

**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
INSTITUTO DE PESQUISAS HIDRÁULICAS
PÓS-GRADUAÇÃO EM RECURSOS HÍDRICOS E SANEAMENTO
AMBIENTAL**

**ESTIMATIVA DO TEOR DE ÁGUA NO SOLO EM
BACIA HIDROGRÁFICA COM REDES NEURAIS
ARTIFICIAIS UTILIZANDO FATORES FÍSICOS E
CLIMÁTICOS**

DISSERTAÇÃO DE MESTRADO

Marquis Henrique Campos de Oliveira

Porto Alegre, RS, Brasil

2014

MARQUIS HENRIQUE CAMPOS DE OLIVEIRA

**ESTIMATIVA DO TEOR DE ÁGUA NO SOLO EM
BACIA HIDROGRÁFICA COM REDES NEURAIAS
ARTIFICIAIS UTILIZANDO FATORES FÍSICOS E
CLIMÁTICOS**

Dissertação apresentada ao Programa de Pós-Graduação em Recursos Hídricos e Saneamento Ambiental, do Instituto de Pesquisas Hidráulicas da Universidade Federal do Rio Grande do Sul, como requisito parcial para obtenção do grau de Mestre em Recursos Hídricos e Saneamento Ambiental.

Orientadora: Profa Dra Nilza Maria dos Reis Castro

Porto Alegre, RS, Brasil

2014

AGRADECIMENTOS

A Deus... não é possível expressar, em palavras, todo o meu agradecimento!

À Universidade Federal do Rio Grande do Sul (UFRGS) e ao Instituto de Pesquisas Hidráulicas (IPH), em especial aos professores do Curso de Pós-Graduação em Recursos Hídricos e Saneamento Ambiental, que possibilitaram a realização desse curso de mestrado.

Ao INMET, pelo fornecimento dos dados meteorológicos da estação de Cruz Alta-RS, essenciais à realização desse estudo.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela bolsa de mestrado, e à FINEP pelo financiamento dessa pesquisa (chamada pública MCT/FINEP CT-HIDRO 01/2010 - projeto "Rede de Pesquisa em Monitoramento e Modelagem de Processos Hidrossedimentológicos em Bacias Representativas Rurais e Urbanas do Bioma Mata Atlântica");

Ao Laboratório de Sedimentos do IPH pela estrutura disponibilizada durante a realização das análises laboratoriais, fundamentais ao desenvolvimento desse estudo.

À minha orientadora, professora Dra Nilza Maria dos Reis Castro, pelo exemplo, que me levou a avançar na compreensão e realização desse trabalho, compartilhando momentos de reflexão e discussão, contando sempre com sua experiência, carinho e amizade: essa pesquisa é, com certeza, também um reflexo de sua grande dedicação e orientação!

Ao professor Dr Olavo Correa Pedrollo, pelos valiosos conhecimentos compartilhados na área de estatística e redes neurais artificiais, e por sua grande dedicação e paciência no esclarecimento de minhas dúvidas: a evolução desse trabalho é também o resultado de suas contribuições!

Aos meus pais Marquis Alvares de Oliveira e Ilma Campos Adorno de Oliveira, e também as minhas irmãs, que me acompanharam em cada momento dessa fase, apoiando-me e ajudando-me, sempre de forma incondicional: minha sempre eterna gratidão!

À minha amiga e colega Vanessa Sari, que com muita paciência ajudou-me a enfrentar minhas dificuldades durante o desenvolvimento dessa pesquisa, auxiliando-me durante o desenvolvimento da dissertação: obrigado por ser um verdadeiro anjo!

Aos professores e colegas do mestrado, que contribuíram na realização desse estudo.

À equipe do laboratório de sedimentos, em especial aos técnicos Bruno da Silva Rocha e Aron Jonatã Funke, e aos estagiários Lucas Pires, Guiniver, Ana Karolina Rodrigues da

Silveira e Silvia Pereira Marengo; pela ajuda durante a realização das análises de laboratório, essenciais à continuidade dessa pesquisa.

À equipe da hidrometria e aos motoristas do IPH, pela ajuda prestada durante os trabalhos de campo: Pedro Massochin Medeiros, Cesar Dias Gonçalves, Luis Gregório Raupp, Gilnei Ricardo da Silva, Pedro Varny Silva da Silva, Mário Cardoso, Anselmo Einloft, assim como aos motoristas terceirizados: muito obrigado pelo apoio ao longo desses anos!

Ao casal sr. Antoninho Zambra, d. Fátima e toda sua família, proprietários das áreas onde foram realizados os experimentos, sem os quais não seria possível concretizar dessa pesquisa, meus sinceros agradecimentos!

Ao pessoal do hotel de Pejuçara (família Miller) e de Cruz Alta (família Pinheiro), pelo carinho e apoio durante todos esses anos: obrigado por me fazerem sentir-me um pouco mais perto de casa durante os intervalos dos cansativos trabalhos de campo!

À Prefeitura Municipal de Pejuçara que sempre estava à disposição para ajudar no que fosse necessário.

Aos meus amigos Tirzah Moreira de Melo, Vander Kaufmann, Haline Depiné, Juliana Becker Silva, Rubmara Oliveira, pelas vivências proporcionadas ao longo dessa pesquisa.

Ao meu amigo Cesar Augusto Alves (Cesinha), que acompanhou toda a minha caminhada desde a minha chegada ao IPH, obrigado pelas conversas, conselhos e pelas muitas risadas na hora do cafezinho.

Aos meus amigos de Canoas, Rafael Bijoldo Fontoura, Victor Teixeira Martins e Leandro Missel Jr, pelos momentos de descontração.

E a todos aqueles que, direta ou indiretamente, auxiliaram nas discussões dessa pesquisa: muito obrigado por me ajudarem, mesmo que indiretamente, a completar mais uma etapa de meu desenvolvimento pessoal e profissional!

RESUMO

Dissertação de Mestrado
Programa de Pós-Graduação em Recursos Hídricos e Saneamento Ambiental
Instituto de Pesquisas Hidráulicas
Universidade Federal do Rio Grande do Sul

ESTIMATIVA DO TEOR DE ÁGUA NO SOLO EM BACIA HIDROGRÁFICA COM REDES NEURAIS ARTIFICIAIS UTILIZANDO FATORES FÍSICOS E CLIMÁTICOS

AUTOR: Marquis Henrique Campos de Oliveira

ORIENTADORA: Nilza Maria dos Reis Castro

Data e Local da Defesa: Porto Alegre, 30 de setembro de 2014

RESUMO: O teor de água no solo é um dos fatores determinantes nos processos de transferência entre o solo e a atmosfera, contribuindo nos balanços de água e de energia. Esse teor é influenciado pelas entradas de água na bacia hidrográfica, por características climáticas, topográficas, de cobertura vegetal, práticas de manejo agrícola e propriedades do solo. A grande heterogeneidade desses fatores faz com que a caracterização desse teor seja ainda um grande desafio. Essa pesquisa objetivou desenvolver abordagens baseadas em Redes Neurais Artificiais (RNAs) para determinação da variação espacial e temporal do teor de água no solo, utilizando informações climáticas, propriedades físicas do solo e variáveis topográficas de uma bacia hidrográfica, com área aproximada de 78 km², localizada na Região Sul do Brasil (bacia do Taboão). A RNA adotada é uma rede de duas camadas, com 25 neurônios na camada intermediária, sendo o treinamento realizado por meio do algoritmo retropropagativo, considerando 16 iterações iniciais dos pesos sinápticos, e número máximo de ciclos igual a 30.000. No total foram testadas 40 variáveis de entrada, sendo quatro referentes à topografia (altitude, declividade, distância do ponto ao trecho do rio mais próximo e desnível do ponto ao trecho mais próximo do rio); oito relacionadas ao solo (tipo de solo, densidade do solo, resistência à penetração no solo para as camadas de 0 a 20 cm e 20 a 40 cm, tensão da água no solo em apenas um ponto na bacia e percentual de argila, silte e areia), 10 relativas ao clima (clima, evapotranspiração de referência, temperatura do ar máxima e temperatura do ar, umidade relativa do ar máxima e umidade relativa do ar mínima, pressão atmosférica, radiação solar global, velocidade do vento e temperatura na relva), e 18 variáveis de chuva (chuva de 1, 2, 3, 4, 5, 6 e 12h; chuva de 1, 2, 3, 5, 10, 15, 20, 25 e 30 dias; chuva média ponderada horária; chuva média ponderada diária). A saída dos modelos foi comparada com valores de umidade gravimétrica determinados por amostras coletadas em 26 pontos da bacia, distribuídos espacialmente na bacia, no período compreendido entre 15/01 e 10/08/2013. Neste período o teor de água no solo (umidade gravimétrica) variou entre 13,73 e 33,75%. Os resultados demonstram que é possível estimar o teor de água no solo, com distribuição espacial e temporal, com boa eficiência ($NS_{\text{verificação}} = 0,77$), empregando dados topográficos da bacia, propriedades físicas do solo e dados de chuva. As informações climáticas, por outro lado, não afetam significativamente essa estimativa ($NS_v = 0,28$), podendo até diminuir a eficiência do modelo ($NS_v = 0,77$ para $NS_v = 0,68$). O emprego de muitas variáveis não gera necessariamente o melhor desempenho do modelo, pois uma variável pode mascarar a outra e, até mesmo, interferir a eficiência do modelo ($NS_v = 0,70$ e $NS = 0,61$ para os modelos onde foram utilizadas 38 variáveis de entrada), além de aumentar o custo e o tempo para aquisição dessas variáveis, e a dificuldade de interpretação dos resultados em relação às várias entradas. Alternativamente, pode-se estimar o teor de água no solo utilizando modelos mais simplificados que empregam dados de chuva monitorados e informações extraídas de mapas (topografia e tipo de solo), mas o desempenho desses modelos é menor ($NS_v = 0,66$). A análise de importância das variáveis de entrada delimitou a tensão da água no solo e a chuva como as variáveis mais influentes nos modelos de melhor desempenho, e a densidade do solo como a menos importante. Nos modelos mais simples, a variável menos relevante é a declividade e a mais importante é a chuva. A análise de sensibilidade demonstrou que nem sempre os modelos conseguem reproduzir o que deveria ocorrer no ambiente natural.

Palavras-chave: umidade gravimétrica, distribuição espacial e temporal, parâmetros físicos do solo e do relevo.

ABSTRACT

Master Course Dissertation
Graduate Program in Water Resources and Environmental Sanitation
Instituto de Pesquisas Hidráulicas
Universidade Federal do Rio Grande do Sul

ESTIMATION OF SOIL WATER CONTENT IN WATERSHED WITH ARTIFICIAL NEURAL NETWORKS USING PHYSICAL FACTORS AND WEATHER

AUTHOR: Marquis Henrique Campos de Oliveira
ADVISER: Nilza Maria dos Reis Castro
Defense Place and Date: Porto Alegre, September 30, 2014.

ABSTRACT: The water content in the soil is one of the determining factors in the transfer processes between the soil and the atmosphere, contributing to the balances of water and energy. This content is influenced by inputs to the basin, climate characteristics, topography, land cover characteristics, agricultural practices, and soil properties. These wide heterogeneity factors make the soil water content characterization still a challenge. This research aimed to develop an Artificial Neural Network (ANN) model to determine the spatial and temporal variation of the water content in the soil, using climate data, physical properties of soil, and topographic variables, of a basin with an area of approximately 78 km², located in Brazil's southern region (Taboão basin). The model adopted is a double layer feedforward neural network with 25 neurons in the hidden layer. The learning method is the back propagation algorithm, with 16 interactions to avoid local minima, and the maximum number of cycles chosen was 30,000. A total of 40 input variables were tested, including four of topography (altitude, slope, distance from the point to the nearest stretch of river and unevenness of the point closest to the stretch of the river), eight of soil related variables (soil type, soil density, soil penetration resistance for layers from 0 to 20 cm and from 20 to 40 cm, soil water tension at a single point in the basin and percentage of clay, silt and sand), 10 climate-related variables (climate, evapotranspiration reference, maximum and minimum air temperature, maximum and minimum air relative humidity, atmospheric pressure, global solar radiation, wind speed and temperature on grass) and 18 variables related to rain (accumulated precipitation in 1, 2, 3, 4, 5, 6 e 12h; accumulated precipitation in 2, 3, 5, 10, 15, 20, 25 and 30 days; weighted hourly accumulated precipitation; weighted daily accumulated precipitation). The outputs of the models were compared with values determined by gravimetric moisture samples collected from 26 points spatially distributed in the basin, in the period between 15/01 and 10/08/2013. During this period the soil water content (gravimetric water content) ranged from 13.73 to 33.75%. The results show that it is possible to estimate the water content of the soil, temporal and spatial distribution, with good efficiency ($NS_{verification} = 0.77$), using topographic data from the basin, soil physical properties and precipitation data. The weather information, on the other hand, did not significantly affect the estimate ($NS_v = 0.28$) and may even decrease the efficiency (NS_v) of the model (from 0.77 to 0.68). The use of many variables not necessarily generates the best performance of the model as a variable may mask another and even disrupt the efficiency of the model ($NS_v = 0.70$ and $NS_v = 0.61$, where 38 input variables were used), besides increasing the cost and the time to acquire these variables, and the difficulty of interpreting the results in relation to the various inputs. Alternatively, one can estimate the water content in soil using more simplified models, employing monitored rainfall data and information extracted from maps (topography and soil type), but the performance of these models is smaller ($NS_v 0.66$). The analysis of the importance of input variables delimited the soil water tension and the rain as the most influential variables in the best models, and the density of the soil as the least important. In the simplest models, the less relevant variable is the slope and the most important is the rain. The sensitivity analysis showed that the models cannot always play what should occur in the natural environment.

Keywords: gravimetric moisture, spatial and temporal distribution, physical soil parameters and relief.

LISTA DE FIGURAS

Figura 1 - Rede neural de múltiplas camadas.....	36
Figura 2 - Modelo expandido com redes neurais	41
Figura 3 – Localização da bacia hidrográfica do rio Potiribu e das sub bacias do rio Taboão, Turcato e Donato no contexto brasileiro e regional	50
Figura 4 - Precipitação média mensal - Estação climatológica de Cruz Alta - INMET período 1961 a 2013.	52
Figura 5 - Altitudes na bacia do Taboão, obtidas a partir do MNT com auxílio do <i>software</i> ArcGIS.....	53
Figura 6 – Declividades na bacia do Taboão, obtidas a partir do MNT com auxílio do <i>software</i> ArcGIS.....	54
Figura 7- Mapa do tipo de solo presente na bacia do rio Taboão.....	55
Figura 8- Mapa de uso do solo da bacia do Taboão, elaborado a partir de uma imagem LANDSAT TM de 26 de janeiro de 2005	57
Figura 9 - Localização dos pontos de coleta de solo, sensor de temperatura na superfície do solo, tensiômetro, e pluviógrafos, na bacia do Taboão.	59
Figura 10 – Procedimentos de a) verificação da resistência à penetração no solo, b) coleta de amostras deformadas de solo, c) coleta de amostras indeformadas de solo, d) amostra de solo indeformada coletada, e e) amostra de solo indeformada acondicionadas em latas para transporte	62
Figura 11 - Tensiômetro instalado na bacia do Taboão para monitoramento da tensão da água no solo	63
Figura 12 - Resíduos do modelo completo e do modelo simplificado.....	69
Figura 13 - Distribuição dos pluviógrafos na bacia do Taboão e influência de cada um deles sobre os pontos de coleta de solo, tendo por base o método de Thiessen	72
Figura 14 – Umidade gravimétrica: variação temporal (gráfico inferior) e espacial (gráfico superior), considerando as coletas realizadas nos 26 pontos entre 15/01/13 e 10/08/13.....	78
Figura 15 - Umidade gravimétrica observada e calculada em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados de umidade gravimétrica (b), e comportamento dos valores calculados e observados, ao longo do tempo (c); considerando apenas as variáveis de entrada relacionadas à topografia da bacia.....	87
Figura 16 – Umidade gravimétrica observada e calculada em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados de umidade gravimétrica (b), e comportamento dos valores calculados e observados, ao longo do tempo (c); considerando apenas as variáveis de entrada relacionadas às propriedades físicas do solo	88
Figura 17 – Umidade gravimétrica observada e calculada em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados de umidade gravimétrica (b), e comportamento dos valores calculados e observados, ao longo do tempo (c); considerando apenas as variáveis de entrada relacionadas ao clima da bacia (sem dados de chuva)	89
Figura 18 – Umidade gravimétrica observada e calculada em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados de umidade gravimétrica (b), e comportamento dos valores calculados e observados, ao longo do tempo (c); considerando apenas as variáveis de entrada relacionadas à chuva antecedente às coletas	90
Figura 19 – Umidade gravimétrica observada e calculada em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados de umidade gravimétrica (b), e comportamento dos valores calculados e observados, ao longo do tempo (c); considerando o modelo com melhor desempenho M69	94

Figura 20 – Umidade gravimétrica observada e calculada em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados de umidade gravimétrica (b), e comportamento dos valores calculados e observados, ao longo do tempo (c); considerando o modelo com melhor desempenho M71	95
Figura 21 – Umidade gravimétrica observada e calculada em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados de umidade gravimétrica (b), e comportamento dos valores calculados e observados, ao longo do tempo (c); considerando o modelo com melhor desempenho M14 com dados de topografia e chuva.....	97
Figura 22 – Umidade gravimétrica observada e calculada em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados de umidade gravimétrica (b), e comportamento dos valores calculados e observados, ao longo do tempo (c); considerando o modelo com melhor desempenho M78 com dados de topografia e chuva e chuva média ponderada horária e chuva média ponderada diária.	98
Figura 23 – Variação do desempenho dos modelos em função da adição das variáveis de entrada do tipo climáticas - M14 (modelo com variáveis topográficas e chuvas), M78 (igual M14 + chuvas ponderadas), M80 (igual ao M14 + ET0), M84 (igual ao 14 + todas variáveis climáticas). A chuva ponderada corresponde a chuva média ponderada horária, chuva média ponderada diária, e chuva de 15 dias e 25 dias.....	99
Figura 24 –Variação do desempenho dos modelos em função da adição das variáveis de entrada do tipo climáticas e tipo de solo- M14 (modelo com variáveis topográficas e chuvas), M78 (igual M14 + chuvas ponderadas), M79 (igual ao M14 + tipo de solo), M81 (igual ao 79 - pressão, vento e ET0), M85 (igual ao M79+estação climática + temperatura na superfície do solo), M86 (igual ao M78 + tipo de solo). A chuva ponderada corresponde à chuva média ponderada horária, chuva média ponderada diária e chuva de 15 dias e 25 dias.	100
Figura 25 – Variação do desempenho dos modelos em função da adição de variáveis de entrada - M69 (características topográficas sem desnível, tipo de solo, densidade e resistência 0 a 10 cm, chuvas ponderadas), M74 (igual ao M69 + resistência penetração 20 a 40 cm), M43 (igual ao M74 + granulometria+chuvas - chuva ponderada), M56 (igual ao M43 - resistência a penetração 0 a 20 cm), M71 (igual ao M43 -tipo de solo+chuva ponderada), M73(igual ao M71 - resistência ao penetrômetro 0 a 20 cm). A chuva ponderada corresponde a chuva média ponderada horária, chuva média ponderada diária e chuva de 15 dias e 25 dias.	101

LISTA DE TABELAS

Tabela 1 - Informações dos pontos de coleta na bacia do Taboão (nome do ponto de coleta, coordenadas de localização do ponto, altitude e tipo de solo).....	60
Tabela 2 - Resumo das estatísticas descritivas dos parâmetros climáticos utilizados como entrada da RNA, considerando dados da estação INMET Cruz Alta no período de 15/01 a 10/08/13.....	64
Tabela 3- Pluviógrafos selecionados para cada um dos pontos de coleta de solo, tendo por base os polígonos de Thiessen.....	73
Tabela 4- Resultados das correlações da média móvel das chuvas passadas ponderadas horárias exponencialmente com o teor de água no solo, obtidos em função das meia-vidas testadas (em horas)	74
Tabela 5 - Resultados das correlações da média móvel das chuvas diárias passadas ponderadas exponencialmente com o teor de água no solo obtidos em função das meia-vidas testadas (em dias)	74
Tabela 6 – Propriedades físicas do solo e topográficas da bacia, e listagem dos pluviógrafos utilizados no cálculo das chuvas, considerando os 26 pontos de coleta de solo e as 24 datas (ou 25 momentos) em que as coletas foram realizadas	76
Tabela 7 - Combinações de entrada testadas para os diferentes modelos de RNA analisados (86 modelos).....	85
Tabela 8 – Resumo das estatísticas para os 31 principais modelos de RNA analisados (treinamento e verificação).....	86
Tabela 9- Resultados da análise de sensibilidade e importância das variáveis de entradas dos 5 modelos finais selecionados (M69, M71, M14, M78 e M86).....	104

SUMÁRIO

1	APRESENTAÇÃO	11
1.1	Introdução e justificativa	11
1.2	Hipótese da pesquisa	14
1.3	Objetivo da pesquisa	14
1.3.1	Etapas necessárias ao desenvolvimento do trabalho	15
2	REFERENCIAL TEÓRICO	16
2.1	Teor de água no solo: conceitos gerais e principais métodos utilizados para sua estimativa	16
2.1.1	Método direto – umidade gravimétrica e volumétrica	18
2.1.2	Reflectômetro com domínio temporal - TDR	19
2.1.3	Sensores de capacitância	21
2.1.4	Tensiômetros	23
2.1.5	Sensoriamento remoto	26
2.2	Fatores que influenciam o teor de água no solo	28
2.2.1	Variável climática – chuva	29
2.2.2	Outras variáveis climáticas - radiação solar, velocidade do vento, umidade relativa do ar, temperatura do ar, pressão atmosférica, período climático (primavera, verão, outono e inverno) e evapotranspiração de referência	31
2.2.3	Variáveis topográficas da bacia – altitude, declividade e proximidade com o rio (zonas de descarga)	31
2.2.4	Variáveis físicas do solo – tipo de solo, granulometria, densidade, tensão da água no solo, e resistência à penetração no solo	32
2.2.5	Uso do solo e cobertura vegetal	33
2.3	Redes neurais artificiais (RNAs)	35
2.3.1	Origem e Natureza:	35
2.3.2	Treinamento das RNAs	37
2.3.3	Modelos Expandidos com Redes Neurais	40
2.3.4	Avaliação dos Resultados das RNAs	41
2.3.5	Análise e Seleção das Variáveis Explicativas	42
2.3.6	Alguns resultados da estimativa do teor de água no solo utilizando RNAs: cenário nacional e internacional	44
3	CARACTERIZAÇÃO DA ÁREA DE ESTUDO	50

3.1.1	Localização da área de estudo e histórico dos projetos	50
3.1.2	Clima da bacia	52
3.1.3	Relevo da bacia	53
3.1.4	Geologia e tipo de solo	54
3.1.5	Uso e manejo do solo	56
4	MATERIAIS E MÉTODOS	58
4.1	Dados de entrada e de saída dos modelos com RNAs	58
4.1.1	Dados de entrada e de saída dos modelos RNAs	58
4.1.1.1	Coleta de amostras de solo e análises em laboratório	58
4.1.1.2	Tensão da água no solo	62
4.1.1.3	Informações meteorológicas	63
4.1.1.4	Temperatura do ar, umidade relativa do ar, pressão atmosférica, radiação solar global e velocidade do vento	64
4.1.1.5	Precipitação	64
A)	MÉDIA MÓVEL DAS CHUVAS PASSADAS HORÁRIA E DIÁRIA COM PONDERAÇÃO EXPONENCIAL	65
4.1.1.6	Características topográficas da bacia	67
4.2	Modelos com RNAs	67
4.2.1	Análise e seleção das variáveis explicativas	69
5	RESULTADOS E DISCUSSÃO	72
5.1	Análise das chuvas utilizadas como entrada nos modelos de RNAs testados	72
5.1.1	Análise das variáveis topográficas da bacia e das propriedades físicas do solo utilizadas como entrada nos modelos de RNAs testados	75
5.2	Análise das estatísticas descritivas do teor de água no solo	77
5.3	Estimativa do teor de água no solo com modelos baseados em RNAs	81
5.4	Análise de sensibilidade e de importância das variáveis de entrada dos modelos RNA	102
6	CONCLUSÕES E RECOMENDAÇÕES	106
	REFERÊNCIAS BIBLIOGRÁFICAS	109

1 APRESENTAÇÃO

1.1 Introdução e justificativa

O teor de água no solo é um dos fatores determinantes nos processos de transferência entre o solo e a atmosfera, contribuindo de forma direta nos balanços de água e energia, e controlando os processos hidrológicos. Sendo assim, a necessidade de conhecimento dessa variável tem importância fundamental na modelagem de bacias hidrográficas, em aplicações agrônomicas e de engenharia. Da mesma maneira, tem grande relevância em investigações acerca da resposta da vegetação em condições de déficit hídrico e para o planejamento de estratégias de manejo e uso eficiente das reservas hídricas do solo.

