm.	NN	N	NN	NN	NN	NN	NN

Tabela 1. Continuação

50% III	Min.	26,5	1,3	55,0	1,0	3,2	1,4	1,1
	Máx.	37,6	1,9	97,0	35,0	33,9	29,5	23,7
	Média	31,2	1,6	82,0	12,2	13,3	9,9	7,2
	DP	2,3	0,1	10,8	9,0	7,7	6,7	5,2
	Norm.	NN	N	NN	NN	NN	NN	NN
30% III	Min.	26,5	1,3	55,0	1,0	3,2	1,4	1,1
	Máx.	37,6	1,8	97,0	35,0	33,9	29,5	23,7
	Média	31,0	1,6	82,0	12,3	13,4	10,0	7,2
	DP	2,2	0,1	11,0	9,3	7,8	7,0	5,6
	Norm.	NN	N	NN	NN	NN	NN	NN
25% III	Min.	26,2	1,2	57	1	3,6	1,6	0,8
	Máx.	36,9	1,8	96	37	36,1	31,8	20,9
	Média	30,1	1,6	85,5	9,3	11,1	8,2	5,3
	DP	2,4	0,1	10,5	9,1	8,3	7,5	4,9
	Norm.	NN	NN	NN	NN	NN	NN	NN

Elevação (m), Ds _ densidade do solo ($\text{g} \cdot \text{cm}^{-3}$), Areia (%), Argila (%), CC _ capacidade de campo (%), 80 kPa _ água retida na tensão de 80 kPa (%), PMP _ ponto de murcha permanente (%), Teste de normalidade Kolmogorov Smirnov, pvalue _ 0,05, NN _ Não Normal, N _ Normal.




Figura 4. Triângulo textural do banco de dados usados para geração e validação da função de pedotransferência.




Figura 5. Proporção das classes de textura encontradas na área utilizada para elaboração da função de pedotransferência.

O coeficiente de correlação de Pearson contribui para o entendimento da relação entre os atributos estudados. Quanto mais próximo o valor da correlação estiver de 1 ou -1, mais correlacionados os atributos estarão. Os sinais positivos e negativos indicam se a associação é diretamente proporcional, neste caso positivo, ou se a associação é inversamente proporcional, sinal negativo.

Conforme observado na tabela de correlação de Pearson (Tabela 2), entre os atributos estudados, a elevação possui correlação positiva com a umidade correspondente à capacidade de campo (CC), 80kPa e ponto de murcha permanente (PMP), ou seja, à medida que a elevação do terreno aumenta, a retenção de água do solo também aumenta. A elevação possui correlação positiva após a cota 30 m, uma vez que conforme observado no gráfico de correlação, a retenção de água aumenta a partir desta cota (Figura 6a, 6b, 6d). Até a cota 30 m aproximadamente, a retenção de água não aumenta com a elevação.

O teor da fração areia apresentou correlação negativa e a argila correlação positiva com os valores de CC, 80kPa e PMP, conforme observado no teste de correlação de Pearson (Tabela 2) e nos gráficos de correlação (Figura 6f, 6g, 6h, 6i, 6j, 6k). Os atributos areia e argila apresentaram relação linear com os valores de capacidade de campo. O uso dos valores de areia e argila para estimar a capacidade de retenção de água nos solos são amplamente relatados na literatura como, da Silva (1990), Arruda et al. (1997), Tomasella et al. (2000), Balbino et al. (2002), Michelin et al. (2010), Barros et al. (2013). Não foi observada correlação entre o atributo densidade do solo e CC, 80kPa, PMP para os solos estudados (Figura 6l, 6m, 6n).

A classe textural predominante nos solos da área estudada é a arenosa. A fração areia influencia fortemente as propriedades hídricas dos solos, resultando em baixa retenção e baixa disponibilidade de água. Os solos arenosos apresentam grande volume de macroporos e suas partículas apresentam menor superfície específica se comparada à partícula de argila. A

superfície específica possui um importante papel na adsorção e dessorção das moléculas de água no solo (Petersen et al., 1996). A distribuição dos poros e as características de superfície das partículas granulométricas explicam fisicamente a capacidade da baixa retenção e da baixa disponibilidade de água nos solos arenosos.

Tabela 2. Matriz de correlação de Pearson entre os atributos estudados usando as três profundidades estudadas.

	Elevação	Ds	Areia	Argila	Pt	Aeração	CC	80 kPa	PMP
Elevação	1								
Ds	-0,11	1							
Areia	-0,73	0,27	1						
Argila	0,73	-0,26	-0,95	1					
Pt	0,017	-0,78	-0,084	0,10	1				
Aeração	-0,60	-0,25	0,71	-0,69	0,56	1			
CC	0,74	-0,33	-0,92	0,91	0,14	-0,74	1		
80 kPa	0,74	-0,32	-0,93	0,93	0,13	-0,73	0,98	1	
PMP	0,58	-0,25	-0,78	0,73	0,096	-0,56	0,75	0,74	1

Ds_ Densidade do solo, Pt_ Porosidade total, CC_ Capacidade de campo, PMP_ Ponto de murcha permanente.

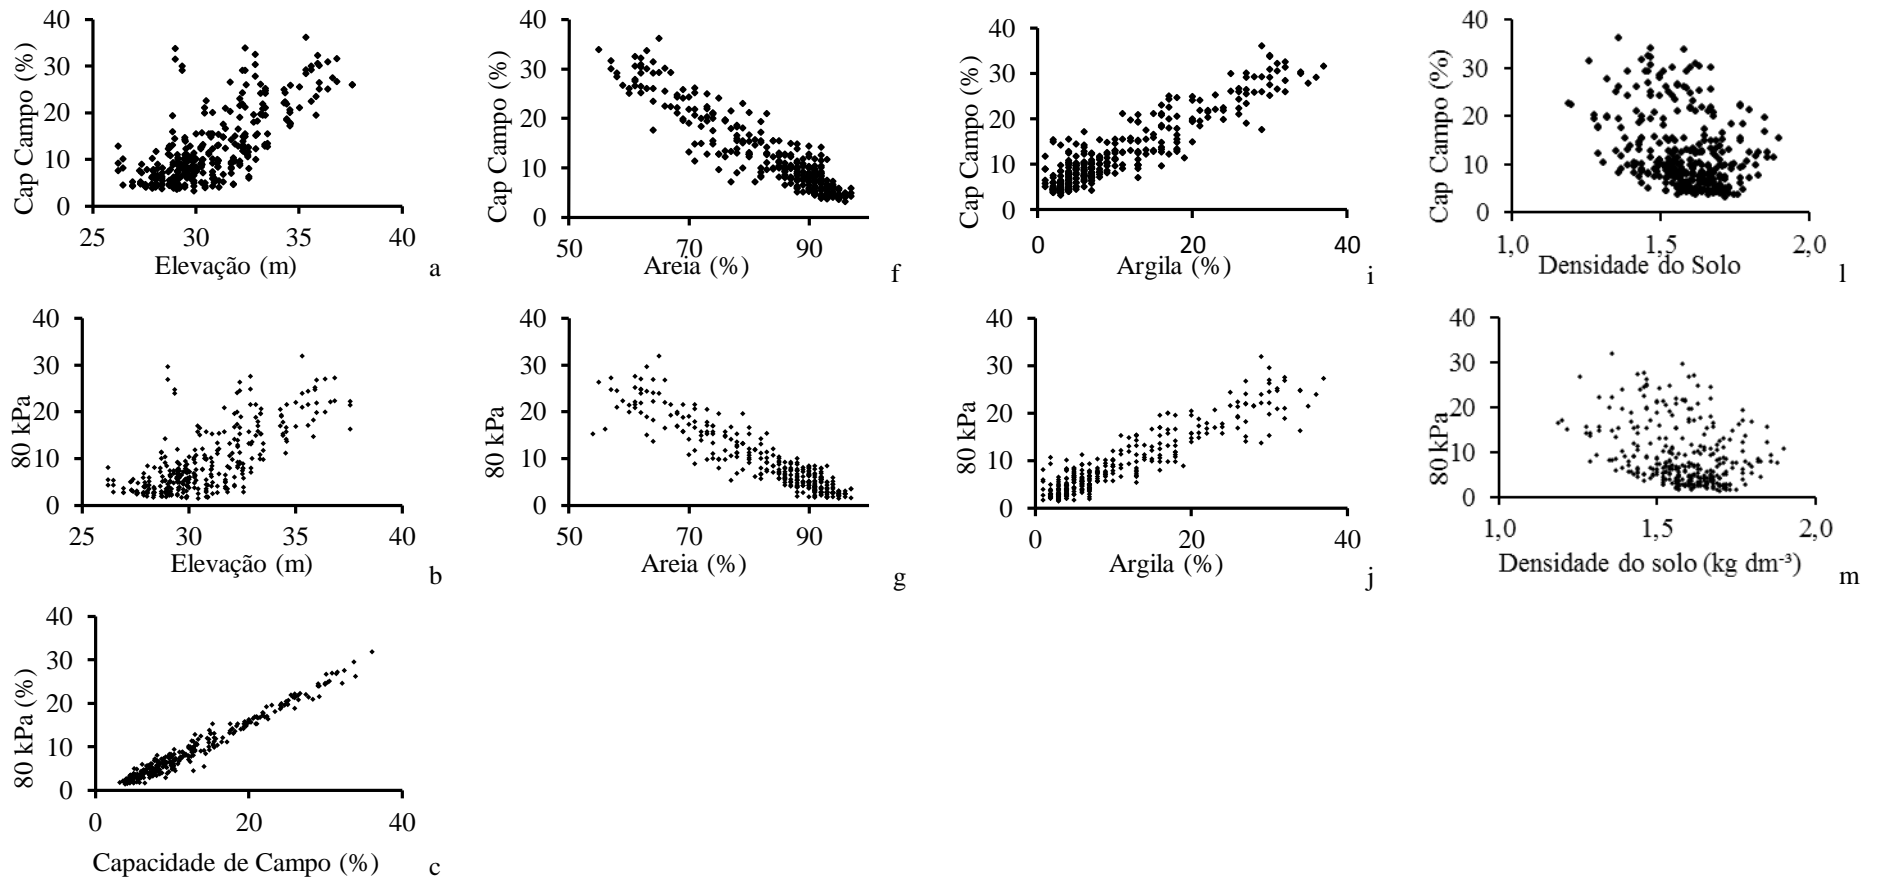
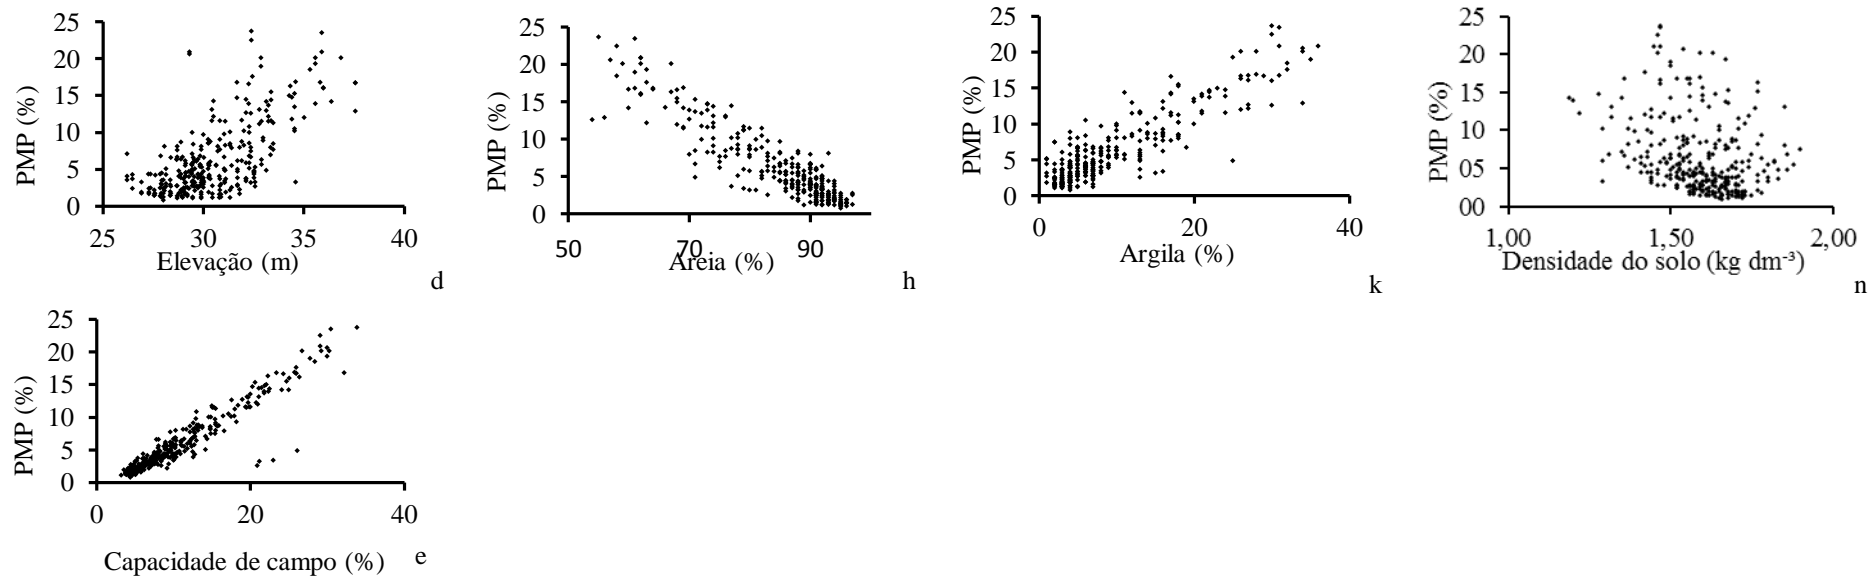


Figura 6. Correlação entre os valores de capacidade de campo (CC) e elevação (a), CC e areia (f), CC e argila (i), CC e densidade do solo (l); 80kPa e elevação (b), 80kPa e areia (g), 80kPa e argila (j), 80kPa e densidade do solo (m), 80kPa e capacidade de campo (c); ponto de murcha permanente (PMP) e elevação (d), PMP e areia (h), PMP e argila (k), PMP e densidade do solo (n), PMP e capacidade de campo (e) nos solos do SIPA.

Figura 6. Continuação



5.5.2 Função de pedotransferência para estimar os valores da capacidade de campo, retenção da água a 80kPa e ponto de murcha permanente para profundidade de 00 a 0,30 m.

As funções de pedotransferência elaboradas com a finalidade de estimar a umidade na capacidade de campo, 80kPa e ponto de murcha permanente são apresentadas nas tabelas 3, 4 e 5. As equações nas tabelas apresentaram o pressuposto da regressão linear que é normalidade dos resíduos. Equação que não tiveram esse pressuposto não foram apresentadas na tabela, o que justifica o diferente número de equações para cada sorteio. As equações, de maneira geral, apresentaram coeficientes de determinação significativos quando usadas no conjunto de dados da validação (25%). A utilização de 75%, 50% e 30% do conjunto de dados utilizados durante o procedimento de treinamento, ou seja, durante a elaboração da função de pedotransferência, apresentaram coeficientes de determinação semelhantes. A partir disto conclui-se que um menor número de pontos, volume de dados, foi capaz de captar as informações a respeito das características físico-hídricas do terreno estudado. Observou-se que os valores do coeficiente de determinação e do RSME variaram pouco com os sorteios I, II, III, quando se utilizaram elevação, densidade do solo, areia e argila como variáveis independentes. As funções foram elaboradas a partir dos dados destinados ao treinamento, porém os valores dos coeficientes de determinação apresentados, são referentes ao uso das equações nos dados destinados à validação.

Observa-se que não houve diferença significativa dos valores de R^2 das equações que utilizaram um maior número de atributos (elevação, densidade do solo, areia e argila) das equações que utilizaram menor número de atributos (areia e argila, areia). Sendo que as equações que utilizaram areia e argila como variável independente não foram significativamente melhores que as equações que utilizaram somente a areia como variável independente. Portanto, como um dos objetivos da elaboração das funções de pedotransferência é facilitar a estimativa de um atributo de maior dificuldade de medição, com o uso de um atributo mais fácil de medir, o uso do teor de areia, neste caso, foi capaz de fornecer informações necessárias para se estimar a retenção da umidade destes solos.