De modo geral, o teor de água no solo é influenciado, predominantemente, pelas entradas de água na bacia hidrográfica, através da precipitação e da irrigação. Entretanto, elementos relacionados às características climáticas, à topografia, à cobertura vegetal, às práticas de manejo agrícola e às propriedades do solo, ao atuarem conjuntamente com a precipitação, podem determinar a variação espacial e temporal desse teor de água; sobretudo, em razão da interferência de tais fatores sobre a evapotranspiração, a infiltração e o armazenamento de água no solo. Dentre esses fatores destacam-se a altitude, a declividade, a proximidade com o rio, a granulometria, a densidade do solo, a resistência à penetração, o teor de matéria orgânica, a precipitação antecedente, a temperatura e a umidade relativa do ar, a radiação solar, a velocidade do vento, a pressão atmosférica, o período climático (primavera, verão, outono e inverno), a temperatura na relva e a tensão da água no solo.

Cada um desses elementos irá exercer um impacto específico sobre o comportamento do teor de água no solo (WESTERN, GRAYSON e BLÖSCHL, 2002), afetando também a porosidade e a distribuição do tamanho dos poros no solo (SUR, JUNG e CHOY, 2013). Contudo, alguns deles exercem influência mais significativa do que os demais, conforme as características predominantes no ambiente analisado (WESTERN et al., 2004). Na realidade, a grande heterogeneidade desses fatores faz com que a distribuição espacial do teor de água no solo seja ainda um grande desafio (VERECKEN et al., 2007); especialmente, porque muitos deles estão inter-relacionados, dificultando a identificação das analogias de causa e efeito dessas variáveis sobre o teor de água no solo (KORRES, REICHENAU e SCHNEIDER, 2013). Essa condição exige uma elevada resolução espaço-temporal de dados

observacionais para que seja possível a estimativa confiável desse teor de água no solo (WESTERN, GRAYSON e BLÖSCHL, 2002).

A necessidade de estimativas precisas do teor de água no solo, em escalas espaço-temporais, induziu o desenvolvimento de diferentes métodos para sua determinação. Atualmente, essa estimativa pode ser realizada através de medições pontuais (em terra) ou por meio de técnicas de sensoriamento remoto (WESTERN, GRAYSON e BLÖSCHL, 2002). As primeiras podem ser realizadas por métodos diretos (coletas de amostras de solo), nos quais o teor de água no solo é determinado com base na diferença entre os pesos de uma amostra de solo úmido e seco; ou ainda, através de métodos indiretos (tensiômetros, sonda de nêutrons, sensores de capacitância elétrica, sensores de resistência elétrica, sensores de dissipação de calor, e reflectômetros com domínio temporal - TDR ou de frequência, etc.), que estimam o teor de água no solo a partir de sua relação com alguma outra variável mensurável (DOBRIYAL et al., 2012; MUÑOS-CARPENA, 2012), sendo necessária uma curva de calibração.

Os métodos de medição por terra apresentam a vantagem de serem relativamente precisos (WESTERN, GRAYSON e BLÖSCHL, 2002), mas de outro lado, demandam recursos materiais e financeiros, considerável trabalho físico e dispêndio de tempo para seu desenvolvimento e aplicação, onerando e, até mesmo, inviabilizando seu emprego para áreas extensas. Com isso, há certa dificuldade na identificação do teor de água no solo para grandes áreas, nomeadamente, em função da exigência de inúmeros pontos de monitoramento devido à heterogeneidade dos fatores que afetam o seu valor.

O emprego do sensoriamento remoto, apesar de ser uma alternativa interessante e que produz bons resultados quando se considera a possibilidade de estimativa da variação espacial e temporal do teor de água no solo (CHAI et al., 2010; PALOSCIA et al., 2013), por outro lado, é uma técnica relativamente cara e complexa (DOBRIYAL et al., 2012). Sua precisão é limitada pelas incertezas da relação entre a resposta do sensor e o teor de água no solo (WANG e QU, 2009), e pela dificuldade em se identificar as variações dessas respostas na presença de vegetação (WESTERN et al., 2004). Como resultado, podem-se obter medidas inconsistentes de um pixel para outro (DOBRIYAL et al., 2012), limitando a representatividade da heterogeneidade do teor de água na superfície terrestre (WEIHERMULLER et al., 2007); ao mesmo tempo em que os custos para aquisição dos dados e da escala espacial em que tais dados são obtidos são majorados.

Por certo, as peculiaridades desse contexto tornam difícil a identificação da distribuição do teor de água no solo em uma bacia hidrográfica. Diante disso, muitos modelos hidrológicos consideram o cálculo dessa variável somente a partir de relações com outros parâmetros, especialmente pelo emprego de equações de balanço hídrico; o que pode traduzir-se em uma fonte de erros nos resultados calculados pelos modelos. Existe, portanto, a necessidade de que sejam desenvolvidos modelos capazes de incorporar a influência dos fatores dominantes para cada uma das paisagens, de forma que seja possível a estimativa eficiente da variação espacial e temporal do teor de água no solo.

Uma alternativa é utilizar as informações climáticas e as propriedades físicas do solo, e topográficas da bacia, monitoradas em um dado ponto, para gerar modelos que permitam a estimativa do teor de água no solo em outros locais não monitorados, empregando como entradas as variáveis climáticas do ponto monitorado (ponderação da variação temporal), associadas às propriedades físicas do solo e topográficas da bacia de interesse (ponderação da variação espacial). Isso permite a redução dos custos e das dificuldades inerentes aos processos de amostragem e monitoramento.

Recentemente, alguns estudos têm utilizado as Redes Neurais Artificiais (RNAs) na estimativa do teor de água no solo (JIANG e COTTON, 2004; CONTADOR, MANETA e SCHNABEL, 2006; ELSHORBAGY e PARASURAMAN, 2008; PALOSCIA et al., 2008; RAMÍREZ-BELTRAN et al., 2008; SAID, KOTHYARI e ARORA, 2008; COELHO et al., 2009; CHAI et al., 2010; ZOU et al., 2010; KÖKSAL et al., 2011; SANTI et al., 2012; ARSOY et al., 2013; PALOSCIA et al., 2013; SRIVASTAVA et al., 2013), incentivados, sobretudo, pelo sucesso da aplicabilidade dessa ferramenta na solução de inúmeros problemas não-lineares, nas mais diversas áreas. A maioria deles estima o teor de água no solo a partir de parâmetros obtidos por imagens de satélite ou radar (temperatura de brilho da superfície, índice de vegetação, coeficiente de retroespalhamento, etc.). Alguns empregam variáveis climáticas (precipitação, temperatura e umidade do ar, temperatura na relva, radiação solar, etc.), enquanto que uma minoria utiliza também informações relativas ao solo (teor de argila, densidade, etc.) e à topografia (curvatura, índice topográfico, etc.) da área de estudo.

As RNAs são modelos estatísticos (HU e HWANG, 2002) e empíricos (ASCE, 2000) que possuem grande habilidade de adaptação, aprendizado e generalização (KRÖSE e SMAGT, 1996; KASABOV, 1998), tendo sido consideradas ferramentas adequadas para a modelagem ambiental. Além disso, essas redes apresentam importante capacidade de separação e organização de dados (KRÖSE e SMAGT, 1996), robustez, grande paralelismo,

armazenamento associativo de informações e processamento espaço-temporal dessas informações (KASABOV, 1998). Em contrapartida, um dos problemas dessa abordagem por meio de RNAs é a estimativa do teor de água no solo para entradas que estão fora dos limites de treinamento da rede.

Além disso, há que se considerar que, apesar desses avanços, existe ainda uma carência de metodologias que facilitem a identificação mais precisa da variação espacial e temporal do teor de água no solo em uma bacia hidrográfica, ponderando-se a influência conjunta dos diferentes fatores que afetam o seu valor. Nesse sentido, a abordagem baseada em RNAs possibilitam a realização de estudos de sensibilidade e sobre a importância das variáveis utilizadas no modelo, de forma a identificar aquelas que mais afetam o teor de água no solo; possibilitando, com isso, a melhoria da compreensão dos processos físicos envolvidos.

Perante semelhante cenário, essa pesquisa buscou identificar os fatores físicos e climáticos que afetam a estimativa do teor de água no solo em uma bacia hidrográfica localizada na região sul do Brasil; visando a compreensão de como tais fatores interferem nessa variável, de maneira a contribuir para a escolha e o desenvolvimento de modelos baseados em RNAs, capazes de estimar adequadamente a variabilidade temporal e espacial do teor de água no solo dessa região.

1.2 Hipótese da pesquisa

Essa pesquisa foi conduzida tendo por base a seguinte hipótese:

O teor de água no solo pode ser estimado a partir de informações climáticas e das propriedades físicas do solo e topográficas da bacia, utilizando modelos baseados em RNAs. Essas RNAs são aproximadores universais e por isso são candidatas naturais para a investigação desejada.

1.3 Objetivo da pesquisa

O objetivo dessa pesquisa é investigar abordagens baseadas em RNAs para estimativa da variação espacial e temporal do teor de água no solo, utilizando informações climáticas, propriedade físicas do solo e variáveis topográficas de uma bacia hidrográfica localizada na região Sul do Brasil.

Concomitantemente, deseja-se determinar as variáveis de entrada de maior sensibilidade e importância para o modelo RNA, de maneira a identificar a estrutura mais adequada para a rede, tanto em termos computacionais quanto em relação aos custos e tempo necessário para aquisição das variáveis de entrada requeridas.

1.3.1 Etapas necessárias ao desenvolvimento do trabalho

As seguintes etapas foram necessárias para o desenvolvimento dessa pesquisa:

- Classificar a bacia em relação à altitude e ao tipo de solo, com subsequente escolha dos pontos de coleta das amostras de solo, de maneira a satisfazer a variação espacial dos parâmetros topográficos da bacia e das propriedades físicas do solo;
- Coletar amostras de solo com variação espacial e temporal, visando à representatividade do teor de água no solo (máximo e mínimo) em diferentes estações climáticas;
- Analisar em laboratório as amostras de solo coletadas para determinação da densidade, granulometria e umidade gravimétrica do solo;
- Analisar a consistência dos dados climáticos (chuva, velocidade do vento, umidade relativa do ar, temperatura do ar, radiação solar, pressão atmosférica e evapotranspiração), e das propriedades monitoradas do solo (tensão da água no solo e resistência à penetração no solo);
- Elaborar e testar modelos com RNAs, utilizando como entradas da rede os dados climáticos e as propriedades físicas do solo e topográficas da bacia, e como saída, o teor de água no solo nos diferentes pontos coletados e nas diferentes datas;
- Analisar a importância e a sensibilidade das variáveis nos modelos RNAs desenvolvidos.

2 REFERENCIAL TEÓRICO

Este capítulo tem por objetivo oferecer suporte para a discussão de como desenvolver abordagens baseadas em RNAs na estimativa da variação espaço-temporal do teor de água no solo, utilizando informações climáticas e propriedades físicas do solo e topográficas de uma bacia hidrográfica.

Nesse sentido, está estruturado de forma a proporcionar uma visão geral acerca do conceito e dos principais métodos utilizados para a estimativa do teor de água no solo, além de discutir a respeito das propriedades físicas do solo e topográficas da bacia, bem como, sobre os fatores climáticos que interferem e influenciam esse teor de água. Na continuidade, faz-se uma revisão em torno das origens, natureza e treinamento das RNAs, e a respeito da construção de modelos expandidos utilizando redes neurais; com destaque para os processos de análise e seleção das variáveis explicativas desses modelos e para a avaliação dos resultados da rede. Por fim, expõem-se os resultados de alguns estudos que utilizaram RNAs na estimativa do teor de água do solo.

2.1 Teor de água no solo: conceitos gerais e principais métodos utilizados para sua estimativa

O teor de água no solo relaciona-se diretamente à quantidade de água retida no espaço poroso desse solo, sendo uma função do tamanho e do volume de seus poros. Essa retenção se dá, por sua vez, em razão das propriedades físico-hídricas do solo, sob o comando de duas forças: as capilares e as de adsorção. Tais forças surgem pela interação entre a água e as partículas sólidas na matriz do solo, e compõem o potencial matricial desse solo (REICHARDT e TIMM, 2004).

As primeiras representam aquelas forças atuantes pelo contato entre o líquido e uma superfície sólida. Controladas pelo diâmetro do poro, são tanto maiores quanto menor for esse diâmetro. Já as segundas, referem-se à capacidade de adesão das moléculas de água aos minerais do solo, sendo uma consequência da presença de cargas elétricas e superfícies adsorptivas nessa matriz de solo. De fato, em uma escala micro e nanométrica, os minerais presentes no solo apresentam cargas elétricas, superfícies reativas, que adsorvem a água e cátions nela dissolvidos, gases, complexas macromoléculas de húmus e bactérias (BRADY e WEIL, 2013).

As menores partículas (<0,001 mm) de material orgânico e de argila apresentam propriedades coloidais e uma grande área superficial por unidade de massa. A superfície interna e externa dos coloides do solo apresentam cargas eletrostáticas positivas e/ou negativas, comumente com predominância das cargas eletronegativas; embora, em alguns solos muito intemperizados ou ácidos, esses coloides minerais possam apresentar um balanço positivo de cargas. A quantidade e a origem dessas cargas de superfície variam em função dos diferentes tipos de coloides, sendo também afetadas pelas mudanças nas condições químicas do solo (por exemplo: alterações do pH do solo). Essas cargas irão atrair ou repelir as substâncias presentes na solução do solo, bem como, as partículas coloidais mais próximas; influenciando também a adsorção de água. De maneira geral, pode-se dizer que quanto maior é a área superficial externa do colóide de solo, maior também será a quantidade de água retida quando o solo é seco ao ar. Isso ocorre porque as cargas nas superfícies internas e externas dos coloides atraem a extremidade da molécula de água com carga oposta à do colóide. As reações originadas desses contextos irão influenciar significativamente o comportamento físico-químico desse solo (BRADY e WEIL, 2013).

Assim sendo, o teor de água no solo é variável no tempo e no espaço (ENTIN et al., 2000; WESTERN, GRAYSON e BLÖSCHL, 2002; ALBERTSON e MONTALDO, 2003; MAHMOOD, LEGATES e MEO, 2004; MANFREDA e RODRIGUEZ-ITURBE, 2006; BROCCA et al., 2007, 2010; FAMIGLIETTI et al., 2008; PENNA et al., 2009, 2010; CHEN et al., 2011) e muitos processos dele dependentes não são lineares (WESTERN, GRAYSON e BLÖSCHL, 2002). Essa variabilidade é influenciada por diversos fatores relacionados: i) ao clima, como: a precipitação, a evaporação, a radiação solar, a temperatura e umidade relativa do ar, a temperatura na relva, a pressão atmosférica, e o período do ano que engloba estes fatores; ii) às características topográficas do local (QIU et al., 2001; WESTERN et al., 2004; BROCCA et al., 2007; PENNA et al., 2013), como, por exemplo a altitude, a declividade, e a curvatura; iii) às propriedades físicas do solo (BUTTLE, DILLON e EERKES, 2004; GRANT, SEYFRIED e MCNAMARA, 2004; HÉBRARD et al., 2006; MAEDA et al., 2006; VEREECKEN et al., 2007; BARONI et al., 2013), entre elas: a granulometria; a quantidade de matéria orgânica, o grau de compactação, a profundidade do solo, e a tensão da água no solo; iv) às práticas de conservação e manejo do solo (MOUSSA, VOLTZ e ANDRIEUX, 2002; CARLUER e DE MARSILY, 2004), e v) às características da vegetação (GOMEZ-PLAZA et al., 2001; MOHANTY, FAMIGLIETTI e SKAGGS, 2000, HUPET e

VANCLOOSTER, 2002; BARONI et al., 2013; ZUCCO et al., 2014), como: a cobertura, o tipo e a idade do vegetal.

Atualmente, a determinação do teor de água no solo pode ser concretizada por meio de medições pontuais (efetivadas em terra) ou à distância, nesse caso, utilizando-se de técnicas de sensoriamento remoto (WESTERN, GRAYSON e BLÖSCHL, 2002). As medidas pontuais, por sua vez, podem ser realizadas por métodos diretos (coletas de amostras de solo) ou através de métodos indiretos (tensiômetros, sonda de nêutrons, sensores de capacitância elétrica, sensores de resistência elétrica, sensores de dissipação de calor e reflectômetros com domínio temporal - TDR ou de frequência, etc.); os quais permitem a identificação do teor de água no solo através de uma relação com alguma outra variável mensurável (DOBRIYAL et al., 2012; MUÑOS-CARPENA, 2012); basicamente por uma propriedade física ou físico-química relacionada ao teor de água no solo (ROMANO, 2014). Nessa condição, é necessária a construção de uma curva de calibração entre essa variável e o teor de água no solo.

2.1.1 Método direto – umidade gravimétrica e volumétrica

O método direto é caracterizado como um método destrutivo, por demandar coletas de amostras de solo para cada um dos pontos desejados, não sendo possível a repetitividade das amostras no mesmo ponto coletado anteriormente (WESTERN, GRAYSON e BLÖSCHL, 2002; ROMANO, 2014). Posteriormente, essas amostras são direcionadas para análises laboratoriais. Apesar disso, e justamente por sua metodologia de concretização, apresentam a desvantagem de serem onerosos e dispenderem tempo e trabalho físico para sua realização; dificultando e até mesmo inviabilizando sua aplicação para grandes áreas. Nesse método, o teor de água no solo, contido em uma amostra, pode ser determinado tendo por base a massa do solo (umidade gravimétrica) ou o volume do solo (umidade volumétrica). As equações 1 e 2 são utilizadas para determinação da umidade gravimétrica e volumétrica, respectivamente; enquanto que a equação 3 é empregada para o cálculo da umidade volumétrica a partir da umidade gravimétrica (CAUDURO, 19??).

$$\theta_g = \frac{\text{Massa de água (g)}}{\text{Massa do solo seco (g)}} \times 100 \quad (1)$$

$$\theta_v = \frac{\text{Volume de água contida na amostra (cm}^3\text{)}}{\text{Volume de solo com estrutura natural (cm}^3\text{)}} \times 100 = \frac{V_a}{V_t} \quad (2)$$

$$\frac{\theta v = \theta g \times Ds}{Da} \quad (3)$$

onde: θg é a umidade gravimétrica (%); θv é a umidade volumétrica (%); Va é o volume da água na amostra (g); Vt é o volume de solo contido na amostra; Ds é a densidade do solo (g/cm^3) e Da é a densidade da água. Considerando a densidade da água igual a $1 \text{ g}/\text{cm}^3$, o volume da água na amostra é determinado pela diferença entre as massas de solo úmido e seco (g).

Na prática, essa determinação da umidade gravimétrica é considerada um valor de referência para o desenvolvimento de estudos comparativos que envolvam o teor de água no solo, já que esse é o único método que fornece uma medida direta desse teor de água no solo (ROMANO, 2014).

Já os métodos indiretos utilizam-se de diferentes princípios físico-químicos para desenvolverem uma relação entre o teor de água no solo e os parâmetros geofísicos. A garantia de uma precisão adequada nesse processo, para a grande parcela desses métodos, exige uma calibração específica (ZHU et al., 2012; ROMANO, 2014) para as diferentes texturas, salinidade, e características do solo. Em geral, tais métodos não envolvem procedimentos destrutivos e os equipamentos utilizados podem ser alocados no solo de forma permanente ou ainda, compor-se de sensores remotos localizados em plataformas aéreas ou satélites. Eles são adequados para a realização de medições em uma base repetitiva, e muitos deles permitem que os dados sejam gravados automaticamente (ROMANO, 2014).

Entre os métodos dessa natureza, os mais utilizados, atualmente, para a determinação do teor de água no solo são: o TDR, os sensores de capacitância, e os tensiômetros.

2.1.2 Reflectômetro com domínio temporal - TDR

O TDR é um método indireto no qual o teor de água no solo é determinado tendo por base a constante dielétrica do solo, que representa a capacidade de um material, não condutor, de transmitir ondas ou pulsos eletromagnéticos de alta frequência (SANTOS, 2005). Essa constante tem forte relação com o teor de água no solo, devido ao elevado contraste entre a permissividade dielétrica da água em comparação com os outros constituintes do solo (VERECKEN et al., 2014). Para um solo seco e para o ar, a constante dielétrica apresenta valores de 5 e 1, respectivamente, enquanto que, para a água, essa constante tem um valor em

torno de 80; o que indica que pequenas mudanças no conteúdo de água do solo podem ter grande influência na constante dielétrica (BOYER e KRAMER, 1995). Assim sendo, a identificação da constante dielétrica de um dado solo é uma boa medida do teor de água presente nesse solo (KIRKHAM, 2005).

A determinação dessa constante é realizada pela identificação da velocidade de propagação de ondas eletromagnéticas de alta frequência ao longo de condutores metálicos (hastes paralelas de metal), introduzidos no solo (NOBORIO, 2001), com comprimento entre 100 mm e 1 m (KIRKHAM, 2005). Na realidade, o equipamento mede a velocidade de propagação de um sinal de alta frequência (1 MHz a 1 GHz), registrando o tempo de deslocamento desse sinal e convertendo esse valor para a constante dielétrica aparente (KIRKHAM, 2005; MUÑOS-CARPENA, 2012, ROMANO, 2014), através da equação 4. Quanto menor a velocidade maior é o teor de água presente nesse solo.

$$Ka = \left(\frac{c \times t}{2L} \right)^2 \quad (4)$$

onde: Ka é a constante dielétrica aparente; c é a velocidade da luz (30 cm/ns); t é o tempo de deslocamento (ns); e L é o comprimento da guia (cm). A divisão pelo fator $2L$ (e não somente por L) ocorre em razão do tempo de deslocamento ser determinado para o percurso de ida e volta do sinal (sinal refletido).

Topp et al. (1980) realizaram os primeiros trabalhos com equipamento TDR, propondo uma relação empírica entre o teor de água no solo (θ_v) e a constante dielétrica aparente (Ka). Os autores sugeriram que as características ambientais do solo (como: textura, densidade, estrutura, teor de sais e temperatura) não afetariam a medição do conteúdo de água através do TDR. Dessa forma, a equação por eles proposta poderia ser utilizada na determinação do teor de água no solo para uma ampla gama de tipos e texturas de solos; sendo desnecessária a construção de relações de calibração em diferentes tipos de solos. Essa equação (equação 5) ficou conhecida como equação universal de calibração do TDR.

$$\theta_v = -5,3 \times 10^{-2} + 2,92 \times 10^{-2}ka - 5,5 \times 10^{-4}ka^2 + 4,3 \times 10^{-6}ka^3 \quad (5)$$

onde: θ_v é o teor de água no solo (%); e Ka é a constante dielétrica aparente.