A distribuição dos valores estimados não possui tendência de erro com a variação da textura (Figura 6).

Tabela 3. Equações elaboradas para determinação da capacidade de campo. Equações em negrito foram elaboradas a partir de dados originais, as demais foram elaboradas a partir de dados transformados. As equações que não apresentaram normalidade dos resíduos não foram apresentadas (continua).

%	Equação	R2	RSME	MAE
75%.I	$-2354,38+5896,319*\text{Elev}+(-0,34918*\text{Ds})+(-0,00005*\text{Are})+0,128357*\text{Arg}$	0,81	3,28	2,26
	$-2916,82+7304,105*\text{Elev}+(-0,34653*\text{Ds})+(-0,000062*\text{Are})$	0,79	3,41	2,38
	$3,501879+(-0,000057*\text{Are})+(-0,163321*\text{Arg})$	0,84	2,97	2,18
75%.II	$-2807,51+7029,436*\text{Elev}+(-0,26642*\text{Ds})+(-0,00005*\text{Are})+0,088186*\text{Arg}$	0,85	3,16	2,31
	$3,651496+(-0,000059*\text{Are})+0,117454*\text{Arg}$	0,88	2,92	2,25
	$4,216479+(-0,000071*\text{Are})$	0,87	3,03	2,35

Tabela 3. Continuação

	-2300,85+5761,853*Elev+(-0,23111*Ds)+(-0,000045*Are)+0,145187*Arg	0,90	2,58	1,91
	-2720,19+6812,062*Elev+(-0,23219*Ds)+(-0,000059*Are)	0,90	2,58	1,87
75%.III	-1903,48+4767,97*Elev+(-0,000048*Are)+0,145829*Arg	0,89	2,80	1,99
	3,385234+(-0,000052*Are)+0,170714*Arg	0,88	2,82	2,00
	4,196071+(-0,00007*Are)	0,88	2,83	2,01
50%.I	-2506,82+6277,387*Elev+(-0,31449*Ds)+(-0,000048*Are)+0,116201*Arg	0,83	3,11	2,19
	-1874,33+4695,556*Elev+(-0,000053*Are)+0,108699*Arg	0,85	2,87	2,13
	3,519462+(-0,000055*Are)+0,145578*Arg	0,85	2,88	2,13
	4,195014+(-0,00007*Are)	0,84	2,93	2,24
50%.II	4,231212+(-0,000071*Are)	0,87	3,02	2,19
	-2399,24+6007,801*Elev+(-0,205*Ds)+(-0,000046*Are)+0,13983*Arg	0,89	2,72	1,96
	-2605,35+6524,782*Elev+(-0,20245*Ds)+(-0,000059*Are)	0,89	2,70	1,93
50%.III	-2148,53+5380,66*Elev+(-0,000048*Are)+0,13859*Arg	0,88	2,92	2,06
	32,13+(-0,29*Are)+0,44*Arg	0,85	2,88	2,02
	4,161652+(-0,000069*Are)	0,88	2,89	2,03
	-1593,4+3994,077*Elev+(-0,31952*Ds)+(-0,000055*Are)+0,07209*Arg	0,83	3,07	2,19
	-1984,28+4972,234*Elev+(-0,32215*Ds)+(-0,000061*Are)	0,82	3,11	2,26
30%.I	-850,301+2135,595*Elev+(-0,00006*Ds)+0,076757*Arg	0,85	2,88	2,15
	54,28+(-0,52*Are)+0,17*Arg	0,86	2,74	2,03
	67,58+(-0,66*Are)	0,86	2,82	2,12
	-2023,2+5068,244*Elev+(-0,26557*Ds)+(-0,00005*Are)+0,106261*Arg	0,86	3,06	2,29
30%.II	3,675393+(-0,00006*Are)+0,12186*Arg	0,88	2,90	2,24
	69,13+(-0,67*Are)	0,85	2,91	2,17
	31+0,05*Elev+(-0,67*Ds)+(-0,28*Are)+0,44*Arg	0,88	2,83	1,98
	62,52+0,10*Elev+(-0,11*Ds)+(-0,64*Are)	0,88	2,84	1,97
30%.III	30,80+0,04*Elev+(-0,29*Are)+0,43*Arg	0,85	2,87	2,01
	32,23+(-0,29*Are)+0,44*Arg	0,85	2,88	2,03
	67,27+(-0,65*Are)	0,85	2,88	2,01

Tabela 4. Equações elaboradas para determinação retenção a 80kPa. Equações em negrito foram elaboradas a partir de dados originais, as demais foram elaboradas a partir de dados transformados. As equações que não apresentaram normalidade dos resíduos não foram apresentadas.

%	Equação	R2	RSME	MAE
75%.I	-1615,52+(4047,47*Elev)+(-0,379*Ds)+(-0,000056*Are)+(0,2783*Arg)	0,80	2,96	1,99
	-2835,39+(7100,79*Elev)+(0,3733*Ds)+(-0,000081*Are)	0,76	3,24	2,18
	-984,992+(2470,41*Elev)+(-0,000061*Are)+(0,2753*Arg)	0,85	2,60	1,91
	2,965072 + (-0,000062*Are)+(0,296343*Arg) 60,18+(-0,61*Are)	0,84	2,61	1,93
75%.II	-2904,78+(7274*Elev)+(-0,2955*Ds)+(-0,000079*Are)	0,82	3,07	2,05
	-1760,69+(4410,34*Elev)+(-0,000061*Are)+(0,2213*Arg)	0,88	2,52	1,82
	3,131586 + (-0,000064*Are)+(0,24464*Arg) 58,23+(-0,58*Are)	0,89	2,45	1,79
75%.III	-1734,08+(4343,83*Elev)+(-0,2603*Ds)+(-0,000055*Are)+(0,2451*Arg)	0,90	2,24	1,59
	46,85+0,33*Elev+(-2,94*Ds)+(-0,52*Are)	0,88	2,52	1,69
	22,471+0,16*Elev+(-0,26*Are)+0,36*Arg	0,89	2,45	1,65
	28,07+(-0,27*Are)+0,38*Arg 58,03+(-0,58*Are)	0,89	2,49	1,74
50%.I	-2112,01+(5289,15*Elev)+(-0,3632*Ds)+(-0,000056*Are)+(0,2374*Arg)	0,81	2,81	1,95
	-3179,48+(7960,83*Elev)+(-0,3487*Ds)+(-0,000076*Are)	0,80	2,95	2,10
	27,98+0,23*Elev+(-0,34*Are)+(0,25*Arg)	0,91	2,23	1,67
	36,32+(-0,36*Are)+(0,28*Arg) 57,74+(-0,58*Are)	0,91	2,28	1,74
50%.II	-1454,25+(3642,61*Elev)+(-0,2855*Ds)+(-0,000043*Are)+(0,3858*Arg)	0,88	2,49	1,81
	-2585,33+(6475,09*Elev)+(-0,2204*Ds)+(-0,000079*Are)	0,84	2,93	2,01
	-1224,19+(3067,21*Elev)+(-0,000048*Are)+(0,3661*Arg)	0,89	2,45	1,77
50%.III	22,95+0,13*Elev+(-2,05*Ds)+(-0,22*Are)+0,39*Arg	0,89	2,44	1,62
	51,86+0,17*Elev+(-2,03*Ds)+(-0,54*Are)	0,88	2,58	1,78
	20,88+0,11*Elev+(-0,23*Are)+0,39*Arg	0,89	2,50	1,67
	25,81+(-0,25*Are)+0,40*Arg 57,10+(-0,57*Are)	0,89	2,53	1,73
30%.I	39,60+0,26*Elev+(-4,63*Ds)+(-0,39*Are)+0,15*Arg	0,88	2,77	1,64
	47,54+0,34*Elev+(-4,73*Ds)+(-0,49*Are)	0,87	2,39	1,73
	37,12+0,16*Elev+(-0,41*Are)+0,16*Arg	0,91	2,26	1,74
	43,06+(-0,43*Are)+0,18*Arg 57,09+(-0,57*Are)	0,91	2,29	1,78

Tabela 4. Continuação

	$-891,95+(2162,49*\text{Elev})+(-0,4304*\text{Ds})+(-0,000048*\text{Are})+(0,3317*\text{Arg})$	0,87	2,57	1,85
	$49,91+0,26*\text{Elev}+(-3,83*\text{Ds})+(-0,51*\text{Are})$	0,87	2,60	1,76
	$-1156,26+(2898,15*\text{Elev})+(-0,000055*\text{Ds})+(0,2949*\text{Arg})$	0,88	2,48	1,79
30%.II	$2,782481 + (-0,000057*\text{Are})+(0,316189*\text{Arg})$	0,89	2,45	1,78
	$4,289537 + (-0,000089*\text{Are})$	0,86	2,70	1,94
	$23,34+0,02*\text{Elev}+(0,36*\text{Ds})+(-0,24*\text{Are})+0,42*\text{Arg}$	0,89	2,51	1,71
	$53,47+0,08*\text{Elev}+(1,08*\text{Ds})+(-0,58*\text{Are})$	0,87	2,67	1,83
	$23,45+0,02*\text{Elev}+(-0,23*\text{Are})+0,42*\text{Arg}$	0,89	2,50	1,69
30%.III	$24,49+(-0,24*\text{Are})+0,42*\text{Arg}$	0,89	2,51	1,71
	$58,37+(-0,59*\text{Are})$	0,88	2,65	1,85

Tabela 5. Equações elaboradas para determinação do ponto de murcha permanente. Equações em negrito foram elaboradas a partir de dados originais, as demais foram elaboradas a partir de dados transformados. As equações que não apresentaram normalidade dos resíduos não foram apresentadas.

%	Equação	R2	RSME	MAE
75%.I	-2082,07+(5215,5*Elev)+(-0,6221*Ds)+(-0,000069*Are)+(0,1347*Arg)	0,79	2,73	1,82
	-2721,77+(6816,5*Elev)+(-0,6172*Ds)+(-0,000081*Are)	0,78	2,83	1,88
	-946,01+(2374,02*Elev)+(0,000077*Are)+(0,1265*Arg)	0,80	2,46	1,70
	3,3995+(-0,000078*Are)+(0,1464*Arg)	0,79	2,51	1,72
	4,0919+(-0,000093*Are)	0,78	2,67	1,79
75%.II	-2767,47+(6929,50*Elev)+(-0,5887*Ds)+(-0,000069*Are)+(0,0997*Arg)	0,82	2,49	1,73
	-3074,97+(7699,55*Elev)+(-0,5852*Ds)+(-0,000079*Are)	0,81	2,69	1,54
	-1752,47+(4390,74*Elev)+(-0,000076*Are)+(0,0934*Arg)	0,87	1,54	1,77
	4,0707+(-0,000092*Are)	0,86	1,99	1,56
75%.III	-1896,50+(4750,86*Elev)+(-0,5225*Ds)+(-0,000064*Are)+(0,1599*Arg)	0,88	1,68	1,30
	3,2355+(-0,000073*Are)+(0,1717*Arg)	0,86	1,80	1,34
	4,0499+(-0,000090*Are)	0,87	1,76	1,33
50%.I	-1639,77+(4109,47*Elev)+(-0,4822*Ds)+(-0,000071*Are)+(0,1198*Arg)	0,80	2,58	1,77
	-2202,12+(5516,86*Elev)+(-0,4721*Ds)+(-0,000081*Are)	0,79	2,64	1,81
	-713,101+(1491,87*Elev)+(-0,000078*Are)+(0,1045*Arg)	0,79	2,46	1,70
	4,0527+(-0,000040*Are)	0,78	2,61	1,73
	3,5035+(-0,000079*Are)+(0,1189*Arg)	0,79	2,50	1,78
50%.II	-2209,10+(5532,82*Elev)+(-0,5604*Ds)+(-0,000066*Are)+(0,1317*Arg)	0,82	2,17	1,64
	-2593,09+(6494,43*Elev)+(-0,5354*Ds)+(-0,000078*Are)	0,81	2,43	1,69
	-1599,31+(4007,74*Elev)+(-0,000076*Are)+(0,0921*Arg)	0,87	1,93	1,53
	3,4696+(-0,000078*Are)+(0,1195*Arg)	0,87	1,90	1,51
	4,0337+(-0,000090*Are)	0,86	1,96	1,54
50%.III	26,04+0,13*Elev+(-5,43*Ds)+(-0,21*Are)+0,26*Arg	0,86	1,80	1,28
	-1616,91+(4053,57*Elev)+(-0,4922*Ds)+(-0,000081*Are)	0,90	1,61	1,23
	-510,996+(1286,33*Elev)+(-0,000076*Are)+(0,1115*Arg)	0,87	1,79	1,32
	25,67+(-0,25*Are)+0,25*Arg	0,85	1,92	1,36
	44,68+(-0,45*Are)	0,86	1,86	1,39
30%.I	44,73+0,22*Elev+(-4,87*Ds)+(-0,43*Are)+(-0,016*Arg)	0,82	2,17	1,60
	43,82+0,21*Elev+(-4,86*Ds)+(-0,42*Are)	0,82	2,16	1,59
	344,7508+(-853,315*Elev)+(0,000079*Are)+(0,1325*Arg)	0,79	2,56	1,75
	46,95+(-0,47*Are)	0,79	2,31	1,71

Tabela 5. Continuação

	29,74+0,22*Elev+(-6,07*D_s)+(-0,26*Are)+0,19*Arg	0,88	1,81	1,44
	42,53+0,27*Elev+(-5,86*D_s)+(-0,41*Are)	0,88	1,80	1,38
30%.II	22,21+0,24*Elev+(-0,29*Are)+0,17*Arg	0,87	1,88	1,48
	3,2526+(-0,000073*Are)+(0,1762*Arg)	0,87	1,90	1,53
	46,65+(-0,47*Are)	0,88	1,81	1,57
	30,62+0,08*Elev+(-4,21*D_s)+(-0,26*Are)+0,23*Arg	0,87	1,74	1,22
	45,69+0,15*Elev+(-3,75*D_s)+(-0,44*Are)	0,88	1,68	1,22
30%.III	30,23+(-0,002*Elev)+(-0,30*Are)+0,21*Arg	0,85	1,87	1,32
	30,17+(-0,30*Are)+0,21*Arg	0,85	1,86	1,32
	47,15+(-0,48*Are)	0,86	1,83	1,36




Figura 6. Gráficos dos valores medidos e estimados a partir do conjunto de dados (25%) da Capacidade de Campo (%) (a), 80kPa (b), ponto de murcha permanente (c) pela função que utilizou areia, equação gerada com o dados 30%III.

5.5.3 Validação da função a partir de dados externos

As funções de pedotransferência são rotineiramente avaliadas entre os valores medidos e os valores estimados. Quando os valores medidos utilizados no treinamento da função são usados para avaliá-la, diz-se que a acurácia é avaliada. A partir do momento em dados externos são usados na avaliação da função, diz-se que a confiabilidade é avaliada (Wosten et al., 2001). A validação é premissa básica na elaboração de funções.

Desta maneira, realizou-se uma revisão sobre trabalhos realizados na área do SIPA e trabalhos realizados na região de Seropédica que mediram os valores de retenção de água no solo e de textura (Tabela 6 e 7). Além disso, amostras indeformadas foram coletadas na área do módulo de produção de hortaliças, localizado no SIPA, porém fora da área de coleta do banco de dados utilizados na geração da função, para avaliar a confiabilidade da estimativa das funções elaboradas.