Todavia, sabe-se que condições ambientais e propriedades locais do solo podem influenciar significativamente as leituras realizadas (STANGL, BUCHAN e LOISKANDL, 2009), tornando necessária a construção de uma relação de calibração para a determinação do

teor de água no solo. Ao mesmo tempo, essa necessidade dificulta a aplicação de tal método de monitoramento.

A salinidade do solo e a presença de grandes quantidades de argila, por exemplo, tornam o solo altamente condutor, atenuando o sinal refletido e, dessa forma, afetando a leitura do aparelho (MUÑOS-CARPENA, 2012). Nos solos orgânicos, nas argilas, turfas, e em alguns solos de florestas, a elevada porosidade, combinada com grandes quantidades de água armazenada, produz diferenças substanciais na assinatura dielétrica do mineral se comparada a um solo arenoso, com mesmo teor de água (JONES, WRAITH e OR, 2002).

Além da textura do solo, do teor de matéria orgânica e da salinidade, pode-se citar ainda como elementos capazes de influenciar a leitura do aparelho: a densidade do solo; a concentração de íons; o comprimento dos cabos (JONES, WRAITH e OR, 2002; GONG, CAO e SUN, 2003; BLONQUIST, JONES e ROBINSON, 2005), que deve ser inferior a 20 m para garantir a precisão das medidas (VERECKEN et al., 2014), a geometria da sonda e o teor de água no solo. A totalidade desses fatores, agindo individualmente ou em conjunto, podem afetar consideravelmente as propriedades dielétricas do solo, criando possíveis erros na determinação do teor de água nele presente (JONES, WRAITH e OR, 2002; GONG, CAO e SUN, 2003; BLONQUIST, JONES e ROBINSON, 2005), o que determina a necessidade de calibração do instrumento.

Esse método é considerado não destrutivo, já que suas leituras são realizadas repetidas vezes em um mesmo sensor, fixado ao solo (em geral, 2 ou 3 hastes metálicas de aproximadamente 20 cm de comprimento). A técnica TDR apresenta como vantagens: a não destruição da região amostrada; a exigência de trabalho técnico pouco intenso; o uso de instrumento portátil, de fácil instalação e seguro do ponto de vista operacional (DOBRIYAL et al., 2012); a repetibilidade das leituras; a rapidez na obtenção da umidade volumétrica (TOMMASELLI, 1997); a robustez e confiabilidade das medições (entre 1 e 2% do conteúdo volumétrico de água no solo), a existência de boa resolução espacial e temporal; a possibilidade de medições contínuas e fáceis de se obter e a não necessidade de calibração para alguns tipos de solo (JONES, WRAITH e OR, 2002; CERNÝ, 2009).

2.1.3 Sensores de capacitância

Outra técnica baseada no princípio da permissividade dielétrica compõem os sensores de capacitância, que consideram o solo como uma componente de um capacitor. Basicamente,

essa técnica determina a permissividade dielétrica aparente do solo através da medição do tempo de carga de um capacitor incorporado a esse solo. Nesse caso, o solo atua como um meio dielétrico (ROMANO, 2014), sendo influenciado pelo teor de água nele presente. Esses sensores utilizam-se de um oscilador de frequência para gerar um campo de corrente alternada, o qual atua como meio de detecção das propriedades dielétricas do solo (PALTINEANU e STARR, 1997).

Tais sensores são pares de eletrodos, constituídos por barras ou anéis circulares de metal, que funcionam como se fossem capacitores, onde o solo é o material dielétrico. Esse capacitor, trabalhando em conjunto com o oscilador, gera um circuito finamente ajustado, que tem sua frequência de operação alterada em função do teor de água no solo (PALTINEANU e STARR, 1997). Dessa forma, mudanças na frequência do circuito indicam alterações no teor de água nesse solo (DOBRYAL et al., 2012).

Atualmente, a utilização de sensores de capacitância é bastante difundida, em comparação com o uso do TDR (ROMANO, 2014), e uma das razões para isso é a facilidade de operação (VERECKEN et al., 2014) e os baixos custos, tanto em termos de tempo despendido quanto em razão dos recursos financeiros demandados; embora obviamente à custa de uma piora na exatidão e precisão das medições realizadas (ROMANO, 2014).

Os maiores erros de medição associados a sua utilização dependem, principalmente, da frequência do campo eletromagnético do instrumento. Em geral, a frequência de oscilação da tensão de alguns sensores de capacitância é de cerca de 20-30 MHz, mas para outros ela atinge valores mais elevados (cerca de 80-100 MHz), chegando até mesmo a alcançar 300 MHz. Essas frequências são menores do que aquelas comumente empregadas no TDR, o que faz com que as medições da permissividade dielétrica do solo sejam mais propensas a serem influenciadas pela temperatura e salinidade desse solo (ROMANO, 2014). Em virtude disso, a obtenção de uma curva de calibração confiável é a chave para a adequada aplicação desses sensores de capacitância em estudos de monitoramento do teor de água no solo (BLONQUIST, JONES e ROBINSON, 2005; MITTELBAACH, LEHNER e SENEVIRATNE, 2012; VAZ et al., 2013).

Assim como as demais técnicas baseadas na permissividade dielétrica, alguns fatores podem afetar o sinal registrado pelo instrumento, tais como: a sensibilidade para entradas de ar (vazios ao redor dos anéis onde se localizam os sensores), o teor de argila presente no solo, a salinidade, a temperatura e a densidade do solo.

Lima et al. (2012) utilizaram uma sonda multisensor de capacitância do tipo PR2/6 (Delta-T Device Ltd.) para medir o teor de água no solo nas profundidades de 10, 20, 30, 40, 60 e 100 cm. Os resultados encontrados demonstraram que, após a construção de uma curva de calibração específica para os Latossolos estudados nos oito locais monitorados (1 área com Latossolo vermelho e 7 áreas com Latossolo Vermelho-Amarelo), 80% das 109 amostras analisadas tiveram erros inferiores a 6% na determinação do teor de água no solo. Entretanto, quando se considera um erro padrão aceitável de 2%, 60% das amostras extrapolariam esse limite admissível. O estudo mostra, portanto, limitações na determinação do teor de água no solo, quando se utiliza tais sensores para monitoramento de solos caracterizados por elevado teor de argila.

2.1.4 Tensiômetros

O tensiômetros medem o potencial matricial da água no solo, incluindo os efeitos de capilaridade e adsorção (MUÑOS-CARPENA, 2012); sendo geralmente compostos por um tubo oco e hermético, [comumente construídos em Policloreto de Vinilo (PVC)] (DOBRYAL et al., 2012). A opção pela utilização de plástico, em vez de metal, minimiza os efeitos da temperatura sobre o instrumento (KIRKHAM, 2005). Esse sistema, uma vez cheio de água, é selado e enterrado no solo, na profundidade em que se deseja monitorar a variação do teor de água, [sendo necessária a instalação de um instrumento para cada profundidade que se deseja monitorar]. Na extremidade em contato com o solo, esse tubo possui uma cápsula porosa de cerâmica, e na outra, um vacuômetro [ou outro dispositivo de medição de pressão], cuja função é registrar a pressão negativa gerada no interior do tubo. Alterações na tensão capilar do solo são acompanhadas pelo movimento da água, através dos poros desse solo, até que a tensão capilar no interior da placa cerâmica seja igual à tensão fora dela (DOBRYAL et al., 2012).

Os poros da placa devem ser menores do que os poros do solo em que a tensão está sendo medida; caso contrário, pode haver a entrada de ar nessa placa, originando efeitos de cavitação (KIRKHAM, 2005). Em geral, a presença de bolhas de ar tende a diminuir a sensibilidade dos tensiômetros e, por conseguinte, aumentar seu tempo de resposta. No entanto, bolhas inferiores a 1 mm de diâmetro, comumente, apresentam efeito negligenciável sobre aparelhos para pressões negativas menores do que 70 kPa (7 m de coluna de água) (TOWNER, 1983).

A temperatura também afeta a leitura dos tensiômetros, por influenciar as propriedades físicas da água, em especial, a densidade e a tensão superficial. Com isso, mudanças de temperatura podem afetar o potencial matricial (tensão) de água no solo. Nesse caso, o principal efeito ocorre na superfície do solo, onde as alterações de temperatura são maiores. Diante disso, recomenda-se que as leituras sejam realizadas no início da manhã, quando o sol é mais fraco. Da mesma maneira, os instrumentos não podem ser utilizados em clima muito frio, uma vez que a água presente no tensiômetro pode congelar e quebrá-lo (KIRKHAM, 2005).

As medidas do tensiômetro são relacionadas ao teor de água no solo (em massa ou volume) através da curva característica de retenção de água no solo (ou simplesmente curva de retenção de água no solo), que expressa a relação entre o teor de água e o potencial matricial da água no solo (força de ligação entre as moléculas de água e as partículas de solo) (EMBRAPA, 2007). Essa curva pode ser determinada em ensaio de laboratório, utilizando-se a câmara de pressão de Richards (RICHARDS e FIREMAN, 1943) e amostras de solo deformadas ou indeformadas. A câmara simula uma dada tensão na amostra de solo e, posteriormente, por diferença de peso (solo úmido após ser submetido à pressão - solo seco em estufa a 105 °C por 48 horas), determina-se o teor de água relacionada à pressão aplicada (EMBRAPA, 2007).

Os tensiômetros possuem a vantagem de ser uma tecnologia não destrutiva e de baixo custo, possibilitando uma estimativa precisa da distribuição do teor de água em solos saturados ou não saturados. Todavia, sua utilização requer dispêndio de tempo para sua instalação, sendo necessárias manutenções periódicas para uma boa funcionalidade do instrumento; apresentando ainda, limitações de aplicabilidade espacial (DOBRYAL et al., 2012), para solos muito secos (SCHMUGGE, JACKSON e MCKIM, 1980) e com altos teores de areia.

Além disso, a medida do potencial matricial do solo através de tensiômetros é limitada a valores menores que 1 atm. Isso porque o manômetro mede pressões manométricas (vácuo) com relação à pressão manométrica externa. Quando a tensão atinge valores próximos a 1 atm surgem bolhas de ar que interferem no equilíbrio, podendo até mesmo romper a coluna de água. Na prática, o intervalo de uso dos tensiômetros encontra-se, aproximadamente, na faixa entre zero (saturação) e -0,8 atm (REICHARDT e TIMM, 2004).

A amostra de solo indeformada consiste na retirada de uma amostra do solo preservando-se suas características físicas naturais, em relação à porosidade e à densidade

(estrutura do solo). Para isso, utilizam-se anéis cilíndricos de volume conhecido (EMBRAPA, 2007), sendo as dimensões usuais em torno de 3 cm de altura e 5 cm de diâmetro.

Em laboratório, a amostra de solo indeformada é inicialmente saturada e pesada, sendo, na sequência, levada à Câmara de Richards, e submetida a determinadas pressões para extração da água nela contida. A cada pressão aplicada (em ordem crescente), retira-se a amostra da câmara, uma vez cessada a drenagem do excedente de água (quando ocorre o equilíbrio entre a pressão aplicada e o teor de água relacionado); e pesa-se essa amostra, voltando-a novamente à câmara de pressão, onde é ajustado o próximo ponto de pressão. Uma vez aplicadas todas as pressões, obtém-se os teores de água, por diferença de peso, aos quais corresponde o potencial mátrico (EMBRAPA, 2007). A retirada da água da amostra ocorre em razão da diferença de potencial entre a placa porosa e a amostra de solo; sendo que o fluxo de água é exponencialmente reduzido à medida que o potencial matricial torna-se mais negativo. Nessa fase, o processo para atingir o equilíbrio passa a dispender um tempo muito grande.

A curva de retenção de água no solo pode ser representada, analiticamente, através da equação proposta por van Genuchten (1980) (equação 6):

$$\theta = \theta_r + \frac{\theta_s - \theta_r}{[1 + |\alpha| \Psi]^n]^m} \quad (6)$$

onde: θ é a umidade volumétrica no solo; θ_r é a umidade volumétrica residual; θ_s é a umidade volumétrica na saturação; Ψ é o potencial matricial (coluna de H₂O em cm); α , m e n são o parâmetros de ajuste.

Como os ensaios na Câmara de Richards podem demorar vários dias até meses, para minimizar esse grande dispêndio de tempo, alguns autores (ARYA e PARIS, 1981; MEDINA et al., 2002; WALCZAK et al., 2006; ABBASI et al., 2011; BOTULA et al., 2012) sugerem a determinação da curva de retenção de água no solo por meio da utilização de uma função de pedotransferência. Tal função tem por base a similaridade entre as curvas de distribuição do tamanho das partículas no solo (ou outras variáveis como densidade, teor de carbono orgânico, teor de matéria orgânica, etc.) e as curvas de retenção de água nesse mesmo solo. Isso seria possível em razão da correlação existente entre a distribuição percentual das frações argila, silte e areia e o armazenamento de água no solo.

De fato, a forma da curva de retenção de um determinado solo está relacionada a diversas propriedades físicas e químicas desse solo, as quais são únicas para cada solo,

representando, portanto, uma impressão digital (*fingerprint*) desse solo (CORNELIS et al., 2001). Dessa forma, é possível estimar a curva de retenção de água no solo a partir do conhecimento da granulometria desse solo, simplificando e agilizando o processo de obtenção dessa curva.

Contudo, existem estudos relatando que esses modelos muitas vezes subestimam ou superestimam o teor de água no solo. Nascimento et al. (2010), por exemplo, testaram o modelo de Ayra e Paris (1981) em um solo de textura arenosa (Neossolo Quartzarênico), localizado em Petrolina – PE, e observaram que o teor de água nesse solo foi superestimado pelo modelo. Já Mohammadi e Vanclooster (2011) aplicaram esse mesmo modelo para solos de diferentes classes texturais (80 solos selecionados a partir da base de dados UNSODA) concluindo que, nos maiores potenciais matriciais, ocorre a subestimativa dos valores calculados. Rezaee, Shabanpour e Davatgar (2011) também demonstraram que os resultados desse modelo geralmente subestimam o teor de água no solo (considerando 35 amostras de solo), tanto para os altos potenciais matriciais quanto para os baixos.

2.1.5 Sensoriamento remoto

Uma nova tecnologia empregada para estimativa indireta do teor de água no solo baseia-se no emprego do sensoriamento remoto, incluindo a utilização de radares (microondas), satélites e sensores ativos e passivos (PUMA et al., 2005). Nos últimos anos, o uso dessas tecnologias tem sido bastante incentivado, sobretudo porque os métodos pontuais de medição são muito limitados para aplicações em grandes áreas. Há que se considerar ainda, o dispêndio de tempo requerido para a instalação de tais aparelhos e o custo dos instrumentos automáticos; fatores que limitam a implantação de um amplo número desses sensores, restringindo o desenvolvimento de uma adequada cobertura espacial, necessária ao monitoramento preciso da variação do teor de água no solo (KORRES, REICHENAU e SCHNEIDER, 2013).

O emprego de tais técnicas possibilita resultados rápidos e eficazes, muitas vezes, com boas estimativas do teor de água no solo em grandes áreas (ZHU et al., 2012). Em contrapartida, essa tecnologia apresenta elevada complexidade e demanda uma grande quantidade de recursos para sua aquisição (DOBRIYAL et al., 2012), [além de possuir limitada precisão em algumas situações], e ser representativa apenas do teor de água da camada mais superficial do solo (LI e ISLAM, 2002).

Todas as faixas do espectro eletromagnético podem ser utilizadas para detectar o teor de água no solo por sensoriamento remoto, mas a região correspondente à faixa das microondas é, sem dúvida, uma das mais qualificadas para a realização de medições quantitativas, pois essa é uma região influenciada pelas propriedades dielétricas do solo e, por conseguinte, pelo teor de água presente nesse solo (KORNELSEN e COULIBALY, 2013).

Ao entrar em contato com a superfície, a energia incidente pode ser absorvida (atenuada), dispersa, refletida ou então, pode penetrar o meio e nele ser absorvida ou dispersa. A energia dispersa que retorna ao sensor (retroespalhamento) é coletada e interpretada como uma imagem (KORNELSEN e COULIBALY, 2013).

Assim sendo, as principais incertezas da estimativa do teor de água estão associadas às variações da resposta do sensor, pois a quantidade de energia retroespalhada, a partir de uma superfície natural, depende: do teor de água no solo; das características da vegetação; da rugosidade da superfície nas diferentes paisagens; do tipo de solo; e das configurações do radar/sensor (KORNELSEN e COULIBALY, 2013). Destaca-se ainda, as incertezas geradas pela baixa resolução espacial dos dados disponíveis para essas estimativas.

O teor de água afeta a temperatura no solo e suas propriedades dielétricas e, portanto a emissividade desse solo. Logo, altera-se a resposta do sensor em relação ao brilho e a temperatura da superfície (WANG e QU, 2009; DOBRYAL et al., 2012). A influência da geometria do detector depende do comprimento de onda da energia emitida e da quantidade de água presente nesse solo. Assim, comprimentos de onda longos penetram mais no solo do que os comprimentos de onda curtos, sendo que a profundidade alcançada aumenta à medida que o solo seca (KORNELSEN e COULIBALY, 2013).

Por outro lado, a grande heterogeneidade da rugosidade do solo é um dos fatores mais limitantes da precisão nas estimativas da umidade do solo por sensoriamento remoto (BRYANT et al., 2007). Semelhantemente ao que ocorre na superfície do solo, a dispersão ou atenuação do sinal em virtude da presença da vegetação irá variar conforme as propriedades do vegetal. Usualmente, o dossel da vegetação provoca o espalhamento da energia, e a quantidade de energia que penetra a vegetação dependerá da frequência da energia emitida e do teor de água na planta (KORNELSEN e COULIBALY, 2013). A fim de separar a influência da vegetação e da superfície do solo no sinal do radar [ou sensor], é necessário determinar alguns parâmetros da vegetação e incluí-los nos modelos construídos para estimativa do teor de água no solo. Entretanto, infelizmente, esses parâmetros geralmente são

de difícil definição, pois eles mudam conforme o ângulo de emissão, o comprimento de onda e a fenologia da vegetação (WIGNERON et al., 2004).

Diante do que aqui foi exposto, pode-se dizer que entre as abordagens disponíveis para a estimativa do teor de água no solo, as medidas pontuais realizadas *in situ*, manuais ou automáticas, são as mais simples e precisas. No entanto, independentemente do método utilizado (TDR, método gravimétrico, sonda de nêutrons, sondas de capacitância, tensiômetros, etc.), os recursos demandados e o dispêndio de tempo são elevados, e as informações fornecidas limitam-se a alguns pontos selecionados. Além disso, essas técnicas mostram uma série de desvantagens, tais como: serem destrutivas (método convencional gravimétrico); radioativas (sonda de nêutrons); apresentarem limites de funcionalidade de até 1 atm (tensiômetros); possuírem limites na geometria de instalação (cabo < 20 m: TDR) ou ainda, a não aplicabilidade em solos com elevado teor de argila e matéria orgânica, bem como, em solos com alta salinidade (TDR e sensores de capacitância, por exemplo).

Por outro lado, técnicas de sensoriamento remoto representam uma maneira rápida e eficaz para estimativa do teor de água no solo em grandes áreas. Contudo, também são afetadas por uma série de limitações, como, por exemplo: deficiente resolução espacial (sobretudo para pequenas bacias) e dificuldades de interpretação do sinal, especialmente em razão da influência da rugosidade da superfície, dos efeitos de distorção causados pela topografia, das variações no teor de água, e pela presença de vegetação; não se excluindo a necessidade de medições em terra para validação dos valores calculados pelos modelos.

Fica evidente, portanto, a necessidade de desenvolvimento de novas metodologias e/ou a adequação daquelas existentes, para que a estimativa do teor de água no solo possa ser realizada com adequada eficiência e baixo custo, principalmente para pequenas bacias hidrográficas. Uma alternativa para essa questão é o emprego de modelos matemáticos que considerem as características climáticas da região, e as propriedades físicas do solo e topográficas da bacia que mais influenciam o teor de água no solo.

2.2 Fatores que influenciam o teor de água no solo

A variabilidade espacial e temporal do teor de água no solo é controlada por interações complexas que envolvem fatores relacionados ao solo, à vegetação, à topografia, e ao clima; sendo a importância de cada uma dessas variáveis dependente das características predominantes no local analisado (WESTERN et al., 2004). Essa condição dificulta ainda

mais a estimativa do teor de água (VEREECKEN et al., 2007), sobretudo porque muitos desses fatores apresentam um comportamento influenciado pela presença dos demais.

2.2.1 Variável climática – chuva

A precipitação interfere diretamente no teor de água no solo, determinando a disponibilidade de água nesse solo. Em razão dessa estreita relação entre essas duas variáveis, a utilização de informações pluviométricas na estimativa do teor de água no solo obviamente melhora os resultados obtidos, em qualquer escala considerada. Essa melhora dependerá da variabilidade e da quantidade precipitada, bem como, das condições pré-existentes do teor de água no solo (KORRES, REICHENAU e SCHNEIDER, 2013).

Em geral, os picos do teor de água no solo ocorrem após grandes volumes pluviométricos, com maiores médias observadas após fortes chuvas. Outros fatores que influenciam a magnitude dos picos incluem: o teor de água médio antecedente (condições pré-existentes de alta umidade geram maiores teores médios de água no solo, comparada à presença de um baixo teor de água anterior e um evento de igual magnitude), a intensidade da precipitação (maiores intensidades geram escoamento superficial mais elevado, gerando menor infiltração e, portanto, menor teor médio de água no solo), e o tempo relativo da precipitação para um dado teor de água monitorado (quando as amostras são rotineiramente coletadas no período da tarde, permite-se a infiltração e drenagem da água relativa ao evento pluviométrico anterior à coleta considerada) (FAMIGLIETTI, RUDNICKI e RODELL, 1998).

Ilustrativamente, considere-se, por exemplo, uma chuva que tenha ocorrido sobre diferentes altitudes em uma dada bacia hidrográfica. Imediatamente após essa chuva, os pontos localizados nas maiores altitudes estarão com maior teor de água no solo para uma coleta realizada logo após a ocorrência da chuva. Por outro lado, se essa mesma coleta fosse realizada algumas horas mais tarde, esse teor seria menor, pois, nesse caso, a água armazenada já teria sido drenada para os pontos de menor altitude. O inverso ocorre para os pontos de menor altitude.

A intensidade da precipitação é relevante na determinação do teor de água no solo, pois sua magnitude exerce interferência nos processos de escoamento superficial, na infiltração e na saturação do solo (HUZA et al., 2014).

Comumente, a variação do teor médio de água no solo responde com um aumento rápido de seu valor após um evento de tempestade e, uma diminuição gradual nos períodos sem chuva, até a ocorrência do próximo evento. Essa condição é resultante da retirada de água pelo processo de evapotranspiração (BROCCA et al., 2007; CHO e CHOI, 2014).

Uma vez que o teor de água depende primeiramente das precipitações, e sendo seu valor mais influenciado pelas chuvas mais recentes, um índice representativo das condições aproximadas pode ser obtido por meio da série de precipitações. Moore (1980), por exemplo, utilizou a média móvel das chuvas passadas, ponderada exponencialmente (EWMA), definida pela seguinte equação recursiva (equação 7):

$$EWMA_t = (1-\alpha)EWMA_{t-1} + \alpha P_t \quad (7)$$

onde: P_t representa as chuvas ocorridas no tempo t ; α é o coeficiente de ponderação, sempre menor do que 1.

Para um intervalo temporal unitário, o coeficiente α está relacionado à meia-vida h através da equação 8:

$$\alpha = 1 - 0,5^{(1/h)} \quad (8)$$

A opção de escolha pela meia-vida de um intervalo de tempo significa que a precipitação que é reduzida à metade para a composição de EWMA corresponde a um intervalo atrás. Da mesma forma, se a meia-vida é de dois intervalos de tempo, isso significa que as precipitações reduzidas à metade para a composição de EWMA são as de um e dois intervalos atrás (contribuição conjunta).