Pereira (2006) e Andrade et al. (2013) trabalharam com pimentão e figo no SIPA, dentro da região onde foi coletado o banco de dados para a geração das funções. Pereira (2006) mediu a capacidade de campo na profundidade de 00-20 cm na área de produção do pimentão, sendo que o mesmo não apresentou dados de argila no trabalho, o que impossibilitou o uso da equação areia + argila. Andrade et al. (2013) mediu nas profundidades de 00-20 e 20-40 cm na área de produção do figo, também situada dentro do domínio da área onde os dados foram gerados. Jaccoud (1976) trabalhou com solos da região de Seropédica e determinou a CC com coletas indeformadas, pelos métodos do anel e torrão. Usando a equação 30%.III elaborada a partir dos dados originais para estimar os valores destes estudos o coeficiente de determinação calculado foi de 0,68 (Figura 7).

O estudo de Jaccoud (1976) ainda utilizada como referência para a classificação dos solos as denominadas “séries” (Itaguaí, Silvicultura, Aprendizado, Agrostologia, Zootecnia, Rosada). Com o avanço do Sistema Brasileiro de Classificação dos solos, as séries receberam outros nomes conforme tabela 7:

Tabela 6. Valores de capacidade de campo medidos pelos autores e valores de capacidade de campo calculados pela equação 30%.III utilizando as variáveis independentes Areia + Argila e Areia.

Autor	CC medida	Areia + Argila		Areia	
		CC estimada	Resíduo	CC estimada	Resíduo
Pereira (2006)	0,220			0,198	0,022
Andrade (2013)	0,226	0,215	0,011	0,211	0,015
	0,172	0,152	0,020	0,153	0,019

Tabela 7. Valores de capacidade de campo medidos por Jaccoud (1976) utilizando amostras indeformadas coletadas por anel, torrão e valores de capacidade de campo calculados pela equação 30%.III utilizando a variável independente Areia.

Autor	SiBCS	CC medida	CC estimada	Resíduo
Itaguaí	Argissolo Vermelho Amarelo	0,260	0,264	-0,004
		0,246	0,244	0,001
		0,230	0,313	-0,084
Silvicultura	Argissolo Vermelho Amarelo	0,178	0,198	-0,021
		0,181	0,231	-0,050
		0,190	0,239	-0,048
Aprendizado	Planossolo	0,122	0,095	0,027
		0,121	0,081	0,041
		0,099	0,084	0,015
Agrostologia	Planossolo	0,158	0,180	-0,022
		0,081	0,082	-0,001
Zootecnia	Planossolo	0,142	0,127	0,014
		0,149	0,196	-0,046
Rosada	Argissolo Vermelho Amarelo	0,170	0,283	-0,112
		0,157	0,198	-0,042




Figura 7. Valores medidos e preditos de Capacidade de Campo (%) para o conjunto de dados do Jaccoud (1976), Pereira (2006) e Andrade (2013) utilizando a equação 30%.III com a variável areia.

Amostras indeformadas de solo foram coletadas no Módulo Experimental de Produção de Hortaliças, localizado no SIPA, com a finalidade de elaborar as curvas de retenção de água no solo. As funções foram utilizadas com a finalidade de estimar a capacidade do solo reter água no potencial referente à capacidade de campo. Na Figura 8 são apresentadas as curvas de retenção de quatro dos treze solos amostrados. Os pontos em negrito representam os valores medidos e os pontos quadriculados, ligados pela linha contínua representam a retenção estabelecida pela equação de van Genuchten (1980). O formato das curvas é característica de solos arenosos, representado pela baixa capacidade de retenção. A porosidade total dos solos

foi de $0,41 \text{ cm}^3 \text{ cm}^{-3}$ para os solos “a” e “b”, e de $0,42 \text{ cm}^3 \text{ cm}^{-3}$ para os solos “c” e “d”. Os valores de capacidade de campo encontrados para os solos da Figura 8 foram de $0,168 \text{ cm}^3 \text{ cm}^{-3}$ (Figura 8a), $0,054 \text{ cm}^3 \text{ cm}^{-3}$ (Figura 8b), $0,138 \text{ cm}^3 \text{ cm}^{-3}$ (Figura 8c) e de $0,147 \text{ cm}^3 \text{ cm}^{-3}$ (Figura 8d).

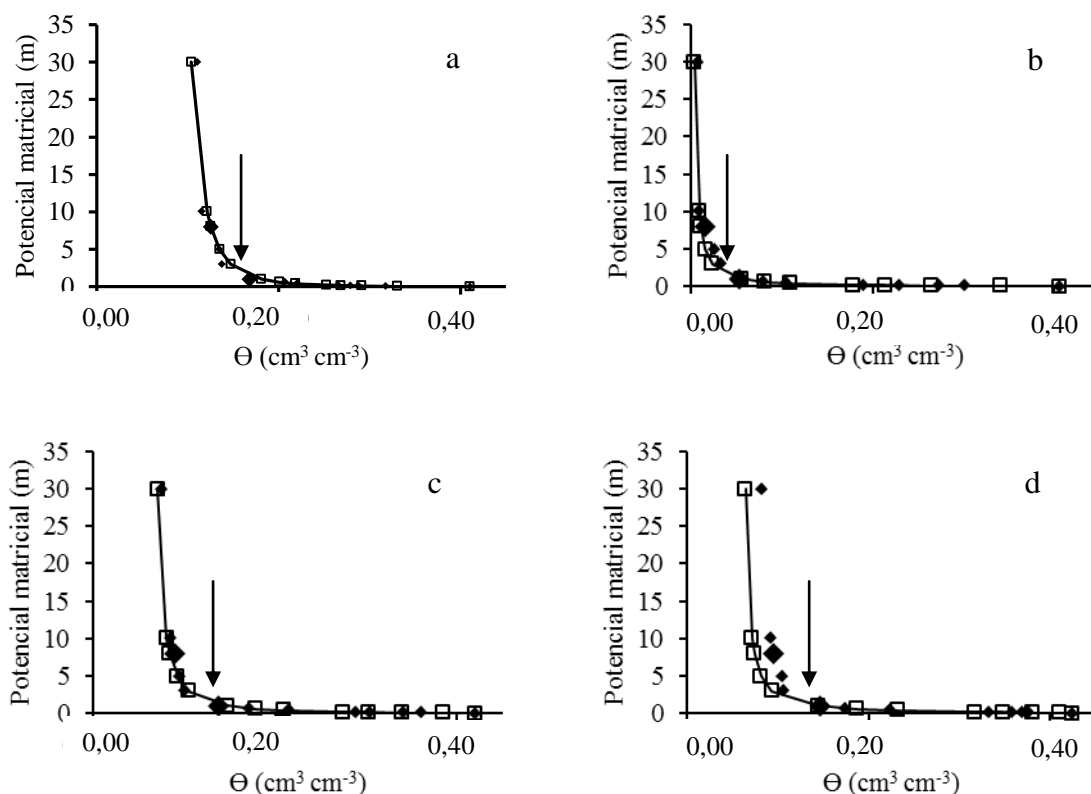


Figura 8. Curvas de retenção de água no solo para os solos do Módulo Experimental de Produção de Hortaliças.

As funções de pedotransferência 30% III com as variáveis independentes *areia* e *argila*, *areia* foram utilizadas para estimar a retenção de água para os solos do Módulo. A capacidade de estimativa da CC das funções caiu muito, apresentando coeficiente de determinação de 0,042 e 0,033. Possivelmente, o manejo do solo adotado no Módulo, isto é, revolvimento intenso do solo para preparo dos canteiros e a adição constante de material orgânico interferiu na capacidade de retenção de água deste solo. Assim, as funções elaboradas a partir do conjunto de dados do SIPA, apesar de apresentarem boa capacidade de estimativa para outros solos da região e mesmo para outras áreas não amostradas dentro do SIPA, não foram boas na predição da retenção da água para os solos do Módulo.

A validação da função de pedotransferência para determinação da retenção de água do solo à **80 kPa**, a partir de dados externos, foi realizada com as informações geradas da curva de retenção de água do solo do Módulo Experimental de Produção de Hortaliças, SIPA (Figura 8). A função de pedotransferência 30% III com as variáveis independentes *areia*, *argila*, foi utilizada para estimar a retenção de água para os solos do Módulo. A capacidade de estimativa da função utilizando areia apresentou coeficiente de determinação de 0,03 (Figura 9a). Portanto a função que utilizou o conteúdo de areia não apresentou boa capacidade de

predição. Como discutido anteriormente, o manejo do solo interferiu na habilidade da função estimar a água retida à 80 kPa.

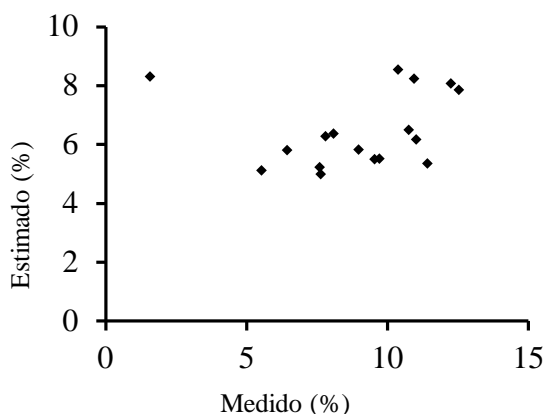


Figura 9. Gráfico dos valores medidos e preditos pela função areia.

Com o objetivo de testar e validar os valores estimados pelas equações elaboradas usando informações geradas por outro banco de dados da região de Seropédica, utilizou-se os dados gerados por Jaccoud (1976). Usando a equação 30%.III elaborada a partir dos dados originais para estimar os valores destes estudos o coeficiente de determinação calculado foi de 0,78 quando usado areia como variável regressora (Figura 10).




Figura 10. Valores medidos e preditos de Ponto de Murcha Permanente (%) para o conjunto de dados do Jaccoud (1976) utilizando a equação 30%III com a variável areia.

5.6 CONCLUSÕES

As funções de pedotransferência elaboradas a partir do banco de dados foram capazes de prever com boa acurácia características físico-hídricas dos solos estudados.

O teor de areia foi o atributo que mais contribuiu para a função estimar a retenção de água na capacidade de campo, retenção a 80 kPa e no ponto de murcha permanente.

A redução do número de variáveis independentes da função não alterou a capacidade de predição da mesma.

A redução do número de dados utilizados na geração da função não alterou a capacidade de predição da mesma.

Quando testou-se as funções elaboradas para estimar a retenção de água nos solos do Módulo, as mesmas não apresentaram boa capacidade de predição. Possivelmente, a baixa capacidade de estimar a retenção da água nos solos do Módulo a partir das equações elaboradas deveu-se ao manejo do solo.

6. CONCLUSÕES GERAIS

A distribuição espacial da umidade do solo apresentou estabilidade temporal para ambos os anos estudados, porém este padrão foi diferente entre os anos. Portanto, é possível utilizar o ponto que apresentou umidade mais próxima à média para estimar o valor da média da umidade na área.

A mudança do padrão espacial da umidade foi associada aos eventos de precipitação. Devido isso, em períodos úmidos é necessário aumentar o número de sensores amostrados e intensificar o período de monitoramento a fim de monitorar a umidade da área.

A correlação entre os teores de argila e a umidade do solo variou no tempo e foi fortemente influenciada pela umidade do solo.

Análises estatísticas que consideram a distribuição espacial podem ser utilizadas para auxiliar no entendimento da contribuição das propriedades dos solos na distribuição espacial do carbono.

A paisagem é um importante componente na distribuição do carbono, argila e areia. Conteúdo prévio de argila foi o atributo mais importante na estimativa dos valores do carbono ao longo do transecto.

A abordagem “state space” forneceu uma compreensiva descrição da distribuição do carbono e a contribuição relativa de cada atributo do solo na predição do carbono pode ser estudada.

O banco de dados utilizado para a geração da função de pedotransferência foi capaz de captar a informação a respeito das características físicas dos solos do SIPA. O mesmo foi utilizado na geração das funções de pedotransferência e estas foram capazes de predizer características físico-hídricas dos solos estudados.

O teor de areia foi o atributo que mais contribuiu para a função estimar a retenção de água na capacidade de campo, retenção a 80 kPa e no ponto de murcha permanente.

7. REFERÊNCIAS BIBLIOGRÁFICAS

- ANDRADE; A.P.S., Manejo da irrigação na cultura da figueira (*Ficus carica*) utilizando o balanço hídrico do solo. Dissertação de Mestrado. Departamento de Fitotecnia, Instituto de Agronomia, Universidade Federal Rural do Rio de Janeiro 44p, 2013.
- AQUINO, L.S., TIMM, L.C., REICHARDT, K., BARBOSA, E.P., PARFITT, J.M.B., NEBEL, A.L.C., PENNING, L.H., State-space approach to evaluate effects of land levelling on the spatial relationships of soil properties of a lowland area. *Soil & Tillage Research* 145, 135–147, 2015.
- ARRUDA, F.B., ZULLO, J.; OLIVEIRA, J.B., Parâmetros de solo para cálculo da água disponível com base na textura do solo. *Revista Brasileira de Ciência do Solo*, v 11, 11-15, 1987.
- AWE, G.O., REICHERT, J.M., WENDROTH, O., Temporal variability and covariance structures of soil temperature in a sugarcane field under different management practices in southern Brazil. *Soil & Tillage Research* 150, 93–106, 2015.
- AWE, G.O., REICHERT, J.M., TIMM, L.C., WENDROTH, O., Temporal processes of soil water status in a sugarcane field under residue management. *Plant Soil*, 387:395–411, 2015.
- BALBINO, L.C.; BRUAND, A.; BROSSARD, M.G.; HAJNOS, M.; GUIMARÃES, M.F., Changes in porosity and microaggregation in clay Ferrasols of the Brazilian Cerrado on clearing for pasture. *European Journal of Soil Science*, 53, 219-230, 2002.
- BARROS, A.H.C.; JONG D, VAN LIER Q; MAIA, A.H.M.; SCARPARE, V.F., Pedotransfer functions to estimate water retention parameters of soils in northeastern Brazil. *Revista Brasileira de Ciência do Solo*, 37, 379-391, 2013.
- BARROS, A.H.C., VAN LIER, Q.J., Pedotransfer functions for Brazilian soils. In Teixeira, W.G.; Ceddia, M.B.; Ottoni, M.V.; Donnagema, C.K. (Eds.) *Application of Soil Physics in Environmental Analysis*. Springer, 2014.
- BATJES, N.H., 1996. Total carbon and nitrogen in the soils of the world. *European Journal Soil Science* 47, 151–163.
- BAZZA, M., SHUMWAY, R.H., NIELSEN, D.R., Two dimensional spectral analysis of soil surface temperature. *Hilgardia*, 56, 3, 1988.
- BERNARDO, S., Manual de irrigação. UFV, Viçosa. 328p, 1984.
- BLÖSCHL, G. AND SIVAPALAN, M., Scale issues in hydrological modelling: A review, *Hydrological Proc.* 9, 251–290, 1995.
- BOTULA, Y., RANST, E.V., CORNELIS, W.M., Pedotransfer functions to predict water retention for soils of the humid tropics: a review. *Revista Brasileira de Ciência do Solo*, 38, 679 – 698, 2014.
- BOUMA, J., Using soil survey data for quantitative land evaluation. *Advance in Soil Science*. 9, 177-213, 1989.
- BURKE, I.C., YONKER, C.M., PARTON, W.J., COLE, C.V., FLACH, K., SCHIMEL, D.S., Texture, climate and cultivation effects on soil organic matter content in US grassland soil. *Soil Science Society of America Journal* 53, 800-805, 1989.
- CARVALHO, D.F., OLIVEIRA, L.F.C., Planejamento e manejo da água na agricultura irrigada. Editora UFV, Viçosa, MG, 2012.