Essa média móvel tem sido aplicada em séries temporais com intervalos constantes, como um filtro temporal, de acordo com a equação 7. Porém, para melhor esclarecimento do conceito da meia-vida, a equação para EWMA pode ser reescrita como a média móvel infinita:

$$EWMA_t = \sum_{i=0}^{\infty} w_i P_{t-i} \quad (9)$$

$$\text{onde: } w_i = \alpha (1-\alpha)^i \quad (10)$$

Dessa forma, para a meia-vida de 1 intervalo, $\alpha = 0,5$ e w_i formaria a sequência de pesos 0,5; 0,25; 0,125; 0,063; 0,031; etc. Para a meia-vida de 2 intervalos resultaria $\alpha = 0,293$ e a sequência de pesos 0,293; 0,207; 0,146; 0,104; 0,073; etc. Portanto, o número dos pesos iniciais, cuja soma corresponde a 0,5, é a própria meia-vida, sendo o tempo correspondente ao

número de intervalos destes pesos, (exemplo: meia-vida=1, então $w_1=0,5$; meia-vida=2, então $w_1+w_2= 0,293+0,207=0,5$). A soma dos pesos deve ser sempre igual a 1, resultando que a média de EWMA é a mesma das precipitações.

2.2.2 Outras variáveis climáticas - radiação solar, velocidade do vento, umidade relativa do ar, temperatura do ar, pressão atmosférica, período climático (primavera, verão, outono e inverno) e evapotranspiração de referência

As variações da umidade relativa do ar, da temperatura do ar e da radiação solar, [bem como, a velocidade do vento e a pressão atmosférica], afetam diretamente os processos de evapotranspiração sendo, portanto responsáveis por alterações do teor de água no solo (WESTERN, GRAYSON e BLÖSCHL, 2002).

A radiação solar e a temperatura do ar apresentam com o teor de água no solo uma tendência inversa de variação. Já uma relação direta é observada entre o teor de água e a umidade relativa do ar (CHO e CHOI, 2014). Lakshmi, Jackson e Zehrhuhs (2003) observaram uma relação inversa entre a temperatura da superfície e o teor de água no solo, para todos os tipos de uso do solo.

De fato, um aumento da temperatura do ar gera maior pressão de vapor e demanda evaporativa, aumentando a evapotranspiração em condições secas e levando a uma redução no teor de água no solo. A radiação solar e a ação dos ventos definem o poder de evaporação da atmosfera que, por sua vez, é condicionada a absorver mais ou menos vapor de água, dependendo da pressão atuante, o que interfere no teor de água no solo.

Comumente, o teor de água no solo é menor durante o verão, pois as temperaturas e as taxas de evapotranspiração são mais elevadas em comparação com a precipitação. Do contrário, durante o inverno a disponibilidade de água no solo tende a aumentar, isso porque nesse período as taxas de evapotranspiração geralmente decrescem (FAMIGLIETTI, RUDNICKI e RODELL, 1998; WESTERN, BLÖSCHL e GRAYSON, 1998).

2.2.3 Variáveis topográficas da bacia – altitude, declividade e proximidade com o rio (zonas de descarga)

Variações na inclinação, no aspecto topográfico, na curvatura, e na elevação relativa afetam a distribuição do teor de água na superfície do solo. O aspecto topográfico e a orientação da declividade influenciam a radiação solar e, por consequência, a evapotranspiração (FAMIGLIETTI, RUDNICKI e RODELL, 1998). A declividade e a

elevação do terreno, por sua vez, interferem nos processos de transformação chuva-vazão, influenciando as taxas de infiltração, a capacidade de retenção de água, e o comportamento e a redistribuição da água no solo (WESTERN et al., 2004; SUR, JUNG e CHOI, 2013).

Em geral, pode-se dizer que quanto maior a declividade do solo menor é a quantidade de água infiltrada e, portanto, menor o teor de água nesse solo; ou seja, existe uma relação inversa entre a elevação relativa e o teor de água na superfície do solo. Essa condição demonstra que as áreas de encosta são mais suscetíveis a serem secas, enquanto que aquelas localizadas em pontos mais baixos (regiões mais planas) apresentam maior teor de água, devido à ocorrência de maior infiltração. Há que se considerar ainda, que locais mais baixos recebem as águas de áreas mais altas e, dessa, forma, existe maior número de áreas drenadas contribuindo nesses pontos em comparação àqueles mais altos, o que torna os pontos mais baixos mais suscetíveis a apresentarem teores de água mais elevados (FAMIGLIETTI, RUDNICKI e RODELL, 1998).

Zhu e Lin (2011) observaram variações mais significativas no teor de água no solo para regiões mais elevadas e heterogêneas em sua topografia (considerando 145 pontos de amostragem, localizados em uma fazenda da Universidade de Kepler, na Pensilvânia), quando comparadas às variações no teor de água estimado para áreas consideradas mais homogêneas em relação à topografia e às propriedades do solo.

Além disso, quando se aumenta a distância em relação às zonas de descarga perenes, [regiões caracterizadas por maior concentração de água (como os rios)], mais elevada tende a ser a variabilidade do teor de água no solo (WESTERN et al., 2004).

2.2.4 Variáveis físicas do solo – tipo de solo, granulometria, densidade, tensão da água no solo, e resistência à penetração no solo

A heterogeneidade do solo afeta a distribuição da água nesse solo devido a variações em sua textura e estrutura, no teor de matéria orgânica, e também, em razão da existência de macroporos. Adicionalmente, a cor do solo exerce influência sobre o albedo da superfície e, conseqüentemente, sobre as taxas de evapotranspiração. Tais fatores interferem nos processos de armazenamento e redistribuição da água no perfil do solo (FAMIGLIETTI, RUDNICKI e RODELL, 1998).

A textura afeta a estrutura de um solo e, por conseqüência, sua capacidade de retenção de água. As frações mais grosseiras (areias) apresentam reduzida capacidade de armazenamento de água, enquanto que as frações mais finas (sobretudo os coloides de argila e

de partículas orgânicas) possuem maior capacidade de adsorção e retenção de água, isso porque tais frações apresentam elevada área superficial e grande presença de íons, fatores que condicionam a atração e adsorção de moléculas de água. Dessa forma, pode-se esperar que solos com textura mais fina e elevado teor de matéria orgânica apresentem maior teor de água (WESTERN et al., 2004).

Baroni et al. (2013) realizaram atividades de monitoramento do teor de água no solo entre junho e outubro de 2006, em uma área plana com 10 ha no norte da Itália, durante a temporada de cultivo de um campo de milho. Eles verificaram que a variabilidade desse teor apresenta correlação significativa com as propriedades do solo (porcentagem de areia, silte e argila) nos períodos chuvosos (períodos úmidos).

A temperatura no solo está relacionada às variações do teor de água nesse solo, em curtos períodos de tempo, ocorrendo um aumento da temperatura para um decréscimo desse teor de água, isso porque a água absorve a radiação incidente sobre a superfície do solo, diminuindo o fluxo de calor nesse solo e, a magnitude desse fluxo é determinante nos processos de evapotranspiração. Por conseguinte, mudanças na temperatura da superfície afetam o teor de água no solo e vice-versa (LAKSHMI, JACKSON e ZEHRFUHS, 2003).

A densidade do solo e a resistência à penetração no solo estão diretamente vinculadas às características de compactação do solo e, portanto, ao volume de vazios (estrutura do solo) e à capacidade de infiltração e de armazenamento de água no solo. Niemann e Edgell (1993) observaram que a macroporosidade exerce controle sobre o movimento da água no solo e também, na variabilidade do teor de água nesse solo.

Por outro lado, alterações na tensão da água no solo afetam a evapotranspiração, aumentando a energia necessária para extração da água nesse solo quando ocorre uma diminuição de seu teor de água (WESTERN, GRAYSON e BLÖSCHL, 2002).

2.2.5 Uso do solo e cobertura vegetal

O uso do solo tem papel fundamental nos sistemas de enraizamento, na fisiologia das plantas, e nas propriedades do solo, entre as quais a densidade e a porosidade (HU et al., 2009). Múltiplos usos do solo tendem a aumentar a variabilidade do teor de água nesse solo (WESTERN, BLÖSCHL e GRAYSON, 1998).

As plantas conectam o solo à atmosfera através de suas raízes, fornecendo caminhos para o transporte da água, a partir da zona das raízes para a atmosfera, influenciando a extração da água do solo, as taxas de evapotranspiração, a quantidade de água interceptada

pelo dossel, a condutividade hidráulica do solo, e o teor de matéria orgânica. O grau dessa interferência varia conforme a época do ano [(fator relacionado à fenologia do vegetal e à evapotranspiração)], o tipo [(ou a espécie)], [a idade], e a densidade dessa vegetação (FAMIGLIETTI, RUDNICKI e RODELL, 1998).

A profundidade das raízes, e as características de cobertura da superfície e de utilização da água dependem da espécie predominante em cada local, configurando propriedades determinantes dos processos de evapotranspiração e interceptação (WESTERN et al., 2004).

Baroni et al. (2013) demonstraram que a vegetação afeta significativamente a dinâmica do teor de água no solo, tanto diretamente como através da interação com outros fatores (textura do solo, por exemplo). Esses autores também observaram que a variabilidade na distribuição do teor de água no solo nos períodos secos é bastante influenciada pela vegetação presente, isso porque a evapotranspiração nesse período é bastante elevada.

Já Oliveira, Castro e Goldenfum (2010) avaliaram as diferenças no comportamento das variáveis hidrológicas do balanço hídrico, sob duas condições de manejo do solo (plantio direto com e sem palha na cobertura), através de lisímetros de 1 m³ contendo solo indeformado. O período de monitoramento caracterizou-se como um ano atípico para a região em relação à precipitação, apresentando um período úmido e outro seco, bem distintos. Os autores verificaram que a presença da palha na superfície do solo impede a incidência direta da radiação solar, diminuindo a temperatura no solo e, por consequência, a evapotranspiração; o que aumenta o teor de água no solo nas camadas mais superficiais (10 cm de profundidade), em comparação com aquele solo sem cobertura e sob as mesmas condições.

Feltrin et al. (2013), por sua vez, monitoraram o comportamento e a variabilidade espacial da umidade do solo, considerando tensiômetros eletrônicos instalados em uma bacia hidrográfica localizada no sul do Brasil. Esses tensiômetros foram instalados em um solo com cobertura vegetal de floresta nativa (Bioma Mata Atlântica) e outro com pastagem. O monitoramento foi realizado simultaneamente para as duas coberturas, no período compreendido entre outubro de 2010 e maio de 2011. Os resultados obtidos mostraram que as maiores variações da tensão da água no solo, do teor de água no solo, e do armazenamento de água ocorreram na camada compreendida entre 10 e 30 cm de profundidade, tanto para a pastagem como para a floresta. Os autores também constataram que o conteúdo de água no solo da floresta foi maior do que aquele da pastagem; existindo uma diferença de 5,73% e

41,12% entre o armazenamento de água no solo da floresta e da pastagem para uma profundidade de 10 e 30 cm, respectivamente.

2.3 Redes neurais artificiais (RNAs)

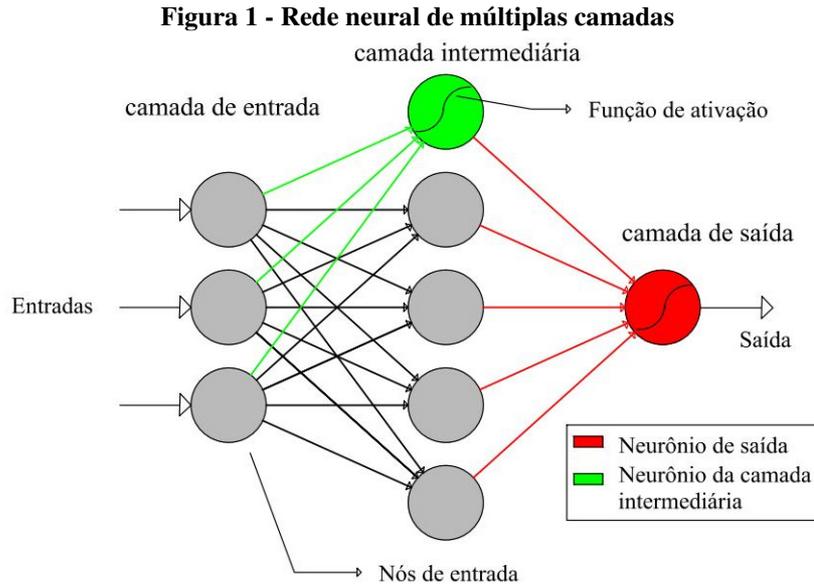
2.3.1 Origem e Natureza:

As redes neurais artificiais foram idealizadas como modelos matemáticos que procuram imitar o funcionamento do cérebro humano. Os primeiros estudos de simulação de um neurônio biológico foram realizados por McCulloch e Pitts (1943), que reproduziram o comportamento do neurônio natural através de um modelo lógico-matemático chamado neurônio artificial, com um sinal de saída derivado de uma ou mais entradas, resultando em uma analogia entre este e os processos eletrônicos. Todavia, a primeira aplicação prática das RNAs, veio somente com o trabalho de Rosenblatt (1958), com a invenção de uma rede de uma camada de neurônios artificiais em paralelo, com tantas saídas quantos neurônios empregados, denominada Perceptron; sendo essa a primeira rede com a capacidade de identificar padrões, graças a um algoritmo próprio de treinamento.

Mais tarde, Widrow e Hoff (1960) introduziram um novo algoritmo de aprendizado, a regra delta, no treinamento de redes neurais do tipo Perceptron adaptativas, porém, sem resultar em capacidade de simulação de relações ou de operações lógicas mais complexas.

Na verdade, as redes neurais de múltiplas camadas (Figura 1) é que são eficientes para a aproximação de relações não lineares, possuindo a capacidade de simular operações lógicas complexas. Não obstante, inicialmente, não existia um método para seu treinamento, embora seu potencial de treinamento fosse sustentado pelo teorema de Kolmogorov (1957), que foi, posteriormente, enunciado para redes neurais como o teorema de Kolmogorov-Nielsen (HECHT-NIELSEN, 1990). Esse teorema estabelece que, para qualquer relação contínua com n entradas e m saídas, existe sempre uma rede neural do tipo Perceptron, com apenas uma camada interna de $2n+1$ neurônios, capaz de aproximá-la.

A disposição dos neurônios artificiais em camadas facilita a construção de algoritmos de operação e de treinamento. A primeira camada consiste nas conexões dos sinais de entrada do modelo, sendo ou não seguida de uma ou mais camadas intermediárias, e de uma camada de saída.



A partir dos anos 80 houve um maior interesse em torno do assunto, principalmente, em função da evolução tecnológica, que disponibilizou novos recursos para processamento computacionais e com a aplicação do método retropropagativo para treinamento de redes neurais de múltiplas camadas, proposto por Rumelhart, Hinton e Williams (1986). Desde então, com o desenvolvimento e a utilização de diversas ferramentas computacionais, as redes neurais artificiais vêm sendo cada vez mais utilizadas, tendo produzido bons resultados em diversas áreas de aplicação.

A unidade de processamento de uma RNA é o neurônio artificial, cujo conjunto interconectado possui potencial para aproximar relações entre variáveis de entrada e de saída. A resposta de um neurônio artificial individual é calculada através de uma função de ativação, que atua sobre a soma ponderada das entradas deste neurônio. Os coeficientes de ponderação de cada entrada são chamados de pesos sinápticos, em analogia aos neurônios biológicos. Uma entrada unitária adicional, com peso sináptico b , é acrescentada, para que a saída do neurônio possa assumir valores diferentes de zero, mesmo para entradas líquidas nulas.

A função de ativação afeta a saída de um neurônio a partir da transformação da entrada líquida. Kasabov (1998) classifica as principais funções de ativação utilizadas como: i) a função limiar, onde as saídas são classificadas em 1 ou 0; ii) a função linear, que utiliza transformações lineares; iii) a função sigmoide, cujo gráfico possui uma forma de "S" e é a principal função de ativação utilizada nas RNA, e se caracteriza por ser uma função crescente, não linear, possuindo valores nos intervalos $[0,1]$ (função sigmoide unipolar) ou $[-1,1]$ (função sigmoide bipolar).

Na prática, observa-se que as alternativas da função sigmoide são equivalentes, e proporcionam a capacidade de aproximação de relações não lineares. A função de ativação sigmoide unipolar e sua derivada podem ser representadas pelas equações 11 e 12, respectivamente:

$$a = \frac{1}{1+e^{-n}} \quad (11)$$

$$f'(n) = a(1 - a) \quad (12)$$

onde: a é a saída da função de ativação; n é a entrada líquida; e $f'(n)$ é a derivada da função de ativação relativa à entrada líquida.

O desenvolvimento de um modelo de redes neurais artificiais envolve basicamente a definição da arquitetura da rede (que consiste na quantidade e na disposição dos neurônios artificiais, e na função de ativação escolhida), o treinamento e a verificação da generalização (comparação dos valores estimados pela rede treinada com uma série de dados não utilizados no treinamento da rede).

2.3.2 Treinamento das RNAs

A Regra Delta, proposta por Widrow e Hoff (1960) para o treinamento de redes neurais de uma camada, consiste em, inicialmente, se atribuir valores aleatórios aos pesos sinápticos e calcular o erro na saída da rede neural. O procedimento iterativo de treinamento é aplicado enquanto a estatística representativa dos erros admissíveis não for aceita. Esta regra não só aproxima os pesos para o ideal, como faz isso de maneira eficiente. É na verdade um processo de procura do ótimo na superfície de desempenho, com direção indicada pela derivada da função de ativação no ponto, precisando-se de um ponto inicial aleatório.

Inicialmente, a regra delta foi desenvolvida para redes de uma camada, não sendo aplicada para redes mais complexas, já que seria dependente do conhecimento do erro na saída. A equação 13 apresenta a forma generalizada de correção dos pesos.

$$W_{k+1} = W_k + (\tau e_s \delta_k P_k) \quad (13)$$

onde: W_k são os pesos sinápticos; τ é a taxa de aprendizado; e_s são os erros das saídas da camada; δ_k são as derivadas das funções de ativação; e P_k são as entradas na própria camada, para a amostragem ou ciclo k de treinamento.

A taxa de aprendizado é muito importante durante o processo de treinamento de uma rede neural, e afeta o “passo” de caminamento no espaço dos parâmetros. Se a taxa de aprendizado escolhida for muito grande, os pesos podem oscilar com uma grande amplitude, passando longe do mínimo global, enquanto que, se a taxa for muito pequena, a convergência do algoritmo pode ser muito lenta, vindo a estacionar nas proximidades de um mínimo local (KASABOV, 1998).

A aplicação da regra delta para redes neurais de múltiplas camadas, por sua vez, depende do conhecimento dos erros das camadas internas, cujo procedimento de cálculo era desconhecido até a descoberta do algoritmo de retropropagação, proposto por Rumelhart, Hinton e Williams (1986). Somente a partir daí, esses erros passaram a ser calculados, com base nos erros observados na camada de saída. Esse algoritmo calcula os erros da camada interna pela equação 14:

$$e_h = \sum(W_s e_s \delta_s) \quad (14)$$

onde: e_h é o erro na camada interna; W_s são os pesos sinápticos na camada posterior; e_s são os erros na camada posterior; e δ_s são as derivadas da função de ativação na camada posterior.

A aplicação do algoritmo consiste em uma sequência de ciclos, cada um deles composto da submissão, à rede, de uma amostragem de registros representativos, e em quantidade suficiente, de entradas e saídas. Para cada ciclo, são realizadas as seguintes etapas:

1. Atribuição inicial de pesos sinápticos aleatórios;
2. Aplica-se a rede neural, e, a partir dos resultados e das observações respectivas, são calculados os erros da saída;
3. Com os erros, os pesos que foram atribuídos e as derivadas da saída, são calculados os erros da camada anterior (equação 14);
4. Com os erros da saída, suas derivadas, a taxa de aprendizado e as entradas (resultantes da camada anterior), utiliza-se a regra delta (equação 13) para atualizar os pesos sinápticos; w_{sk+1}
5. Com os erros da camada intermediária (obtidos na etapa 3), suas derivadas, taxa de aprendizado e entradas da rede, são atualizados os pesos desta camada (equação 13, regra delta); w_{hk+1}
6. O processo é repetido, desde a etapa 2, até ser obtida a condição de parada.

O principal critério de parada do treinamento é o da precisão desejada. Essa precisão pode ser representada por indicadores de duas naturezas: Erros admissíveis em um ciclo (erro máximo, erro mediano, erro associado a uma frequência, etc.) e estatísticas de desempenho, onde um desempenho mínimo (representado pelo erro quadrático, erro absoluto médio, etc.) é requerido. É necessário um critério adicional, para a interrupção dos processos que não convergem, sendo o mais comum o número máximo de ciclos.

Entretanto, em algumas aplicações, o método retropropagativo não é muito eficiente, visto que exige um grande número de repetições para que haja uma convergência dos resultados. Como alternativa prática para melhorias do algoritmo retropropagativo, sugere-se modificações do mesmo, buscando uma aceleração da convergência (VOGL et al., 1988).

Uma dessas modificações consiste na realização do aprendizado com uma taxa heurísticamente variada. Esta técnica implica a aceitação dos pesos sinápticos com o aumento da taxa de aprendizado, sempre que o erro, em um ciclo de treinamento, sofrer redução. E, ainda, a manutenção das estimativas anteriores dos pesos, com redução da taxa de aprendizado, quando o erro em um ciclo aumentar em relação ao erro presente no ciclo anterior. Os fatores multiplicativos recomendados, para a redução ou o aumento da taxa são, respectivamente, 0,5 e 1,1.

Por certo, o método de treinamento é dependente das condições iniciais, a partir das quais o treinamento corre o risco de estacionar em mínimos locais. Este fenômeno é tanto mais frequente quanto mais complexa é a superfície de desempenho, sendo que essa complexidade está associada, por sua vez, à complexidade da rede e dos fenômenos que estão sendo simulados.

Para contornar este problema, pode-se executar o treinamento com diversas partidas de pesos aleatórios, adotando-se o modelo cujo desempenho no treinamento revelou-se melhor.

Os resultados de um estudo proposto por Dornelles (2013) apontam que após 30 realizações de treinamentos, a partir de condições aleatórias, os melhoramentos possíveis de desempenho de uma rede são muito pequenos, para o caso específico de modelos de previsões hidrológicas com redes neurais de múltiplas camadas.

Por outro lado, um superajustamento ocorre quando o treinamento consegue reproduzir até mesmo o comportamento individual, inclusive os erros e a aleatoriedade das amostras de treinamento, o que prejudica a sua capacidade de generalização. Em geral, quando os resultados da verificação são muito bons para os propósitos desejados, pode-se

admitir que não houve um superajustamento ou, que ele foi irrelevante. Caso contrário, cuidados tornam-se necessários para evitá-lo.

Entre os métodos para evitar o superajustamento estão: a limitação da complexidade da rede (com graus de liberdade suficientemente reduzidos, que não permitam a reprodução das oscilações indesejadas) e a interrupção antecipada do treinamento (uma vez que, a forma da reprodução proporcionada pela rede evolui a partir de uma explicação nula da variância em direção a complexidades crescentes).

O recurso mais conhecido de procedimento automático para a interrupção antecipada é a técnica da validação cruzada. A técnica de validação cruzada utiliza, além da série de treinamento, uma série adicional (série de validação), para determinar o ponto de parada ótimo durante o treinamento, para que esta não perca a sua capacidade de generalização; evitando-se, dessa forma, o superajustamento. Outro conjunto de dados, chamado de série de verificação, que não faz parte daqueles dados utilizados para o treinamento da rede, é utilizado para a avaliação do desempenho da generalização. Com o uso dessa técnica, verifica-se que o índice de desempenho com a série de treinamento vai sempre diminuindo (indicando desempenho melhor), enquanto que o índice de desempenho com a série de validação, a partir de determinado ciclo, torna a subir, indicando que um limiar foi atingido; a partir do qual a capacidade de generalização é comprometida. Este é o limiar de interrupção do treinamento (HECHT-NIELSEN, 1990).