- CASSEL, D.K.; NIELSEN, D.R., Field capacity and available water capacity. In: KLUTE, A., ed. *Methods of soil analysis. Part I.* Madison, Soil Science Society of America, 901-924, 1986.
- CEDDIA, M.B., VIEIRA, S.R., VILLELA, A.L.O., MOTA, L.S., ANJOS, L.H.C., CARVALHO, D.F., Topography and spatial variability of soil physical properties. *Scientia Agricola*.66, 338 – 352, 2009.
- CEDDIA, M.B., VILLELA, A.L.O., PINHEIRO, E.F.P., WENDROTH, O., Spatial variability of soil carbon stock in the Urucu river basin, Central Amazon-Brazil. *Science of the Total Environment* 526, 58–69, 2015.
- CERRI, C.C., BERNOUX, M., ARROUAYS, D., FEIGL, B., PICCOLO, M.C., Carbon pools in soils of the Brazilian Amazon. In: Lal, R. (Ed.), *Global Climate Change and Tropical Ecosystems. Advances in Soil Science.* CRC Press, Boca Raton, 33–50, 2000.
- da SILVA, A.S.; BRITO, L.T.; OLIVEIRA, C.A.; MOTA, A.W., Parâmetros de solo em função da umidade na capacidade de campo em áreas irrigáveis do trópico semiárido Brasileiro. *Pesquisa Agropecuária Brasileira*, v.25, 103 – 116, 1990.
- DING, R., KANG, S., VARGAS, R., ZHANG, Y., HAO, X., Multiscale spectral analysis of temporal variability in evapotranspiration over irrigated cropland in an arid region. *Agricultural Water Management*, 130, 79– 89, 2013.
- DOURADO-NETO, D., TIMM, L.C., OLIVEIRA, J.C.M., REICHARDT, K., BACCHI, O.O.S., TOMINAGA, T.T., CÁSSARO, F.A.M., State-space approach for the analysis of soil water content and temperature in a sugarcane crop. *Scientia Agricola*, 56, 1215-1221, 1999.
- EMBRAPA, 1999. Levantamento semidetalhado dos solos da área do Sistema Integrado de Produção Agroecológica (SIPA), Boletim de Pesquisa n.5, 43p, Seropédica.
- KACHANOSKI, R.G.; JONG, E. 1988. Scale dependence and the temporal persistence of spatial patterns of soil water storage. *Water Resources Research* 24: 85-91.
- HASSINSK, J., Effects of soil texture and grassland management on soil organic C and N and rates of C and N mineralization. *Soil Biology and Biochemistry* 26, 1221-1231, 1994.
- HODNETT, M.G., TOMASELLA, J., Marked differences between van Genuchten soil water-retention parameters for temperate and tropical soils: A new waterretention pedo-transfer functions developed for tropical soils. *Geoderma* 108, 155–180, 2002.
- HUI, S., WENDROTH, O., PARLANGE, M.B., NIELSEN, D.R., Soil variability–infiltration relationships of agroecosystems. *J. Balkan Ecol.* 1, 21–40, 1998.
- KACHANOSKI, R.G.; JONG, E., Scale dependence and the temporal persistence of spatial patterns of soil water storage. *Water Resources Research* 24: 85-91, 1988.
- KALMAN, R.E., A new approach to linear filtering and prediction problems. *Trans. ASME J. Basic Eng.*, 8, 35-45, 1960.
- KALMAN, R.E., BUCY, R.S., New results in linear filtering and prediction theory. *Trans. ASME J. Basic Eng.* 83, 95–108, 1961.
- KATYAL, J.C., RAO, N.H., REDDY, M.N., Critical aspects of organic matter management in the tropics: The example of India. *Nutrient Cycling in Agroecosystems* 61, 77-88, 2001.
- LAL, R., 2004. Soil carbon sequestration impacts on global climate change and food security. *Science* 304, 1623–1627.

- LAL, R., 2015. Sequestering carbon and increasing productivity by conservation agriculture. *Journal of Soil and Water Conservation Society* 70, 55-62.
- LIU, Z.P., SHAO, M.A. AND WANG, Y.Q. 2012. Estimating soil organic carbon across a large-scale region: a state-space modeling approach. *Soil Science* 177, 607 - 618.
- LONGCHAMPS, L., KHOSLA, R.; REICH, R.; GUI, D.W., Spatial and temporal variability of soil water content in leveled fields. *Soil Science Society American Journal*, 79, 1446 – 1454, 2015.
- JACCOUD, A.; CASTRO A.F., Curvas de caracterização de umidade de solos da área da Universidade Federal Rural do Rio de Janeiro, município de Itaguaí. *Pesquisa Agropecuária Brasileira, Série Agronomia*, v.11, pg 1-9, 1976.
- LIN, H.S.; MCINNES, K.J.; WILDING, L.P.; HALLMARK, C.T., 1999. Effects of soil morphology on hydraulic properties: II. Hydraulic pedotransfer functions. *Soil Science Society of America Journal*, 63, 955-961, 1999.
- MATA, M.G.F., Qualidade do solo e avaliação microeconômica de um módulo experimental de produção orgânica intensiva de hortaliças. Dissertação (Mestrado em Ciência do Solo). Departamento de Solos, Instituto de Agronomia, Universidade Federal Rural do Rio de Janeiro. 75p, 2012.
- MCBRATNEY, A.B.; MINASNY, B.; CATTLE, S.R.; VERVOORT, R.W., From pedotransfer function to soil inference system. *Geoderma*. 109, 41-73, 2002.
- MCBRATNEY, A., FIELD, D.J., KOCH, A., 2014. The dimensions of soil security. *Geoderma*. 213, 203-213, 2014.
- MERDUN H.; ÇINAR O.; MERAL, R.; APAN, M., Comparison of artificial neural network and regression pedotransfer functions for prediction of soil water retention and saturated hydraulic conductivity. *Soil e Tillage Research* v.90, pg 108-116, 2006.
- MERZ, B; PLATE, E.J., An analysis of the effects of spatial variability of soil moisture on runoff. *Water Resources Research*, 33, 2909 – 2922, 1997.
- MICHELON, C.J.; CARLESSON, R.; OLIVEIRA, Z.B.; KNIES, A.E.; PATRY, M.T.; MARTINS, J.D., Funções de pedotransferência para estimativa da retenção de água em alguns solos do Rio Grande do Sul. *Ciência Rural Santa Maria*, 41, 848-853, 2010.
- MILONE, G.; ANGELINI, F., *Estatística geral*. São Paulo, Atlas, 1993.
- MINASNY, B.; MACBRATNEY, A.B.; BRISTOW, K.L., Comparison of different approaches to the development of pedotransfer functions for water retention curves. *Geoderma*, v.93, pg 225-253, 1999.
- MINASNY, B.; HARTEMINK, A.E., Predicting soil properties in the tropics. *Earth Science Reviews*. 106, 52-62, 2011.
- MORKOC, F., BIGGAR, J.W., NIELSEN, D.R., ROLSTON, D.E., Analysis of soil water content and temperature using state-space approach. *Soil Science Society American Journal* 49, 798–803, 1985.
- NIELSEN, D.R. AND ALEMI, M.H., Statistical opportunities for analyzing spatial and temporal heterogeneity of field soils. *Plant and Soil* 115, 285-296, 1989.