Para a técnica de validação cruzada são utilizadas três séries dos registros de dados disponíveis, com proporções recomendadas de 50% para o treinamento, 25% para a verificação e os restantes, 25%, para a validação.

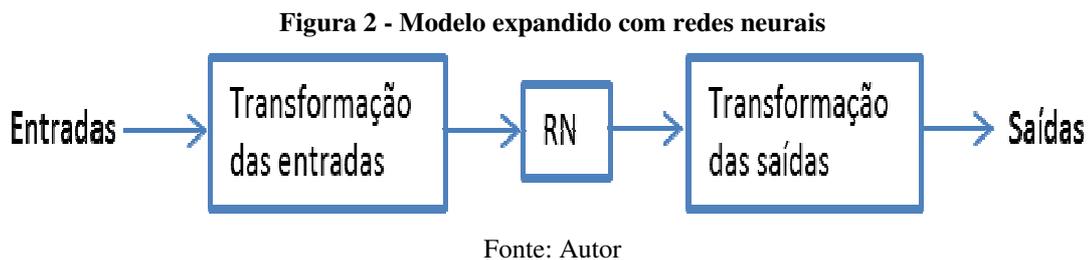
Em alguns casos, a utilização da validação cruzada é inviável, porque a quantidade de dados representativos disponíveis é excessivamente restrita, uma vez que essa técnica pressupõe a divisão dos registros amostrais em três séries distintas. Assim, quando o número de registros disponíveis não recomenda a divisão destes em três séries representativas, pode-se utilizar outros recursos, embora bem mais onerosos computacionalmente e, em geral, menos confiáveis.

2.3.3 Modelos Expandidos com Redes Neurais

O escalonamento de dados tem por objetivo realizar sua transformação, e também para adequar as saídas das funções de ativação dos domínios reais das variáveis simuladas. Os parâmetros de transformação devem ser agregados ao modelo para operações futuras e para a

recuperação da escala original dos resultados (Figura 2). Os cálculos desses parâmetros das transformações, por conseguinte, devem ser executados com dados representativos de todo o domínio desejado, inclusive para o uso futuro da rede.

Quando se trabalha com diferentes séries temporais se faz necessário o escalonamento dos dados de entrada, já que existe a possibilidade de as séries possuírem amplitudes de valores bem diferentes, o que afetaria o treinamento da rede, ao favorecer as variáveis de maior magnitude.



Quanto ao escalonamento dos dados de saída, é utilizado em duas situações: ante a existência de mais de uma saída com diferentes magnitudes, o que afetaria o treinamento tanto quanto a existência de entradas de grandezas diferentes; e para se ajustar as variáveis de saída aos contradomínios da função de ativação, uma vez que as funções de ativação utilizadas possuem domínio de saída restrito (Ex.: entre 0 e 1).

Portanto, as redes neurais constituem-se, na maioria dos problemas práticos, em partes de modelos, compostos também de transformações dos dados, as quais podem, por sua vez, ser lineares ou não-lineares. Com o uso de escalonamento linear, tanto para as entradas quanto para as saídas, o modelo resultante pode ser representado pela equação 15:

$$\frac{yt-bu}{au} = RN \frac{xt-be}{ae} \quad (15)$$

onde: x_t e y_t são as variáveis de entrada e de saída, respectivamente; a_u e b_u são parâmetros de escala e de posição das saídas do modelo, respectivamente; a_e e b_e são os parâmetros de escala e de posição das entradas do modelo, respectivamente.

2.3.4 Avaliação dos Resultados das RNAs

Para se avaliar o desempenho das RNAs, podem ser utilizadas três estatísticas: coeficiente de Nash-Sutcliffe (NASH e SUTCLIFFE, 1970), erro absoluto médio (EAM),

como em ZHANG, PATUWO e HU (1998), e o erro não ultrapassado em 95% das amostras, que corresponde ao quantil 95% ou E95 (DEPINÉ et al., 2014).

O coeficiente de Nash-Sutcliffe (NS) é uma medida da proporção da variabilidade da variável de saída, que é explicada pelo modelo (Equação 16); e representa a capacidade de ajuste da RNA. Essa medida pode variar de negativo infinito ($-\infty$) a um. Desta forma, valores altos de NS indicam que a rede apresenta elevada capacidade preditiva, conforme exemplificado em Silva et al. (2008). Nesse trabalho, especifica-se:

$$NS = 1 - \frac{\sum(U_{obs_t} - U_{mod_t})^2}{\sum(U_{obs_t} - \overline{U_{obs}})^2} \quad (16)$$

onde: U_{obs_t} é a precipitação registrada pela estação pluviométrica no intervalo de tempo t (mm h⁻¹); U_{mod_t} é a precipitação modelada no intervalo de tempo t (mm h⁻¹); e $\overline{U_{obs}}$ é a precipitação média registrada pela estação pluviométrica em todo o período simulado (mm/h).

Já o erro absoluto médio (EAM) procura quantificar, em termos médios, a diferença entre os valores reais e os estimados. O modelo com o menor valor para EAM é considerado “o melhor” quando comparado a outro.

Quanto ao E95 representa o valor em que o erro não é ultrapassado em 95% da amostra preenchida, ou seja, apenas 5% do preenchimento terão valores de erro superiores ao E95. Esta estatística é mais robusta do que o erro máximo, o qual pode estar sendo afetado por erros nos dados de valores atípicos.

2.3.5 Análise e Seleção das Variáveis Explicativas

As entradas das redes neurais dependem diretamente do tipo de estudo que está sendo realizado. No caso das previsões de teor de água no solo, essas variáveis são aquelas envolvidas no processo na área de abrangência do estudo, como, por exemplo, a chuva, as características do solo e as características geomorfológicas da bacia.

Nos modelos baseados em RNAs, o excesso de variáveis de entrada, muitas vezes, pode reduzir a eficiência da simulação. Neste caso, os principais efeitos são: aprendizado dificultado, com o aumento da complexidade que resulta de variáveis com pouca ou nenhuma contribuição; aumento de mínimos locais na superfície de desempenho, provocando convergência insuficiente e perda de precisão; e maior dificuldade na interpretação de

modelos complexos de modo semelhante aos resultados de modelos mais simples. Existe ainda uma “maldição da dimensionalidade”, segundo a qual entradas irrelevantes prejudicam os resultados, pois fazem com que o modelo utilize recursos importantes para representar porções insignificantes do espaço de soluções; sendo requerida maior quantidade de dados para compensar este efeito (BOWDEN, DANDY e MAYER, 2005).

O método da análise preliminar das autocorrelações e intercorrelações (SALAS et al., 1980) entre as variáveis explicativas e a explicada é o mais popular, apresentando, porém, a desvantagem de não apontar as possíveis relações não lineares entre as entradas e saídas, resultando na omissão de variáveis que seriam importantes.

Além disso, pode ser que uma variável explicativa tenha seus efeitos potencializados pela presença de outra que, individualmente, pode ou não ter sido classificada como importante para o processo (OLIVEIRA et al., 2011). Ou ainda, duas variáveis que possuam coincidência parcial de informações (exemplo: chuva de 1 dia e de 2 dias), quando juntadas no mesmo modelo, podem prejudicar a sua eficiência, ao repetirem as informações, mascarando o treinamento e prejudicando também a interpretação.

Já o método de, simplesmente, experimentar todas as combinações possíveis, pode se tornar inviável, mesmo para um pequeno número de variáveis explicativas, pois todas as combinações devem ser treinadas e testadas com dados diferentes do treinamento.

Assim sendo, os métodos mais utilizados, entre os que extraem informações de redes já ajustadas, são os chamados métodos de análise de sensibilidade; baseando-se em interferências sobre cada uma das variáveis de entrada e na verificação de seu efeito sobre as variáveis de saída (BOWDEN, DANDY e MAYER, 2005).

O termo análise de sensibilidade das variáveis de entrada refere-se à sensibilidade do modelo a modificações induzidas sobre cada variável de entrada. A hipótese básica é de que as variáveis cujas modificações induzidas influenciam mais fortemente as saídas são as mais importantes.

O método utilizado por Maier e Dandy (1997) revelou-se simples e eficiente para a verificação da influência de diferentes defasagens temporais em séries de entrada dos modelos de redes neurais. Um índice, chamado índice de sensibilidade (“*sensitivity*”) S , é calculado conforme a equação 17:

$$S(i) = \frac{\% \text{ das modificações resultantes sobre as saídas}}{\% \text{ das modificações induzidas sobre cada entrada}(i)} \times 100 \quad (17)$$

O uso de proporções evita que o índice resultante seja afetado pelas diferenças de magnitude das variáveis.

Segundo os autores, variáveis com maior sensibilidade são mais importantes para a simulação. Com isso, recomenda-se o uso desse índice como um índice de significância relativa para o modelo, para a classificação das variáveis explicativas de acordo com sua importância na simulação, e mesmo, para a eliminação de variáveis que não contribuam, significativamente, para a concepção de modelos subsequentes.

Um índice de sensibilidade positivo indica que um aumento da variável explicativa correspondente resulta, também, em um aumento da variável de saída do modelo. Inversamente, quando o índice de sensibilidade é negativo, um aumento da variável explicativa correspondente resulta em uma redução da variável de saída do modelo. No primeiro caso, a variável explicativa possui efeito direto, e no segundo, subtrativo.

2.3.6 Alguns resultados da estimativa do teor de água no solo utilizando RNAs: cenário nacional e internacional

No APÊNDICE A é apresentada uma tabela resumo contendo as principais características e conclusões de alguns estudos publicados entre 2004 e 2013 que utilizaram as RNAs para estimativa do teor de água no solo. Em geral, esses estudos empregaram redes progressivas de múltiplas camadas com algoritmo retropropagativo para treinamento da rede, tendo encontrado bons resultados em suas estimativas. Apenas um trabalho analisado referia-se à estimativa do teor de água em solos brasileiros.

Dos 14 estudos encontrados, 7 deles estimaram o teor de água no solo empregando parâmetros obtidos por imagens de satélite ou radar, como, por exemplo: a temperatura de brilho polarizada da superfície (horizontal e vertical), o índice de vegetação (NDVI), a temperatura da superfície terrestre (LST), o coeficiente de retroespalhamento, o ângulo de incidência, e a rugosidade da superfície do solo (JIANG e COTTON, 2004; CHAI et al., 2010; PALOSCIA et al., 2008; SAID et al., 2008; SANTI et al., 2012; PALOSCIA et al., 2013; SRIVASTAVA et al., 2013).

Jiang e Cotton (2004) optaram pela escolha de uma rede híbrida (Mapas Auto-Organizáveis de Kohonen e rede lienar de Grossberg) para estimativa da umidade do solo com alta resolução temporal e espacial, tendo empregado como entradas informações de sensoriamento remoto de temperatura da superfície, índice de vegetação NDVI e precipitação acumulada (30 dias). Os autores alcançaram bom desempenho para o modelo durante o

treinamento ($R^2=0,9529$) e também no teste da rede ($R^2=0,9971$); entretanto, o modelo adotado tende a subestimar a umidade no perfil do solo (0 a 75 cm) quando os valores reais da umidade são baixos e subestimar quando os valores de umidade são altos.

Chai et al. (2010), por sua vez, testaram diferentes configurações de RNAs para determinar a umidade do solo em regiões menores (até 4 km²), a partir de imagens de satélite de áreas maiores. O melhor modelo encontrado pelos autores ($R^2=0,88$ e $RMSE=2,86\%$) foi uma rede progressiva com três camadas, contendo 20 neurônios na camada intermediária, e tendo como entradas a temperatura de brilho polarizada (vertical e horizontal).

Paloscia et al. (2008) analisaram a possibilidade de estimativas de mapas de umidade do solo de áreas agrícolas, a partir de informações obtidas por um único sensor (ENVISAT/ASAR). Para isso, os autores desenvolveram duas redes progressivas com 2 camadas intermediárias cada e 10 neurônios em cada uma dessas camadas. Uma RNA (RNA1) incluiu a variável de entrada coeficiente de retroespalhamento (considerando polarização HH e HV e ângulo incidente de 23°); enquanto que a outra rede (RNA2) empregou como entradas o coeficiente de retroespalhamento (polarização HH e HV e ângulo incidente de 23°) e a rugosidade da superfície do solo. O desempenho das duas redes foi bom, com melhor resultado para a RNA2 ($R^2=0,85$ para RNA1 e 0,91 para a RNA2).

Por outro lado, Said et al. (2008) avaliaram diferentes configurações de RNAs (24 no total), considerando dados do ERS-2 SAR de diferentes datas, para identificar a umidade do solo quando esse solo encontrava-se exposto ou com cobertura vegetal. Um modelo utilizando 5 variáveis de entrada (cobertura vegetal, ângulo de incidência, rugosidade da superfície, coeficiente de retroespalhamento, altura da rugosidade da superfície RMS e índice de área foliar) foi considerado satisfatório para determinação da umidade do solo, com R^2 variando entre 0,85 e 0,92 (diferentes datas). Considerando as diferentes configurações adotadas para as RNAs, o R^2 variou entre 0,74 e 0,93 durante o treinamento, entre 0,70 e 0,91 na validação da rede e entre 0,72 e 0,89 durante o teste da rede. Os autores também observaram que a utilização de informações das 3 imagens combinadas (diferentes datas) reduz o R^2 , isso porque a variação da umidade ao longo do tempo é mais elevada (para um mesmo ponto).

Já Santi et al. (2012) escolheram uma rede progressiva multicamada, com duas camadas intermediárias e 10 neurônios em cada uma delas, para estimar a umidade do solo a partir de informações obtidas do sensor AMSR-E, considerando solo exposto ou com pouca vegetação. As variáveis de entrada utilizadas foram temperatura de brilho da superfície na banda C-, com polarização vertical (TbV); ângulo de incidência (> 50°); índice de polarização

banda X- (PIX), TbV na banda Ka-. Os resultados encontrados apresentaram um desempenho bom durante a validação da rede ($R^2=0,82$), mas obtiveram um desempenho inferior no teste da rede (R^2 variando entre 0,28 e 0,52 na órbita ascendente, e entre 0,26 e 0,36 na órbita descendente).

Paloscia et al. (2013) desenvolveram, testaram e validaram RNAs para estimativa da umidade do solo em 6 áreas na Itália, uma área na Austrália e uma na Espanha, utilizando dados do GMES Sentinel-1. As redes empregadas eram do tipo progressiva, com 2 camadas intermediárias e 10 neurônios em cada uma dessas camadas. Os autores utilizaram as seguintes entradas: coeficiente de retroespalhamento (polarização HH, VV, e HV/VH), e o índice de vegetação NDVI. Os autores encontraram desempenho (R^2) entre 0,04 e 0,872. Eles observaram que a polarização VV apresentou os resultados menos favoráveis, já o emprego do índice de vegetação NDVI melhora o desempenho dos modelos, tanto para polarização VV quanto para a HH. Os melhores resultados dos modelos foram obtidos para polarização cruzada.

Srivastava et al. (2013) optaram por uma rede progressiva com 4 camadas (2 camadas intermediárias com 2 neurônios em cada uma delas) para melhorar a resolução espacial de dados de umidade do solo obtidos a partir de dados SMOS (disponíveis em escala de 40 km). O desempenho foi comparado com o déficit de umidade do solo determinado através do modelo de Distribuição de Probabilidades (PDM SMD). As variáveis de entrada do modelo adotado incluíram informações de temperatura da superfície terrestre (MODIS-LST) e dados de umidade do solo (produto derivado de dados do SMOS). A rede apresentou bom desempenho, com $R^2= 0,797$ no treinamento e 0,751 no teste. Durante o período de crescimento da vegetação (março a novembro), o modelo apresentou melhor desempenho no teste da rede ($R^2= 0,617$), deixando a desejar no período de não crescimento (dezembro a fevereiro), onde o R^2 foi apenas 0,273. Por outro lado, o modelo respondeu muito bem quando a rede foi testada considerando todo o período (de crescimento e não-crescimento da vegetação), alcançando um desempenho muito bom ($R^2=0,859$).

Uma parcela dos estudos analisados (quatro estudos) utilizam pelo menos uma variável climática como entrada da RNA, como: precipitação, temperatura e umidade do ar, e radiação solar direta e difusa, temperatura na relva ou nas camadas do solo (CONTADOR, MANETA e SCHNABEL, 2006; COELHO et al., 2009; ELSHORBAGY e PARASURAMAN, 2008; RAMÍREZ-BELTRAN et al., 2008). Enquanto que quatro estudos (ZOU et al., 2010; KÖKSAL et al., 2011; ARSOY et al., 2013; RAMÍREZ-BELTRAN et al.,

2008) usam também informações relativas ao solo (por exemplo: teor de finos, densidade, permissividade dielétrica, e umidade anterior a uma dada profundidade), e apenas um estudo (CONTADOR, MANETA e SCHNABEL, 2006) emprega dados relativos à topografia da área de estudo (curvatura horizontal e vertical, e índice de umidade topográfica) para realizar a estimativa do teor de água no solo. Alguns estudos (quatro do total) consideram parâmetros relativos à vegetação, sejam eles obtidos por imagem de satélite (JIANG e COTTON, 2004; SAID et al., 2008; PALOSCIA et al., 2013) ou por outros meios (CONTADOR, MANETA e SCHNABEL, 2006).

Contador, Maneta e Schnabel (2006) desenvolveram uma rede progressiva com 3 camadas, com 5 neurônios na camada, para prever a umidade do solo a partir de variáveis topográficas e de cobertura do solo, utilizando um número restrito de pontos de amostragem. As variáveis de entrada incluíram a curvatura vertical e horizontal, o índice topográfico, o índice de radiação, e a cobertura vegetal, e o desempenho do modelo foi bom ($R^2=0,71$).

Coelho et al. (2009), por sua vez, empregaram uma rede neural de base radial (rede progressiva com 3 camadas), testando a utilização de 2 a 6 neurônios na camada intermediária, para determinação da umidade no perfil do solo (0 a 3 m) em uma área localizada em Curitiba (PR). As variáveis de entrada usadas foram: temperatura do ar, umidade relativa do ar, e radiação solar direta e difusa. Considerando as diferentes camadas no perfil do solo e variando o nº de neurônios na camada intermediária, o desempenho do modelo para todas as alternativas testadas foi superior a 0,9796 quando consideradas as médias do treinamento e verificação; já quando se considera somente o treinamento da rede, o R^2 variou entre 0,1024 a 0,9996, e para a verificação R^2 variou entre 0,1024 e 0,9990.

Já Elshorbagy e Parasuraman (2008) determinaram a umidade do solo na turfa e em diferentes camadas, considerando diferentes tipos de cobertura (D1: 20 cm turfa + 30 cm solo, D2: 15 cm de turfa + 20 cm solo, e D3: 20 cm turfa + 80 cm solo). Para isso, os autores testaram diferentes modelos de RNA de primeira ordem (modelos M1 a M3, M5 a M9) e de alta ordem (M4, M10 de 2ª ordem). As variáveis de entrada adotadas nos modelos foram: valores médios diários de precipitação (P), temperatura do ar (Ta), temperatura no solo (na turfa: Tt e nas camadas de solo: Ts), e radiação solar (Rs). Os autores encontraram desempenhos do modelo (R^2) entre 0,128 e 0,82 para verificação.

Zou et al. (2010) empregaram uma rede progressiva com 3 camadas, com número de neurônios na camada intermediária determinado pelo método de Box–Jenkins. Para cada profundidade, o número de neurônios por camada considerado satisfatório foi: 5-6-1 (20 cm);

3-5-1 (40 cm); 3-2-1 (60 cm); e 1-4-1 (para todo o perfil do solo). A abordagem de Box-Jenkins também foi usada para descobrir a apropriada defasagem das variáveis de entrada. As variáveis de entrada adotadas foram: umidades médias no perfil do solo, determinadas pela análise clássica de Box-Jenkins e calculadas pelo modelo ARIMA (x_{t-1} , x_{t-12} , x_{t-13} , x_{t-24} e x_{t-25}). O R^2 no perfil do solo variou entre 0,8912 (2 neurônios na camada intermediária) e 0,8987 (4 neurônios na camada intermediária), e o R^2 na profundidade de 20 cm variou entre 0,0057 (15 neurônios na camada intermediária) e 0,8707 (12 neurônios). A melhor estatística, considerando a combinação do R^2 e MSE, foi 0,5244 para a profundidade de 20 cm; 0,9381 para a profundidade de 40 cm; e 0,4797 para a profundidade de 60 cm.

Köksal et al. (2011) desenvolveram modelos de calibração do medidor de umidade de nêutrons, utilizando RNAs. Os autores adotaram rede progressiva com o número de camadas e neurônios na camada intermediária dependente da profundidade do solo, sendo que de 0 a 30 cm e de 30 a 60 cm, a rede adotada possuía 3 camadas com 10 neurônios na camada intermediária; entre 60 e 90 cm a RNA possuía 4 camadas com 15 neurônios nas camadas intermediárias, e entre 90 e 120 cm a rede adotada possuía 3 camadas com 15 neurônios na camada intermediária. Eles também consideram uma rede para o perfil inteiro do solo (0 a 120 cm), sendo essa caracterizada por 4 camadas, com 15 neurônios nas camadas intermediárias. Para as variáveis de entrada foram testadas: i) entradas por camadas (de 30 em 30 cm), considerando dados de entrada de cada camada: razão de contagem (RNA1, RNA2, RNA3 e RNA4); e ii) modelo para todo o perfil (0-120 cm), empregando como entradas valores de profundidade de medição na camada (1/2 da camada) e de razão de contagem (RNA5). O R^2 no treinamento utilizando dados da camada foi igual a 0,94 (0 a 30 cm); 0,95 (30 a 60 cm); 0,87 (60-90 cm); e 0,88 (90 a 120 cm); enquanto que o R^2 no treinamento da rede com dados de 0 a 120 cm foi igual a 0,97.

Arsoy et al. (2013) testaram duas redes progressivas de 3 camadas, uma com 8 e outra com 11 neurônios na camada intermediária, para prever a umidade em solos arenosos com diferentes texturas e níveis de compactação. As variáveis de entrada utilizadas foram: permissividade elétrica aparente, densidade seca, teor de finos, e gravidade específica. Os dois modelos propostos apresentaram bons resultados, com coeficiente de Nash-Sutcliffe (NS) variando entre 0,971 e 0,998 no treinamento (diferentes tipos de solo) para a RNA com 8 neurônios, e entre 0,9998 e 0,9981 no treinamento da rede com 11 neurônios.

Ramírez-Beltran et al. (2008) empregaram RNA progressiva, com 3 camadas e 4 neurônios na camada intermediária, para estimar a umidade do solo em diferentes

profundidades (5, 10, 20, 50, e 100 cm); utilizando como entradas o percentual de argila e areia, a umidade do solo a 20 cm de profundidade, e a precipitação de 30 dias. O RMSE médio do modelo foi igual a 2,50% na verificação, e o RMSE médio por profundidade variou entre: 2,16% e 6,01%, com média de 4,14% (5 cm de profundidade); entre 0,9% e 3,84%, com média de 1,91% (10 cm); entre 1,23% e 2,94%, com média de 2,18% (50 cm); e entre 0,22% e 4,17%, com média de 1,78% (100 cm). O RMSE médio das estações, considerando o perfil do solo, variou entre 1,70% e 4,24%, com média de 2,50%. Os autores concluíram que o algoritmo proposto é uma potencial ferramenta para estimar a umidade do solo em intervalos horários, até 1 km de resolução espacial e com até 1 m de profundidade.

De forma geral, esses estudos demonstram a influência de diferentes fatores sobre a variação do teor de água no solo, sejam eles relacionados ao solo, à topografia, à vegetação ou ao clima. A magnitude dessa influência dependerá das características predominantes em cada região e da interferência de um fator sobre os demais. Porém a grande maioria destes estudos aborda a variação espacial do teor de água no solo, não prevendo a variação deste teor ao longo do tempo em função das variações climáticas.

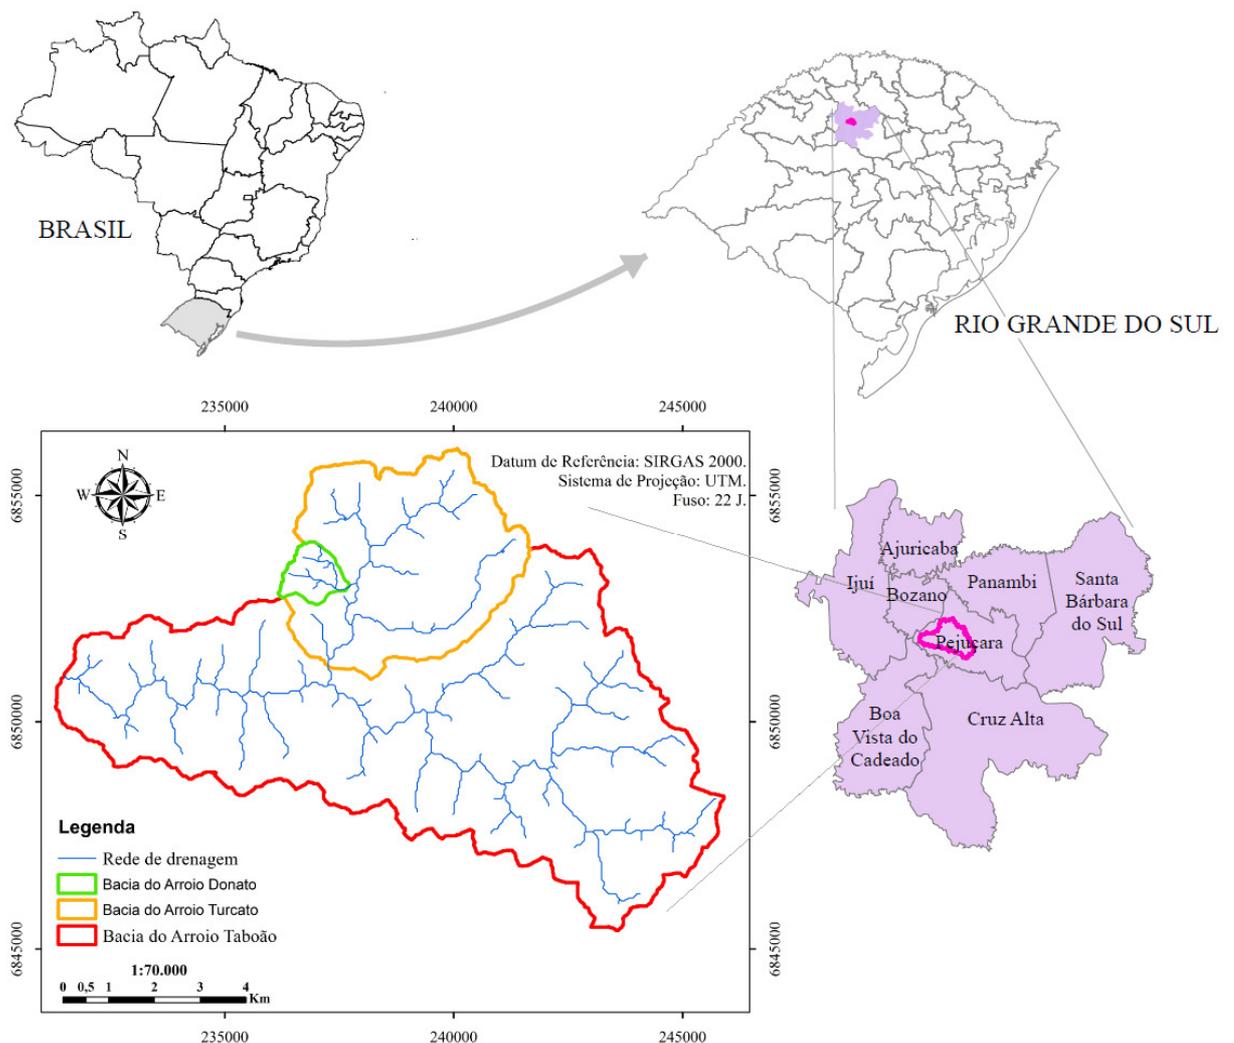
3 CARACTERIZAÇÃO DA ÁREA DE ESTUDO

Neste item descrevem-se as principais características físico-climáticas e de uso do solo da área de estudo dessa pesquisa.

3.1.1 Localização da área de estudo e histórico dos projetos

O local de estudo compreende a bacia hidrográfica do rio Taboão, com área de 78 km². Essa bacia é uma sub-bacia do rio Potiribu e possui duas bacias hidrográficas nela embutidas: a bacia do Donato (área de 1 km²), e a bacia do Turcato (área de 20 km²). Na Figura 3 é mostrada a localização da bacia do Taboão (e suas sub-bacias) no contexto brasileiro e regional.

Figura 3 – Localização da bacia hidrográfica do rio Potiribu e das sub bacias do rio Taboão, Turcato e Donato no contexto brasileiro e regional



Fonte: Autor

A bacia do Taboão localiza-se a noroeste do estado do Rio Grande do Sul, entre as municípios de Ijuí, Cruz Alta e Panambi, na posição central do derrame basáltico sul-americano. Está completamente situada dentro do município de Pejuçara (área de 414,14 km²) e possui um núcleo urbano de aproximadamente 1,8 km² (IBGE, 2010). O rio principal dessa bacia é um contribuinte do rio Potiribu que, por sua vez, é um afluente do rio Ijuí. O rio Ijuí é contribuinte da margem esquerda do rio Uruguai.

O Instituto de Pesquisas Hidráulicas da UFRGS realiza, desde 1989, o monitoramento hidrológico na bacia do rio Potiribu (CASTRO, CHEVALLIER e GOLDENFUM, 2000; CASTRO et al., 2010; GIRARDI et al., 2011). A escolha dessa bacia como alvo de monitoramento deve-se ao fato de que essa região é representativa de uma das zonas físico-climáticas homogêneas do derrame basáltico sul-rio-grandense (BORGES e BORDAS, 1988), uma região caracterizada pela intensa atividade agrícola.

O monitoramento vem sendo realizado com recursos de projetos de pesquisa do CNPq e FINEP. No início da década de 90, os projetos eram unicamente associados à bacia do Potiribu e a partir do final da década de 90, os projetos foram desenvolvidos em rede com outras universidades e monitoramento de outras bacias no RS e no Brasil. Os projetos em rede envolvidos neste monitoramento foram:

- 1997 a 2001: MCT FINEP RECOPE REHIDRO projeto "Redes Cooperativas e Pesquisas"
- 2007 a 2010: MCT/FINEP CT-HIDRO projeto "Rede de pesquisa em bacias representativas e experimentais no bioma da mata atlântica na região sul do Brasil" – MATASUL
- 2009 a 2012: MCT/FINEP/CT-HIDRO-IGRH 01/2007 - "Disponibilidade Hídrica para Aplicação dos Instrumentos de Gestão de Recursos Hídricos. Quantidade e Qualidade de Água" - INTEGRA
- 2009 a 2013: MCT/FINEP/AÇÃO TRANSVERSAL - PREVISÃO DE CLIMA E TEMPO 04/2008 Convênio 1406/08 do Projeto "Estudo de Mudanças Climáticas na Região Sul do Brasil" - CLIMASUL
- 2013 a 2015: MCT/FINEP CT-HIDRO 01/2010 - projeto "Rede de Pesquisa em Monitoramento e Modelagem de Processos Hidrossedimentológicos em Bacias Representativas Rurais e Urbanas do Bioma Mata Atlântica" - RHIMA

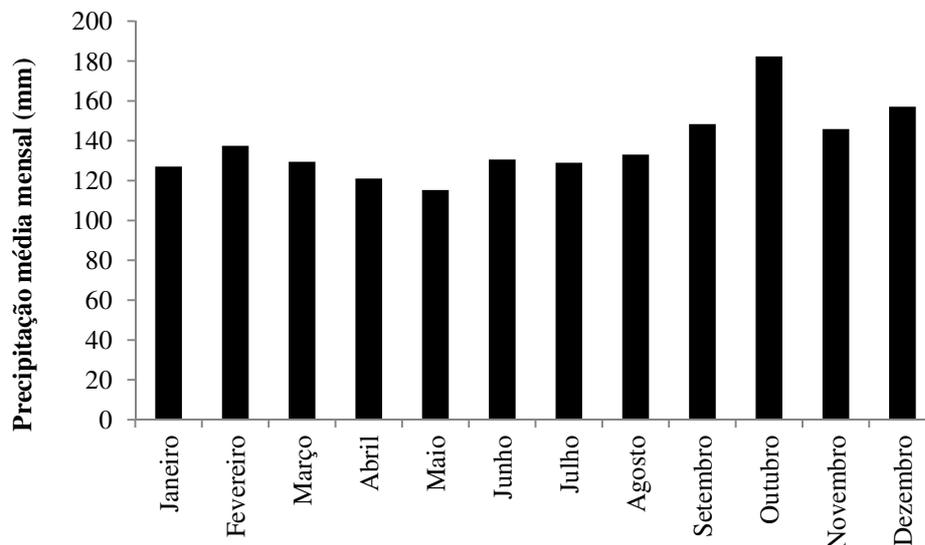
- 2014 a 2017: MCT/FINEP CT-HIDRO 01/2013 projeto "Avaliação do Aporte de Sedimentos em Reservatórios Visando Aumento da Disponibilidade Hídrica"

3.1.2 Clima da bacia

Conforme o sistema de classificação Koeppen, o clima da região é classificado como mesotérmico brando, do tipo temperado, super úmido e sem estação seca (cfa) (NIMER, 1989). As temperaturas médias mensais situam-se entre 14°C (mês de julho) e 24 °C (mês de janeiro); podendo alcançar extremos inferiores à 0°C ou superiores a 35°C. A média das temperaturas máximas é superior a 22°C, e a média das mínimas oscila entre -3 e 18°C (IPAGRO, 1989).

A precipitação média anual, calculada a partir de uma série histórica de 52 anos (1961 a 2013), monitorada na cidade de Cruz Alta (localizada a 18 km de Pejuçara, coordenadas UTM: 238553 m E e 6833021 m N, Fuso 22J), é igual a 1700 mm; com médias mensais variando entre 115 e 182 mm. As chuvas são bem distribuídas ao longo do ano, com ausência de mês sem chuva (Figura 4).

Figura 4 - Precipitação média mensal - Estação climatológica de Cruz Alta - INMET período 1961 a 2013.



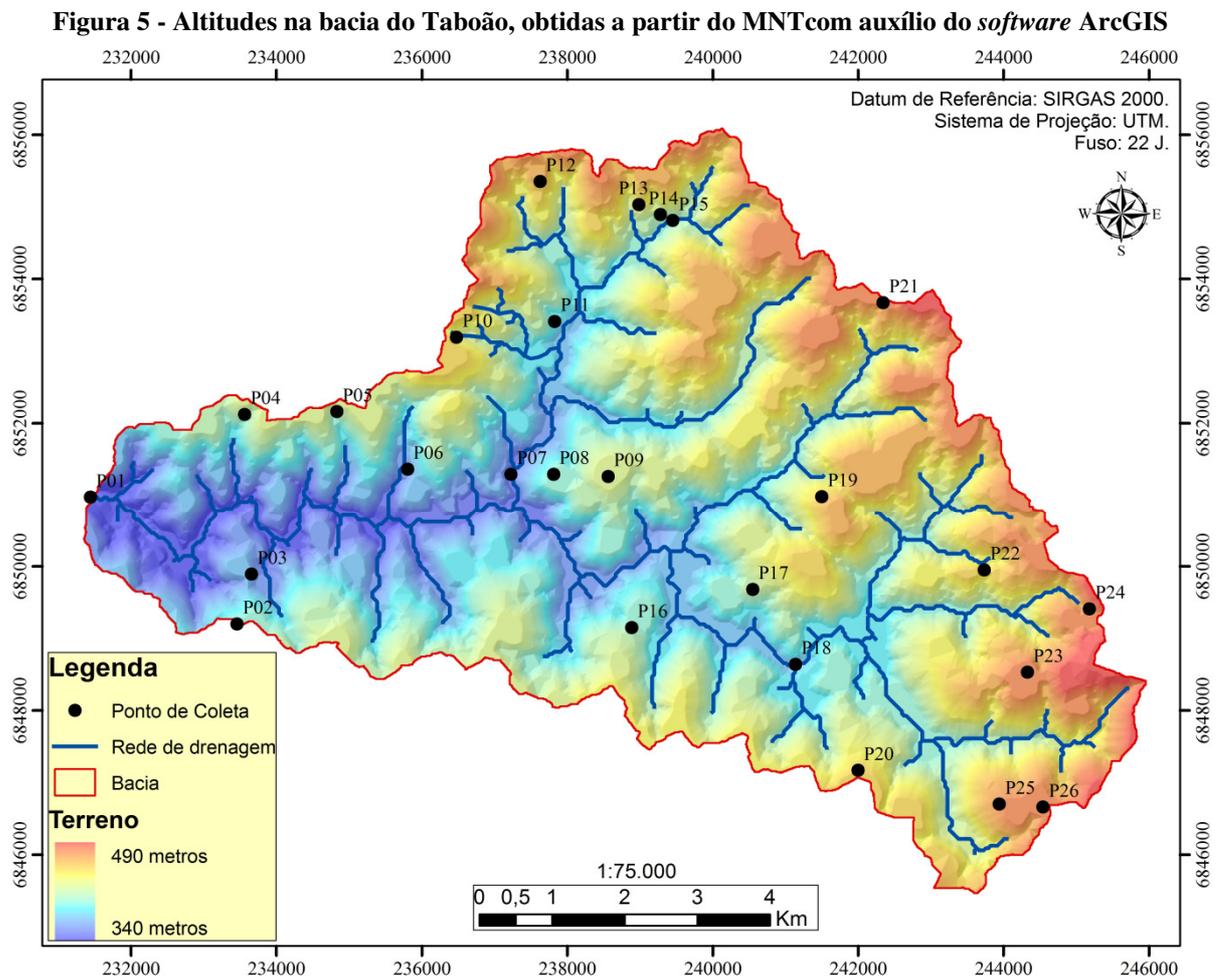
Fonte: autor

A precipitação diária de frequência anual é igual a 88,9 mm, enquanto que a de frequência decenal é igual a 130,5 mm; considerando uma série histórica de um posto localizado em Cruz Alta (coordenadas UTM: 246170 m E e 6826670 m N, Fuso 22J) para o

período compreendido entre 1934 e 1985 (CHEVALLIER e CASTRO, 1991). Entretanto, a região pode ser afetada pela ocorrência de chuvas extremas, sobretudo pela influência do *El Niño*, que ocasiona o aumento das chuvas na região sul do Brasil ou ainda, da *La Niña*, responsável por secas nessa mesma região.

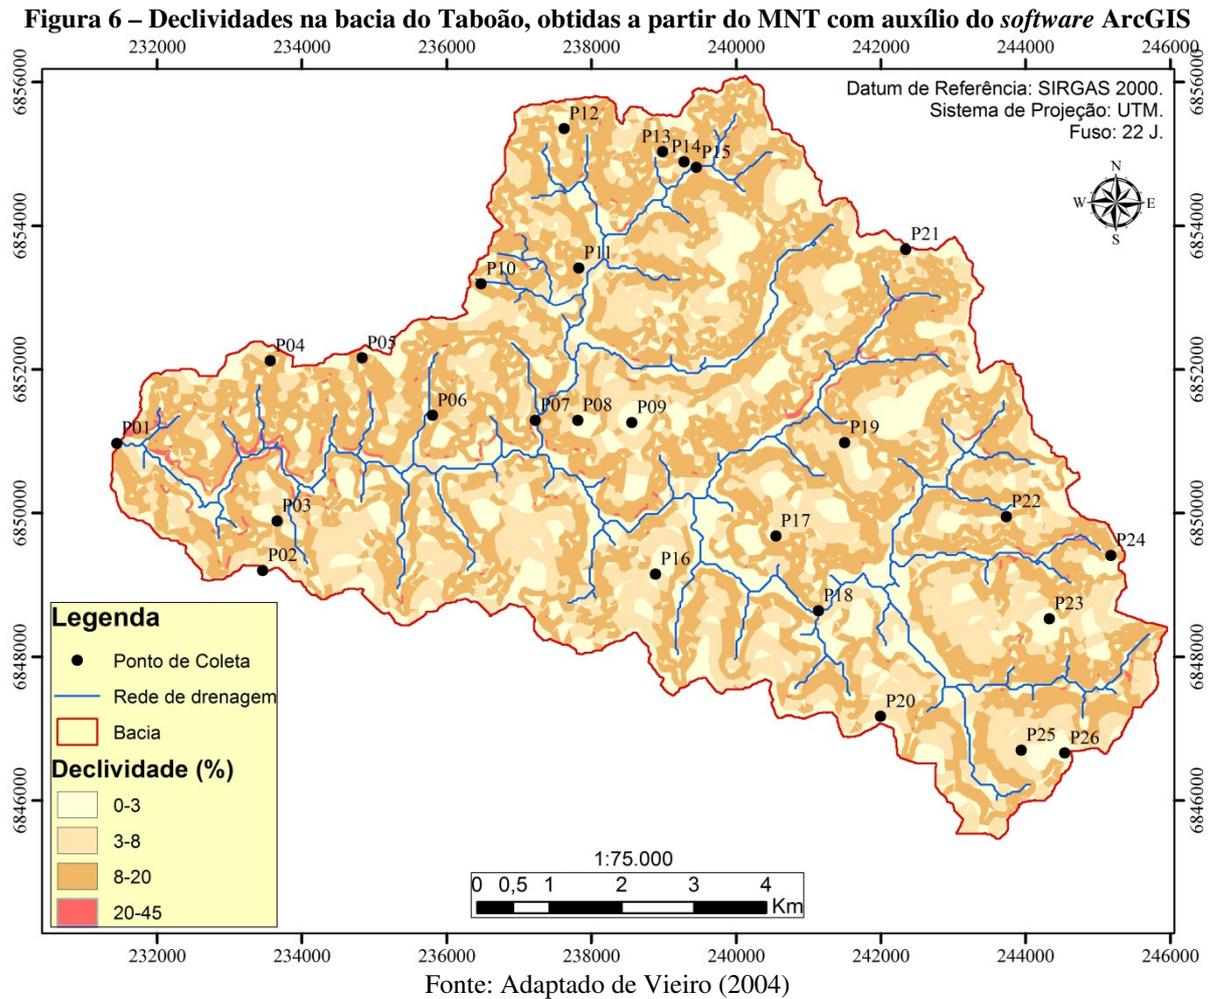
3.1.3 Relevo da bacia

O relevo da bacia do rio Taboão é caracterizado como suave ondulado, regionalmente conhecido por coxilhas, com altitudes variando aproximadamente entre 340 e 490 m ao nível do mar. Na Figura 5 são mostradas as altitudes e a rede hidrográfica da bacia do Taboão, obtidas através de reconstituição de carta topográfica Folha SH.22-V-A-I-3, da Divisão de Serviços Geográficos do Exército e fotografias aéreas na escala 1:50.000, com curvas de níveis equidistantes 4 m. O modelo numérico do terreno (MNT) foi recortado, com o auxílio do *software* ArcGIS, resultando em uma mapa de relevo da área da bacia.



Fonte: Adaptado de Vieiro (2004)

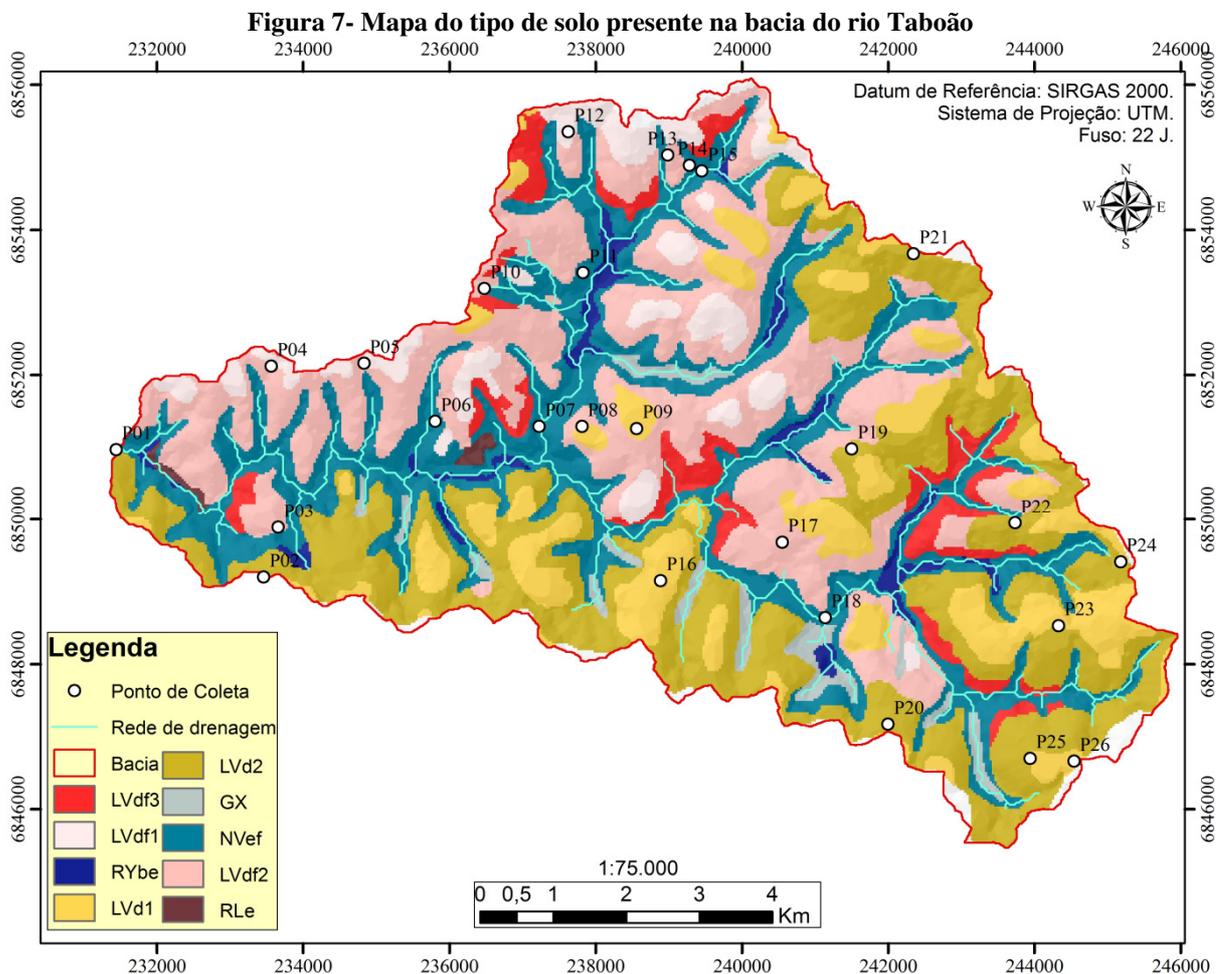
Na Figura 6 são apresentadas as declividades na bacia do Taboão. A declividade média na bacia é de 8%, embora varie entre 10 e 20% na região de vales. Além disso, nas áreas mais declivosas da bacia (vales entalhados na rocha, especialmente na região sudoeste), as vertentes podem apresentar declividades em torno de 30%, chegando a atingir 45% em alguns pontos (VIEIRO, 2004).