- NIELSEN, D., HOPMANS, J.W., KUTILEK, M., WENDROTH, O., A brief review of soil water, solute transport and regionalized variable analysis. *Scientia Agricola*, 57 (número especial), 89 – 115, 1997, 1997.
- NIELSEN, D., WENDROTH, O., PIERCE, F.J., Emerging Concepts for Solving the Enigma on Precision Farming Research. In: Robert, P.C., Rust, R.H., Larson, W.E. (Eds). *Proceedings of the Fourth International Conference on Precision Agriculture*. Madison, WI, 303 – 318, 1999.
- NIELSEN, D.R., WENDROTH, O., *Spatial and Temporal Statistics – Sampling Field Soils and Their Vegetation*, first ed. CATENA VERLAG GMBH, Reiskirchen, Germany, 2003.
- OLEA, R.A., 1991. *Geostatistical Glossary and Multilingual Dictionary*, Oxford University Press.
- PINHEIRO, E.F.M., CAMPOS, D.V.B., BALIEIRO, F.C., ANJOS, L.H.C., PEREIRA, M.G., 2015. Tillage systems effects on soil carbon stock and physical fractions of soil organic matter. *Agricultural Systems* 132, 35–39.
- PACHEPSKY, YA.A.; RAWLS, W.J., Accuracy and reliability of pedotransfer functions as affected by grouping soils. *Soil Science Soc. Of America Journal*, 63, 1748-1757, 1999.
- PEREIRA, J.B.A., Avaliação do crescimento, necessidade hídrica e eficiência no uso da água pela cultura do pimentão (*capsicum annum*. L), sob manejo orgânico nos sistemas de plantio com preparo de solo e direto – Seropédica, RJ. Dissertação de Mestrado. Departamento de Fitotecnia, Instituto de Agronomia, Universidade Federal Rural do Rio de Janeiro 112p, 2006.
- PETERSEN, L.W., MOULDRUP, P., JACOBSEN, O.H., ROLSTON, D.E., Relations between specific surface area and soil physical and chemical properties. *Soil Science*. 161, 9 – 21, 1996.
- RAWLS, W.J.; BRAKENSIEK, D.L.; SAXTON, K.E., Estimating soil water retention from soil physical properties and characteristics. *Advance Soil Science* 16, 213-234, 1991.
- REICHARDT, K. A, A água em sistemas agrícolas. São Paulo, Manole, 95-98, 1990.
- RIENZI, E.A., MAGGI, A.E., SCROFFA, M., LOPEZ, V.C., CABANELLA, P., 2016. Autoregressive state spatial modeling of soil bulk density and organic carbon in fields under different tillage system. *Soil & Tillage Research* 159, 56–66.
- SALTER, P.J.; WILLIAMS, J.B. The influence of texture on the moisture characteristics of soils. I. A critical comparison of techniques for determining the available-water capacity and moisture characteristic of a soil.. *J. Soil Sci.*, 16:1-15, 1965.
- SEN, A.K., Spectral-temporal characterization of riverflow variability in England and Wales for the period 1865–2002. *Hydrological Processes*. 23, 1147 – 1157, 2009.
- SCHWEN, A., YANG, Y., WALTON, R.J., WENDROTH, O., A new experimental design reveals the impacts of land use and irrigation characteristics on Bromide leaching. *Vadose Zone Journal*, 2012.
- SHE, D., XUEMEI, G., JINGRU, S., TIMM, L.C., HU, W., 2014. Soil organic carbon estimation with topographic properties in artificial grassland using a state-space modeling approach. *Canadian Journal of Soil Science* 94, 503–514.
- SHUMWAY, R.H., STOFFER, D., An approach to time series smoothing and forecasting using the EM algorithm. *Journal Time Series Analysis*, 3, 253–264, 1982.

SHUMWAY, R.H., Applied Statistical Time Series Analysis. Prentice Hall, Englewood Cliffs, New Jersey, 1988.

SI, B.C., ZELEKE, T.B., Wavelet coherency analysis to relate saturated hydraulic properties to soil physical properties. Water Resources Research, 41, 2005.

SILVA, M.B.; ANJOS, L.H.C.; PEREIRA, M.G.; NASCIMENTO, R.A.M., Estudo da topossequência da baixada litorânea fluminense: efeitos de origem e posição topográfica. Revista Brasileira de Ciência do Solo, v.25, pg 965-976, 2001.

SOMBROEK, W.G., NACHTERGAELE, F., HEBEL, A., 1993. Amounts, dynamics and sequestering of carbon in tropical and subtropical soils. Ambio 22, 417–426.

STEVENS, F., BOGAERT, P., WESEMAEL, B.VAN, 2015. Spatial filtering of a legacy dataset to characterize relationships between soil organic carbon and soil texture. Geoderma 237–238, 224–236.

STEVENSON, J.D., WENDROTH, O., VAN KESSEL, C., NIELSEN, D.R., 2001. A comparison of two methods to predict the landscape-scale variation of crop yield. Soil and Tillage Research 58, 163–181.

TIMM, L.C., FANTE JR, L., BARBOSA, E.P., REICHARDT, K., BACCHI, O.O.S., Interação solo-planta avaliada por modelagem estatística de espaço de estados. Scientia Agrícola, 57, 751 – 760, 2000.

TIMM, L.C., BARBOSA, E.P., SOUZA, M.D., DYNIA, J.F., REICHARDT, K., State-space analysis of soil data: an approach based on space-varying regression models. Scientia Agrícola, 60, 371-376, 2003.

TIMM, L.C., REICHARDT, K., OLIVEIRA, J.C.M., CASSARO, F.A.M., TOMINAGA, T.T., BACCHI, O.O.S., DOURADO-NETO, D., NIELSEN, D.R., State-space approach to evaluate the relation between soil physical and chemical properties. Revista Brasileira de Ciência do Solo, 28, 49 – 58, 2004.

TIMLIN, D.J., WILLIAMS, R.D.; AHUJA, L.R.; HEATHMAN, G.C., Simple parametric methods to estimate soil water retention and hydraulic conductivity. In Pachepsky, Y; Rawls, W.J. (Eds.) Development of pedotransfer functions in soil hydrology. Developments in Soil Science, v. 30, p. 3-18, Elsevier, 2004.

TOMASELLA, J.; HODNET, M.G., ROSSATO, L.; Pedotransfer functions for the estimation of soil water retention in Brazilian soils. Soil Science Society of American Journal, v 64, 327-338, 2000.

TOMASELLA, J.; PACHEPSKY, Y.; CRESTANA, S.; RAWLS, W.J., Comparison of two techniques to develop pedotransfer functions for water retention. Soil Science Society of America Journal, v.67, pg 1085-1092, 2003.

van GENUCHTEN, M.T.; NIELSEN, D.R., On describing and predicting the hydraulic properties of unsaturated soils. Ann. Geophysical. 3, 615-628, 1985.

VERECKEN, H.; HERBST, M., Statistical Regression. In Pachepsky, Y; Rawls, W.J. (Eds.) Development of pedotransfer functions in soil hydrology. Developments in Soil Science, v. 30, p. 3-18, Elsevier, 2004.

VIEIRA, S.R., Geoestatística em estudos de variabilidade espacial de solos. In: Sociedade Brasileira de Ciência do Solo. Tópicos avançados em Ciência do Solo. SBCS, Viçosa, 2000.

- VILLELA, A.L.O., Variabilidade Espacial da Qualidade Físico-Hídrica dos Solos de uma Unidade de Pesquisa em Produção Agroecológica. Dissertação (Mestrado em Ciência do Solo). Departamento de Solos, Instituto de Agronomia, Universidade Federal Rural do Rio de Janeiro. 2007.
- WEBSTER, R., AND OLIVER, M. A., Geostatistics for Environmental Scientists, John Wiley, Chichester, United Kingdom, 2001.
- WENDROTH, O., AI-ORNRAN, A.M., KIRDA, C., REICHARDT, K., NIELSEN, D.R., State-space approach to spatial variability of crop yield. Soil Science Society of American Journal, 56, 801-807, 1992.
- WENDROTH, O., REUTER, H.I., KERSEBAUM, K.C., Predicting yield of barley across a landscape: a state-space modeling approach. Journal of Hydrology 272, 250 – 263, 2003.
- WENDROTH, O., VASQUEZ, V., MATOCHA, C.J., Field experimental approach to bromide leaching as affected by scale-specific rainfall characteristics. Water Resources Research, 47, 2011.
- WENDROTH, O., NAMBUTHIRI, S., WALTON, R.J., Accounting for soil spatial variability in soil water capacitance probe calibration. Vadose Zone J. 12, 2–14, 2013.
- WOSTEN, J.H.M., van GENUCHTEN, M. Th., Using texture and other soil properties to predict the unsaturated soil hydraulic functions. Soil Science Society of American Journal, 52, 1762 – 1770, 1988.
- WOSTEN, J.H.M.; PACHEPSKY, YA.A.; RAWLS, W.J., Pedotransfer function: bridging the gap between available basic soil data and missing soil hydraulic characteristics. Journal of Hydrology. 251, 123-150, 2001.
- YANG, Y., WENDROTH, O., WALTON, R.J., Field-scale bromide leaching as affected by land use and rain characteristics. Soil Science Society of American Journal 77, 1157–1167, 2013.
- YANG, Y. AND WENDROTH. O., State-space approach to analyze field scale bromide leaching. Geoderma 217–218:161–172, 2014.
- YATES, S.R., WARRICK, A. W., Geostatistics. In Methods of Soil Analysis, Part 4, Physical Methods, Eds. J. H. Dane e G. C. Topp, Soil Science Society of America Book Series, no. 5. Madison, Wis, 81 – 118, 2002.