3.1.4 Geologia e tipo de solo

A bacia do Taboão está situada sobre o derrame basáltico sul-americano, que possui uma área de 230.000 km² (BORGES e BORDAS, 1988). Carvalho et al. (1990) identificaram seis unidades de mapeamento no levantamento de solos da região, das quais predominam, conforme classificação atualizada EMBRAPA (2006): Neossolo Flúvico Tb Eutrófico (RYbe), Neossolo Litólico Eutrófico (RLe), Latossolo Vermelho Distrófico (LVd), Latossolo Vermelho Distroférico (LVdf), Nitossolo Vermelho Eutroférico (NVef) e Gleissolo Háptico (GX).

A distribuição dos solos na bacia é apresentada na Figura 7. Esse mapa é uma adaptação daquele construído por Carvalho et al. (1990), que realizaram o levantamento dos solos presentes na bacia e a identificação das unidades de mapeamento. Essas unidades de mapeamento são resultantes do enquadramento das unidades definidas, originalmente, em conformidade com o Sistema Brasileiro Classificação de Solos (EMBRAPA,1999). O enquadramento foi realizado tendo por base os perfis de solo que descrevem cada unidade de mapeamento, sendo os perfis representados pela descrição morfológica e dados físicos e químicos dos horizontes. Uma atualização dessa classificação foi realizada por Vieiro (2004). O mapa atual de classificação do solo da bacia do Taboão foi atualizado para a nova classificação dos solos (EMBRAPA, 2006).



Neossolo Flúvico Tb Eutrófico (RYbe), Neossolo Litólico Eutrófico (RLe), Latossolo Vermelho Distrófico subclasse 1 (LVd1), Latossolo Vermelho Distrófico subclasse 2 (LVd2), Latossolo Vermelho Distroférico subclasse 1 (LVdf1), Latossolo Vermelho Distroférico subclasse 2 (LVdf2), Latossolo Vermelho Distroférico subclasse 3 (LVdf3), Nitossolo Vermelho Eutroférico (NVef) e Gleissolo Háptico (GX).

Fonte: Adaptado de Carvalho et al., 1990 e Vieiro, 2004

Os solos predominantes são os Latossolos vermelhos (71,49% da área da bacia), caracterizados por grande profundidade e quantidade de argila. A alta atividade dos argilominerais presentes nesse solo forma estruturas de micro agregados, que confere ao solo bom armazenamento de água (característica da argila), e alta taxa de infiltração, sendo conhecidos como falsas areias. A profundidade desse solo pode atingir até mais de uma dezena de metros, caracterizando-se por boa drenagem. Essa característica torna esses solos bons para a agricultura, tanto para culturas de inverno como de verão; desde que corrigida a fertilidade química (CASTRO, 1996).

Observa-se ainda a presença de Neossolos (2,76%), Nitossolos (23,45%) e Gleissolo Háplico (2,29%). Os Nitossolos, assim como os Latossolos, são solos profundos diferindo desse último por apresentarem um horizonte B com uma estrutura mais desenvolvida e caracterizada por revestimento brilhante (cerosidade). O Neossolo é um solo pouco desenvolvido e normalmente raso. Por outro lado, nas áreas de depressões (baixa declividade) encontra-se o Gleissolo, com características de coloração acinzentada ou escura, pouca profundidade e má drenagem.

3.1.5 Uso e manejo do solo

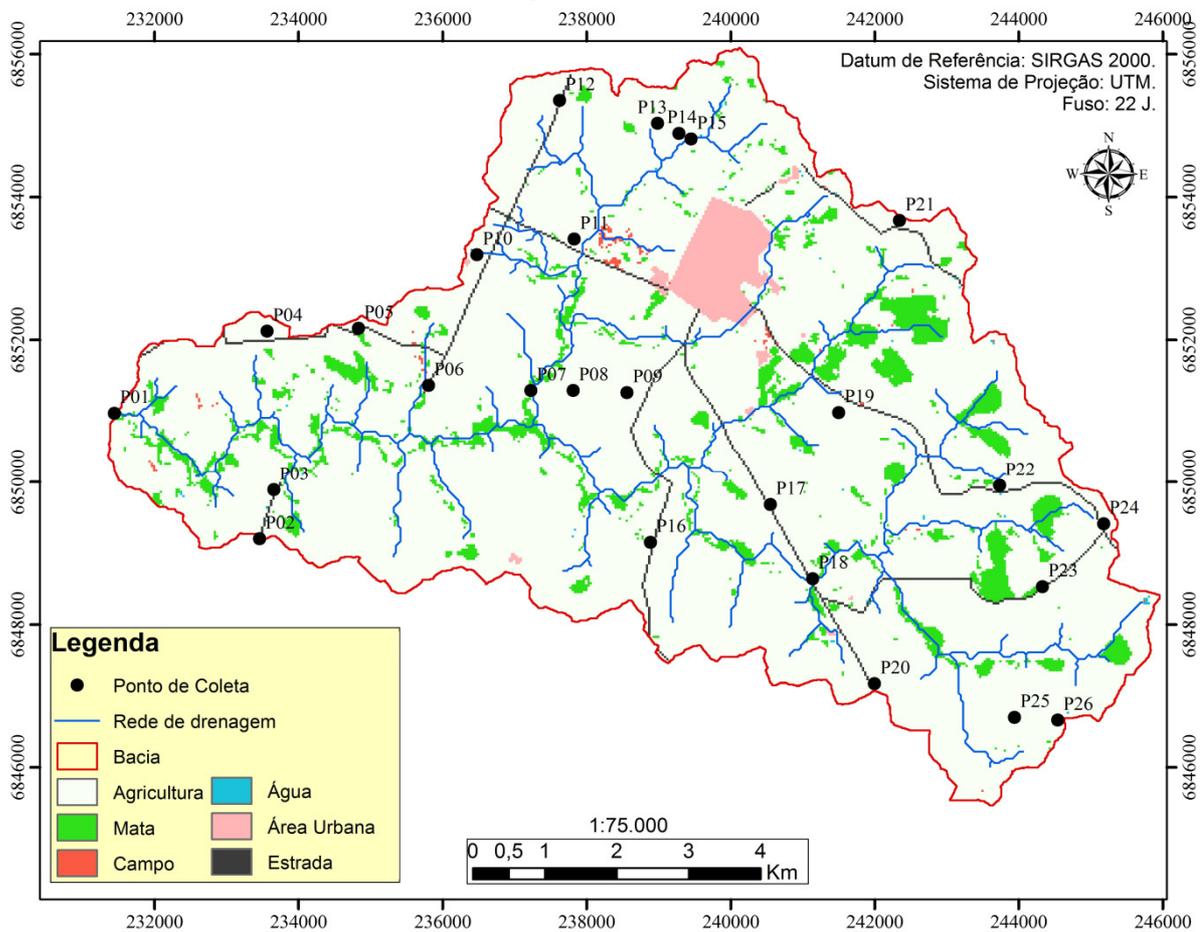
A bacia do Taboão possui 88,47% de sua área ocupada por cultivo agrícola, sendo a soja e o milho os cultivos mais comuns no período do verão, e o trigo e a aveia no inverno (MEDEIROS, 2004; OLIVEIRA, 2006). A utilização do solo para pastagens é pouco expressiva (VIEIRO, 2004).

Na Figura 8 apresenta-se o mapa de uso do solo na bacia do Taboão. Esse mapa foi construído, a partir de uma imagem LANDSAT TM (índice WRS 223/80 de 26 de janeiro de 2005), com resolução espacial de 10 metros, em quatro bandas espectrais; empregando a técnica de Classificação Supervisionada, realizada com auxílio do *software* Idrisi Andes[®].

Até o início da década de 90, o preparo do solo era na modalidade convencional, com plantio baseado em curvas de nível e terraceamento agrícola, e revolvimento da camada superficial do solo por meio de arado e grade niveladora. Eventualmente era usado subsolagem em profundidades maiores para descompactar o solo. No ano de 1994, o plantio direto foi adotado pela maioria dos agricultores, visando diminuir o impacto da agricultura e das máquinas agrícolas (tratores, arados, etc.) sobre o solo. Essa técnica tem como principal característica o não revolvimento do solo e a manutenção dos restos da cultura anterior sobre a superfície do solo, no intervalo entre culturas (CASTRO, 1996).

As áreas de vegetação nativa estão presentes na forma de fragmentos de mata ciliar ou em manchas isoladas com área máxima de 1 km² (GIRARDI et al., 2011). Essas florestas compõem 7,51% da área da bacia. Já os campos são encontrados em 0,18% da área da bacia, enquanto que as águas superficiais compõem 0,06% dessa área, a área urbana de alta densidade ocupa 2,21% da bacia, e a malha viária está presente em 1,42% da área. São também encontradas áreas residenciais de menor densidade; formadas, sobretudo por benfeitorias e casas localizadas nas regiões rurais da bacia (0,15% da área total da bacia).

Figura 8- Mapa de uso do solo da bacia do Taboão, elaborado a partir de uma imagem LANDSAT TM de 26 de janeiro de 2005



Fonte: autor

4 MATERIAIS E MÉTODOS

Para efeitos desta pesquisa, o teor de água no solo foi estimado através da umidade gravimétrica do solo.

4.1 Dados de entrada e de saída dos modelos com RNAs

Neste item são descritos os métodos que foram utilizados para a obtenção dos dados usados como variáveis de entrada e de saída (teor de água no solo), dos modelos de RNAs desenvolvidos, bem como os detalhes da construção de tais modelos.

Foram realizadas análises estatísticas descritivas (média, máximo, mínimo, e desvio padrão) para todas as variáveis de entrada do modelo RNA e também para os valores do teor de água no solo medidos nos diferentes pontos de coleta.

4.1.1 Dados de entrada e de saída dos modelos RNAs

Inicialmente, foram consideradas como entradas dos modelos RNAs informações pluviométricas, dados climatológicos (temperatura do ar máxima e temperatura do ar mínima, radiação solar global, velocidade do vento, umidade relativa do ar, pressão atmosférica e evapotranspiração de referência, e temperatura de relva), informações topográficas da bacia (altitude, proximidade do rio, desnível entre o ponto de coleta e o trecho do rio mais próximo, e declividade), e propriedades físicas do solo (densidade, granulometria, , resistência à penetração no solo, tensão da água no solo).

Para treinamento e validação da rede, e para o cálculo do desempenho da série de teste utilizaram-se dados de teor de água no solo (umidade gravimétrica).

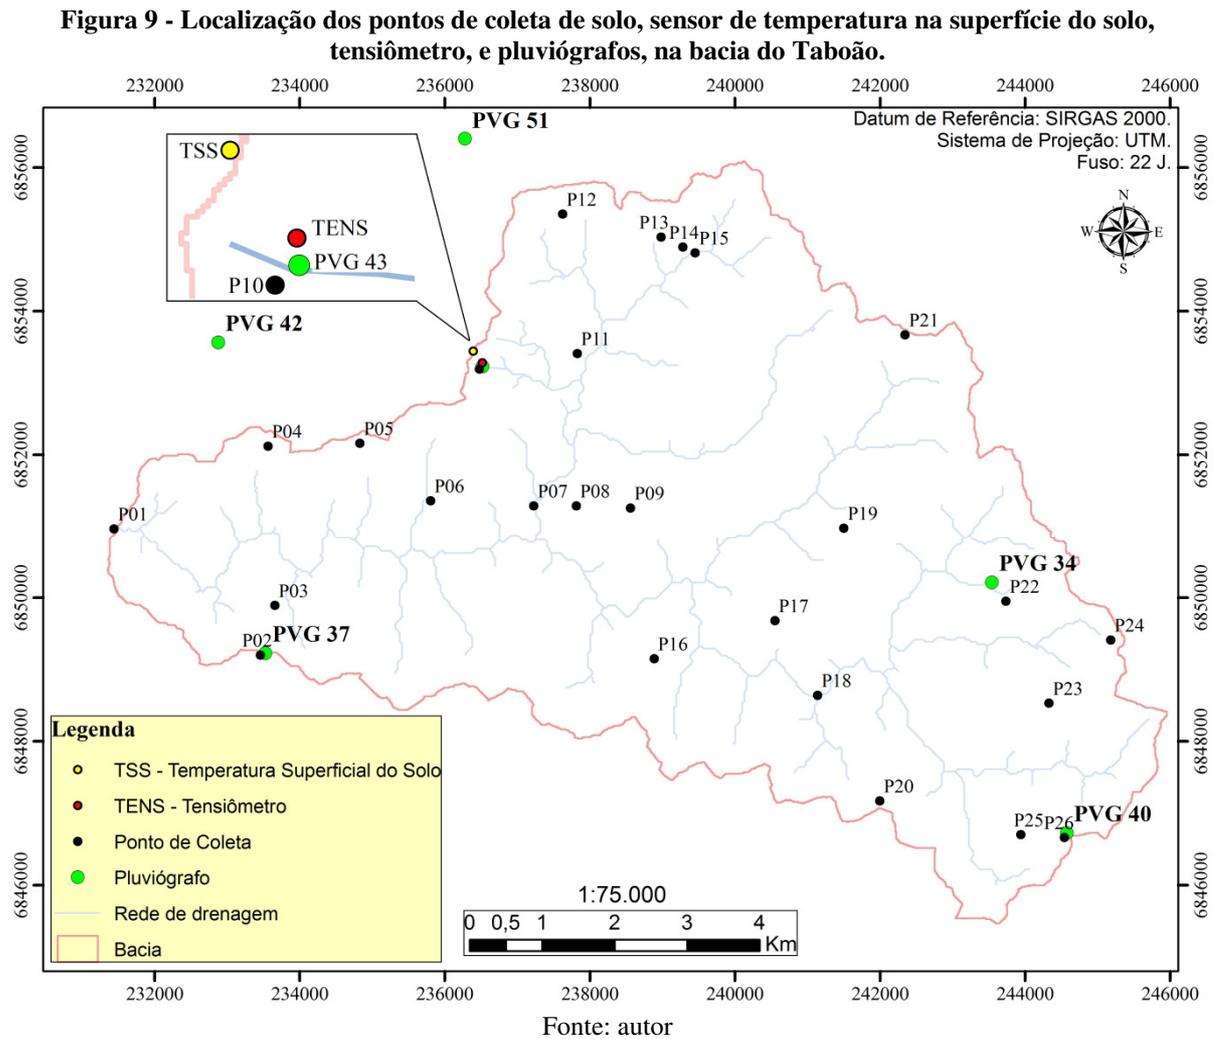
A seguir apresenta-se, detalhadamente, a metodologia desenvolvida para aquisição dessas informações.

4.1.1.1 Coleta de amostras de solo e análises em laboratório

As coletas de solo foram realizadas em 24 datas (ou 25 momentos de coleta, pois em um dos dias as coletas foram realizadas pela parte da manhã e tarde), no período compreendido entre 15 de janeiro e 10 de agosto de 2013, para determinação das propriedades

físicas do solo (densidade e granulometria) e da umidade gravimétrica. Foram determinados 26 pontos de coleta na bacia, distribuídos ao longo dos diferentes tipos de solo e altitudes.

Na Figura 9 é ilustrada a localização dos 26 pontos de coleta de solo na bacia do Taboão, e na Tabela 1 são apresentadas as informações de cada um dos pontos coletados (nome do ponto de coleta, coordenadas de localização do ponto, altitude e tipo de solo).



As amostras de solo foram coletadas na superfície do perfil do solo (entre 5 e 15 cm de profundidade), em triplicata, sendo eliminada a vegetação e os restos culturais presentes nessa superfície. Foram realizadas quatro coletas espaçadas de 24 horas em cada mês (15, 16, 17 e 18 de janeiro; 19, 20, 21, 22 de fevereiro; 20, 21, 22, 23 de março; 1, 2, 3 e 4 de maio; 5, 6 (pela manhã e a tarde), 7 e 8 de junho; 7, 8, 9 e 10 de agosto), totalizando 25 coletas em 24 datas (06/06: coletas realizadas em 2 momentos - manhã e tarde). As amostras foram armazenadas em latas de alumínio com tampas sendo, posteriormente, envolvidas em plástico

filme para evitar a ocorrência da evaporação da água. As latas foram identificadas, anotando-se o local, o dia e horário de cada coleta.

Tabela 1 - Informações dos pontos de coleta na bacia do Taboão (nome do ponto de coleta, coordenadas de localização do ponto, altitude e tipo de solo)

Ponto	Coordenadas - WGS84		Altitude (m)	Tipo de Solo
	(Fuso: 22S)			
	E (m)	N (m)		
P01	231443	6850970	351	NVef
P02	233460	6849200	410	LVd2
P03	233658	6849890	382	LVdf2
P04	233565	6852120	419	LVdf2
P05	234832	6852160	429	LVdf1
P06	235805	6851360	396	NVef
P07	237228	6851290	378	NVef
P08	237814	6851290	397	LVd1
P09	238562	6851260	435	LVd1
P10	236478	6853190	433	LVdf2
P11	237828	6853410	389	NVef
P12	237627	6855350	455	LVdf1
P13	238985	6855030	448	LVdf2
P14	239283	6854890	427	NVef
P15	239453	6854810	417	NVef
P16	238888	6849150	411	LVd1
P17	240552	6849680	415	LVdf2
P18	241141	6848640	402	NVef
P19	241502	6850980	452	LVd2
P20	241999	6847170	457	LVd2
P21	242346	6853670	477	LVd2
P22	243736	6849950	446	LVd2
P23	244331	6848530	474	LVd1
P24	245181	6849410	483	LVd1
P25	243943	6846700	470	LVd1
P26	244543	6846660	483	LVd1

Todas as amostras foram levadas para o laboratório de sedimentos do IPH onde foram pesadas úmidas e então secas em estufa a 105°C. Após a secagem as amostras foram pesadas novamente para obtenção do peso seco. A umidade gravimétrica foi calculada pela equação 1, descrita no item 2.1.1.

O valor da mediana das coletas em triplicata foi utilizado para treinamento e validação da rede, evitando assim possíveis erros gerados pela existência de valores extremos. Essa

mesma metodologia foi empregada por Castro (1996). Os dados de teor de água no solo foram utilizados como variáveis de saída do modelo para o treinamento e validação da RNA, e para o cálculo das estatísticas do desempenho do modelo na série de verificação.

Na entrada do modelo foram consideradas as seguintes características físicas do solo: densidade do solo, granulometria e resistência à penetração no solo.

A densidade foi determinada pela relação entre a massa de solo seco e o volume da amostra. Para isso, foram realizadas coletas de solo indeformado em cada um dos 26 pontos monitorados, também em triplicata, sendo a densidade de cada ponto obtida pela mediana das triplicatas. Essas coletas foram realizadas nos dias 8 e 9 de agosto de 2013.

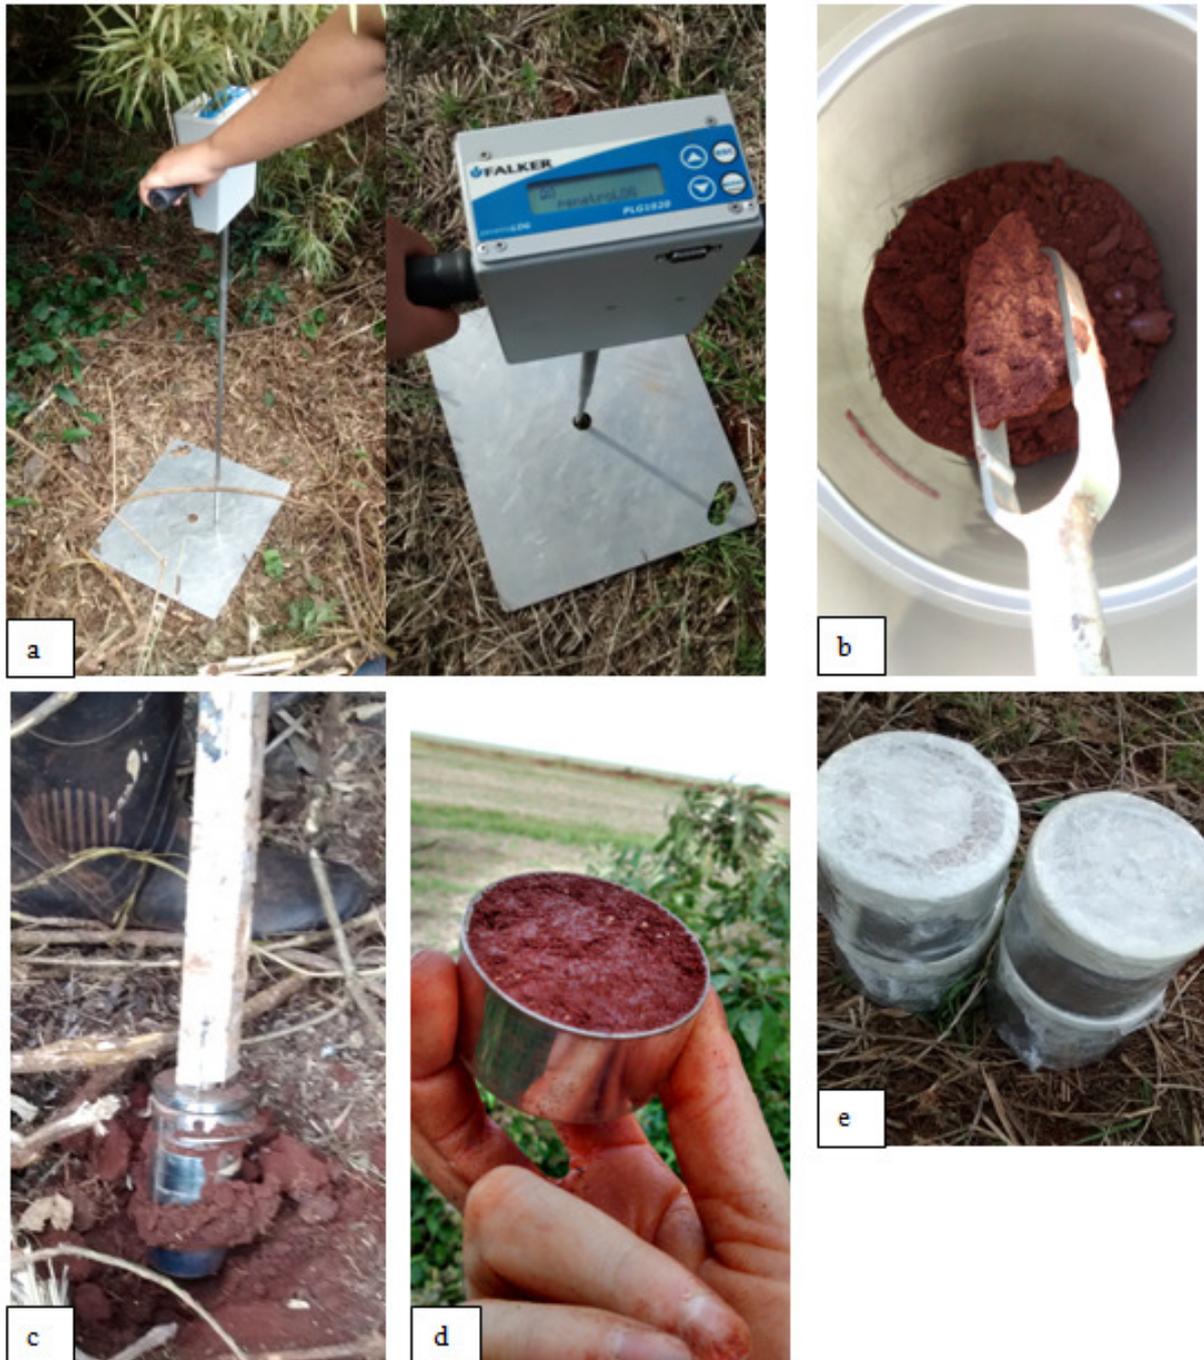
A resistência à penetração foi determinada para as camadas de 0 a 20 cm e 20 a 40 cm. Tais medições foram realizadas utilizando o equipamento PenetroLOG (Medidor Eletrônico de Compactação do Solo), Falker Automação Agrícola Ltda, da Faculdade de Agronomia da UFRGS. O penetroLOG faz medições em camadas de até 60 cm de profundidade, possibilitando a identificação das condições físicas do solo (pressão correspondente à compactação do solo na camada), em várias profundidades, nos pontos escolhidos. Essas medições foram realizadas no período compreendido entre 28 de abril a 03 de maio de 2014.

Na Figura 10 são ilustrados os procedimentos de coleta de solo e verificações da resistência à penetração no solo.

A granulometria do solo em cada um dos pontos foi obtida em laboratório pelos métodos de peneiramento e pipetagem (CAUDURO et al., 19??). Para isso, foram realizadas coletas, em triplicata, de amostras de solo deformado em cada um dos pontos monitorados. Essas coletas de solo foram realizadas no mesmo período em que foram executadas as medições de resistência à penetração no solo.

O material coletado passou, primeiramente, pelo processo de queima da matéria orgânica com peróxido de hidrogênio. Após esse procedimento, o solo foi macerado em um primeiro processo de desagregação mecânica e passado por peneiramento. O material menor que 0,0063 mm passou então, por um segundo processo de desagregação mecânica, através de agitação mecânica (mais de 12 horas), e desagregação química com adição na amostra de hexametáfosfato de sódio ($\text{Na}_6[(\text{PO}_3)_6]$) e carbonato de sódio (Na_2CO_2) para compor a solução desagregante (calgon). Após esse procedimento, o material foi encaminhado para pipetagem.

Figura 10 – Procedimentos de a) verificação da resistência à penetração no solo, b) coleta de amostras deformadas de solo, c) coleta de amostras indeformadas de solo, d) amostra de solo indeformada coletada, e e) amostra de solo indeformada acondicionadas em latas para transporte



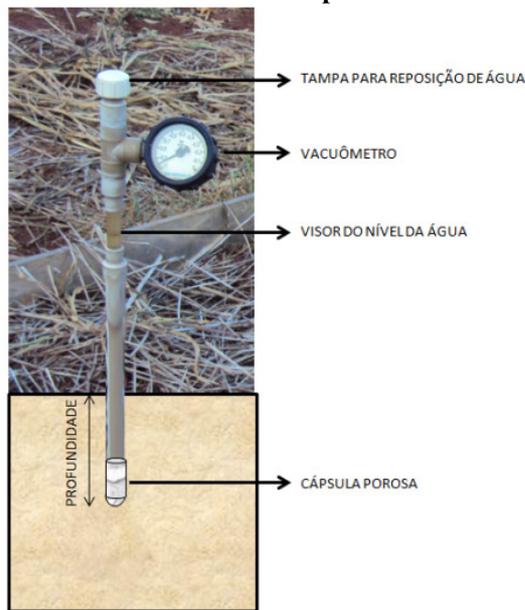
Fonte: autor

4.1.1.2 Tensão da água no solo

A tensão da água no solo (em bar) foi utilizada como entrada da RNA. Seu monitoramento foi realizado diariamente por um observador, ao longo do período dessa

pesquisa. O tensiômetro utilizado está instalado a uma profundidade de 10 cm da superfície do solo (Figura 11), na sub-bacia do Donato (Figura 9).

Figura 11 - Tensiômetro instalado na bacia do Taboão para monitoramento da tensão da água no solo



Fonte: autor

Os dados desse tensiômetro foram comparados com um segundo tensiômetro instalado próximo desse. Em caso de dados duvidosos do primeiro tensiômetro, utilizou-se informações do segundo. O valor máximo registrado da tensão da água no solo foi igual a 0,83 bar e o mínimo foi de 0,06 bar, com média de $0,26 \pm 0,23$ bar, e mediana de 0,14 bar.

4.1.1.3 Informações meteorológicas

As informações meteorológicas utilizadas como entrada da RNA compreendem dados pluviométricos (monitorados na bacia) e registros climáticos (temperatura do ar máxima e temperatura do ar mínima, umidade relativa do ar, pressão atmosférica, radiação solar e velocidade do vento) fornecidos pelo Instituto Nacional de Meteorologia (INMET). Além disso, utilizaram-se também dados de evapotranspiração.

4.1.1.4 Temperatura do ar, umidade relativa do ar, pressão atmosférica, radiação solar global e velocidade do vento

Os valores de temperatura do ar máxima, temperatura do ar mínima, umidade relativa do ar máxima, umidade relativa do ar mínima, pressão atmosférica, radiação solar global e velocidade do vento foram monitorados na estação meteorológica localizada na cidade de Cruz Alta (coordenadas UTM: 238553 mE e 6833021 mS, Fuso 22J), situada a uma distância aproximada de 18 km do centro da bacia do Taboão. Os dados utilizados estão relacionados aos 24 dias (ou 25 momentos) em que foram realizadas coletas de amostras de solo. A Tabela 2 apresenta o resumo das estatísticas descritivas desses parâmetros.

Tabela 2 - Resumo das estatísticas descritivas dos parâmetros climáticos utilizados como entrada da RNA, considerando dados da estação INMET Cruz Alta no período de 15/01 a 10/08/13

Parâmetros	Mínima – Máxima	Média	Mediana	Desvio Padrão
Temperatura na relva (°C)	12,00 - 31,60	18,51	18,70	4,17
Temperatura do ar máxima (°C)	6,70 - 30,90	22,99	23,60	4,89
Temperatura do ar mínima (°C)	4,90 - 28,80	16,31	15,40	7,18
Umidade relativa do ar máxima (%)	78,20 - 97,00	91,44	94,00	5,63
Umidade relativa do ar mínima (%)	35,00 - 92,00	64,92	67,00	19,18
Pressão atmosférica média (hPa)	958,15 - 972,79	965,75	965,93	3,06
Radiação solar global (kJ/m ² /dia)	9744,66 - 45311,81	21257,93	17555,12	9115,31
Velocidade do vento média (m/s)	0,10 - 6,50	2,58	2,65	1,51
Evapotranspiração de referência calculada (mm)	0,90 - 8,00	3,71	3,40	1,80

A evapotranspiração de referência foi calculada com auxílio do *software* Sistema para Manejo da Agricultura Irrigada - SMAI (MARIANO, SANTOS e HERNANDEZ, 2011), através da equação de Penman-Monteith (ALLEN et al., 1998), utilizando as variáveis climáticas registradas na estação climatológica do INMET.

4.1.1.5 Precipitação

Os dados de chuva foram coletados em seis pluviógrafos (tipo báscula) instalados na bacia, sendo quatro deles da empresa Agrosystem e dois da Waterlog. Cada báscula armazena 0,2 mm de chuva e é realizada uma contagem através de um *logger* (empresa Novus para aqueles da empresa Agrosystem e Hoboware para a Waterlog), que registra a chuva a cada 10 minutos.

O método dos Polígonos de Thiessen (THIESSEN, 1911) foi utilizado para a delimitação da área de influência de cada pluviógrafo e para determinar quais pontos de coleta de solo compreendiam cada polígono. Dessa forma, determinou-se qual pluviógrafo seria utilizado para cada ponto de coleta de solo. Quando o ponto se localizava exatamente entre dois polígonos, os dois pluviógrafos correspondentes às áreas delimitadas pelos polígonos foram utilizados. Foram testadas as seguintes variáveis de chuva, em função dos dados de chuva no modelo:

1. conjunto de dados de chuva horária: (Chuva de 1 hora antes da coleta; chuva de 2 horas; chuva de 3 horas; chuva de 4 horas; chuva de 5 horas; chuva de 6 horas; chuva de 12 horas);
2. conjunto de dados de chuva diária: chuva de 1 dia antes da coleta; chuva de 2 dias; chuva de 3 dias; chuva de 5 dias; chuva de 10 dias; chuva de 15 dias; chuva de 20 dias; chuva de 25 dias; chuva de 30 dias;
3. média móvel das chuvas horárias passadas com ponderação exponencial;
4. média móvel das chuvas diárias passadas com ponderação exponencial.

A chuva utilizada foi diferente para cada ponto de coleta de solo, pois a chuva foi sempre em relação ao horário de coleta de cada ponto considerado e como a bacia tem 78 km^2 , a coleta de solo era realizada sempre no mesmo dia, mas em horários diferentes. Além de considerarmos como variáveis de entrada a chuva em várias alternativas de horas e de dias (itens 1 e 2), considerou-se também a média móvel das chuvas, tanto horárias como diárias passadas com ponderação exponencial (itens 3 e 4), de maneira que os valores da chuvas mais recentes tenham um peso maior que os valores de chuvas mais antigos. Esse procedimento foi o mesmo utilizado em Oliveira et al. (2011), com um ótimo resultado para a bacia do rio Ijuí ($NS = 0,95$), sendo que a bacia do Taboão é uma sub-bacia daquela. Os autores identificaram que essa média móvel, quando aplicada como variável de entrada, resultou em uma melhor eficiência no modelo, comparativamente às chuvas.

a) Média móvel das chuvas passadas horária e diária com ponderação exponencial

Uma vez que se deseja obter uma soma ponderada exponencialmente de totais de chuva em intervalos que nem sempre são uniformes, é preciso trabalhar com os pesos resultantes (equação 10), em vez de utilizar a equação recursiva tradicional (7).

Para intervalos contínuos de tempo, a equação 7 é suficiente. Porém, quando se tem uma sequência de chuvas até certo número de intervalos, seguida da chuva acumulada alguns intervalos depois, é preciso adotar critérios. Nesse caso, o critério foi considerar o peso para as chuvas nos intervalos descontínuos como sendo a soma dos pesos que teriam ocorrido até as horas existentes se os intervalos tivessem sido contínuos. Por exemplo, considere-se chuvas horárias até seis horas antecedentes, e depois as chuvas de seis horas até às 12 horas antecedentes. Nesse caso, obtêm-se os pesos correspondentes até 12 horas de antecedência com a equação 10. Adotam-se os pesos obtidos até às seis horas para os respectivos valores das chuvas, e a soma dos pesos das sete horas até às 12 horas para a chuva da hora 12, que corresponde à chuva entre seis e 12 horas. Numericamente, para a meia-vida de 1 intervalo horário:

Pesos calculados = 0,5000; 0,2500; 0,1250; 0,0625; 0,0313; 0,0156; 0,0078; 0,0039; 0,0020; 0,0010; 0,0005; 0,0002; 0,0001.

Se os dados estão configurados para até seis intervalos anteriores de forma contínua, e o próximo, 12 intervalos anteriores, então, adotam-se os pesos: 0,5000; 0,2500; 0,1250; 0,0625; 0,0313; 0,0156; e 0,0154.

É fácil expandir o critério para incorporar as chuvas acumuladas de 18 e de 24 intervalos anteriores, se for o caso, para esse exemplo.

Nessa pesquisa, trabalhou-se com dois níveis de médias móveis ponderadas exponencialmente de chuvas passadas: i) com intervalos horários, incorporando as chuvas continuamente até seis horas de antecedência e também as chuvas de seis a 12 horas de antecedência; e ii) com intervalos diários, considerando as chuvas com 1, 2 e 3 dias de antecedência.

Tanto para a primeira como para a segunda variáveis, respectivamente, a média móvel ponderada exponencialmente das chuvas horárias passadas e a média móvel ponderada exponencialmente das chuvas diárias passadas, testou-se um valor preliminar para a meia-vida, experimentando-se valores, por tentativas sistemáticas, e calculando-se as correlações com os teores de umidade. Depois, durante o treinamento dos modelos, estes valores são questionados, com a experimentação de outros em seu entorno, para o “ajuste fino” requerido, buscando-se as meias-vidas respectivas que resultam melhor desempenho dos modelos.

4.1.1.6 Características topográficas da bacia

As variáveis de entrada no modelo, relacionadas com a topografia da bacia foram: a altitude, a declividade, a distância do ponto de coleta ao trecho mais próximo do rio e o desnível do ponto ao trecho mais próximo do rio.

Essas variáveis foram extraídas do Modelo Numérico de Terreno (MNT) com resolução de 90 metros, com auxílio da ferramenta *ArcToolbox* do software ARCGIS (ESRI®). Inicialmente, os pontos coletados e suas coordenadas geográficas foram plotados, e a partir da função *Add Surface Information* (em *Functional Surface*) a altitude (Z) do MNT foi adicionada a cada ponto de coleta. Com a ferramenta *Slope* (em *Raster Surface*) calculou-se a declividade no ponto.

A distância do ponto de coleta até o trecho da rede de drenagem mais próxima foi definida através da ferramenta *Near* (*ArcToolbox>Analysis Tools>Proximity>Near*). Essa ferramenta permite encontrar o caminho mais próximo em linha reta. Uma vez encontrada a extremidade da distância do ponto de coleta até a rede de drenagem determinou-se o desnível entre esses pontos (diferença das cotas do ponto considerado e do ponto mais próximo à rede de drenagem).

4.2 Modelos com RNAs

Os programas para a especificação, o treinamento, as simulações, a avaliação de desempenho e a interpretação das RNA foram desenvolvidos no ambiente do software MATLAB® 7.12.0, R2010a. O tipo de RNA utilizado nesse estudo foi a rede de múltiplas camadas, com treinamento pelo algoritmo retropropagativo, com taxa de aprendizado heurísticamente variável e aplicação de validação cruzada. Foi empregada apenas uma camada interna na rede neural, sendo o número de neurônios inicialmente testado pela regra $2n+1$, onde n é o número de variáveis de entrada conforme abordado no item 2.3.1 (HECHT-NIELSEN, 1990). Partiu-se deste número de neurônios e testou-se para cada modelo, vários números de neurônios, sendo escolhido após os testes, o número de 25 neurônios.

Para o escalonamento linear dos dados foi realizada uma investigação dos valores máximos e mínimos das entradas e saídas, de forma a escolher os limites inferiores e superiores do domínio, buscando deixar uma “folga” entre os limites escolhidos e os valores dos extremos, para prevenir derivadas muito pequenas nos extremos, e permitir pequenas extrapolações futuras. Posteriormente foi realizada a separação das amostras, com 50% dos

dados utilizados para o treinamento, 25% para a validação e 25% para a verificação, buscando selecionar o período que possuía os valores extremos para a série de treinamento.

Foi realizado o treinamento da rede neural com a utilização de uma rotina própria para o algoritmo retropropagativo, sendo especificados o número de neurônios, o número de iterações (repetições do treinamento) e o número de ciclos. A rede neural foi treinada 16 vezes, escolhendo-se o melhor modelo no treinamento, com o objetivo de minimizar os efeitos causados pela aleatoriedade das condições iniciais.

Após o treinamento, o modelo completo é aplicado à série de verificação, resultando em valores, na escala original, da variável de saída. A comparação desses resultados com os valores observados, por inspeção visual e pela aplicação de estatísticas de desempenho, permite avaliar a qualidade do modelo. Como estatística de desempenho foram utilizados erros característicos (erro médio absoluto e quantil 0,95 correspondente), e o parâmetro Nash-Sutcliffe (NS), calculado também em função dos erros.

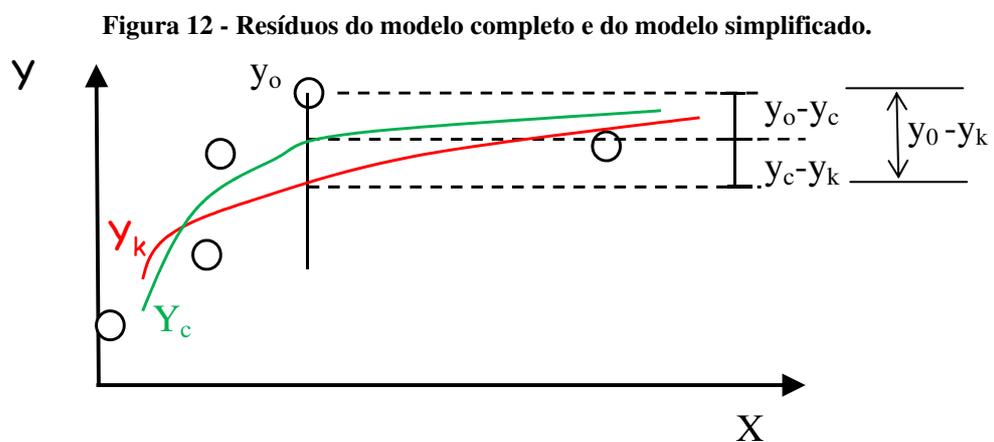
Diversas variáveis de entrada foram testadas para o modelo. No total foram 40 variáveis, sendo quatro referentes à topografia (altitude, declividade, distância do ponto ao trecho do rio mais próximo e desnível do ponto ao trecho mais próximo do rio); oito relacionadas ao solo (tipo de solo, densidade do solo, resistência à penetração no solo para as camadas de 0 a 20 cm e 20 a 40 cm, tensão da água no solo, % argila, % silte, % areia), dez relativas ao clima (clima, evapotranspiração de referência, temperatura do ar máxima e temperatura do ar mínima, umidade relativa do ar máxima e umidade relativa do ar mínima, pressão atmosférica, radiação solar global, intensidade do vento e temperatura na relva), e 18 de chuva (chuva de 1, 2, 3, 4, 5, 6 e 12h; chuva de 1, 2, 3, 5, 10, 15, 20, 25 e 30 dias; chuva média ponderada horária; chuva média ponderada diária).

Foi realizada uma rotina no modelo para permitir a desacumulação das chuvas. Assim, quando era selecionada a chuva de 1, 5 e 30 dias, por exemplo, era possível, ao considerar a chuva de 5 dias, excluir a chuva de 1 dia, dessa forma seria considerada somente a chuva entre 1 e 5 dias. Da mesma forma, ao considerar a chuva de 30 dias, ao excluir a chuva de 5 dias, seria considerada somente a chuva que ocorreu entre 5 e 30 dias. Esse procedimento foi realizado, pois foi observado ao longo dessa pesquisa que informações repetidas afetavam o modelo de maneira negativa.

4.2.1 Análise e seleção das variáveis explicativas

Testes preliminares lançaram dúvidas sobre a utilização do índice de sensibilidade para a classificação da importância das variáveis explicativas dos modelos com redes neurais, pois o seu uso sistemático para a eliminação de variáveis com menor sensibilidade nem sempre coincide com os resultados obtidos pela análise exaustiva de todas as combinações. Isso ocorre porque o índice de sensibilidade representa o efeito sobre os valores calculados, mas não sobre os erros do modelo. Além disso, uma variável com pequeno índice de sensibilidade pode estar conferindo estabilidade ao modelo, havendo, portanto, redução sensível de desempenho com a sua retirada (OLIVEIRA et al.,2011).

Com base nessas constatações, propõem-se (PEDROLLO, 2014¹) a utilização de uma nova estatística para quantificar o incremento da variância não explicada após a supressão da variabilidade/variância da variável considerada em relação à variância não explicada pelo modelo completo. Considerando-se a Figura 12, duas relações para Y , representadas esquematicamente na em função de um conjunto X de variáveis explicativas:



onde: Y_c é a relação completa, com todas as variáveis explicativas consideradas; Y_k é a relação sem a contribuição da variável explicativa k , mediante a substituição dos valores desta variável pelo ponto médio de seu domínio; y_k é o valor observado (y_0); e y_0 , y_c são os valores correspondentes calculados, respectivamente, pelos modelos Y_c e Y_k .

Fonte: Pedrolo, O.C. (2014)

Considerando-se que o modelo completo (Y_c) proporciona melhor aproximação a variância não explicada pelo modelo Y_k é a soma da variância não explicada pelo modelo completo e da variância residual entre estes modelos. Então, resulta, para um conjunto de N registros (equação 18):

¹ Comunicação pessoal

$$\sum_{i=1,N}(y_{0i} - y_{k_i})^2 = \sum_{i=1,N}(y_{0i} - y_{c_i})^2 + \sum_{i=1,N}(y_{c_i} - y_{k_i})^2 \quad (18)$$

Isolando-se o termo dos quadrados residuais entre os modelos, resulta na equação 19:

$$\sum_{i=1,N}(y_{c_i} - y_{k_i})^2 = \sum_{i=1,N}(y_{0i} - y_{k_i})^2 - \sum_{i=1,N}(y_{0i} - y_{c_i})^2 \quad (19)$$

Dividindo-se os termos pela soma dos quadrados correspondente ao modelo completo, para resultar uma proporção, obtém-se a equação 20:

$$I_k = \frac{\sum_{i=1,N}(y_{c_i} - y_{k_i})^2}{\sum_{i=1,N}(y_{0i} - y_{c_i})^2} = \frac{\sum_{i=1,N}(y_{0i} - y_{k_i})^2}{\sum_{i=1,N}(y_{0i} - y_{c_i})^2} - 1 \quad (20)$$

Esse resultado constitui a proporção do incremento da variância não explicada pelo modelo devido à supressão da variância da variável k (Y_k), em relação à variância não explicada pelo modelo completo (Y_c), cujos valores podem ser interpretados. Exemplificando:

- Se $I_k < 0$, então a variância não explicada com a supressão da contribuição da variável k diminuiu, o que significa que esta variável estava prejudicando a capacidade de aproximação do modelo completo;
- Se $I_k = 0$ ou próxima de 0, então a variância não explicada com a supressão da contribuição da variável k não foi alterada ou a alteração produzida não foi significativa, concluindo-se que a variável não é importante;
- Se I_k é grande, então a variância não explicada com a supressão da contribuição da variável k é significativa, concluindo-se que esta variável é importante para a aproximação da função. Particularmente, se esta é um, significa que a supressão da contribuição da variável causou um aumento de 100% na variância não explicada em relação àquela do modelo completo.

Portanto, o índice I_k pode ser considerado como um índice de importância de cada variável explicativa k . Quanto maior este índice, mais importante é a variável para a aproximação da relação desejada.

Um índice de sensibilidade relativa, com base no que foi utilizado por Maier e Dandy (1997), é utilizado complementarmente, uma vez que este fornece também a informação do efeito relativo, aditivo ou subtrativo, da variável explicativa sobre as saídas do modelo. Porém, uma vez que as redes neurais constituem a parcela do modelo que atua no domínio das variáveis escalonadas (com variação entre zero e um), este índice foi modificado para a

análise da rede neural, com a indução de uma perturbação aditiva constante. A equação utilizada (equação 21) (PEDROLLO, 2014²), para um conjunto N de registros foi:

$$S_k = \frac{\sum_{i=1,N}(t_{c,p}(i) - t_{c,o}(i))}{\sum_{i=1,N}(p_{k,p}(i) - p_{k,o}(i))} \quad (21)$$

onde: $p_{k,o}, p_{k,p}$ é a variável explicativa escalonada k, original (o) e perturbada (p); $t_{c,o}, t_{c,p}$ são as saídas escalonadas calculadas (c) pela rede neural, originais (o) e resultantes após a perturbação da variável k (p); S_k é o índice de sensibilidade relativa resultante para a variável k.

Dessa forma, o índice de sensibilidade utilizado representa a proporção com que os resultados da rede neural são afetados por modificações em determinada variável explicativa. Um índice de sensibilidade maior que um indica que ocorreu amplificação da perturbação e um índice menor que um, que ocorreu atenuação desta. Em geral, espera-se, para modelos com mais de uma variável explicativa, amortecimento do efeito de cada variável, tendo-se em conta que a característica da robustez das redes neurais pressupõe este efeito. Variáveis explicativas cujas perturbações induzidas resultam ampliadas, ou menos amortecidas que as demais, na saída do modelo, indicam que este é mais sensível a estas.

O sinal deste índice também fornece informação, pois indica o sentido da variação conjunta da variável explicativa e da variável explicada. Se este sinal é positivo, significa que seu aumento provoca aumento nas saídas, e se é negativo, seu aumento provoca redução nas saídas da rede neural. Esta interpretação, porém, pode ser prejudicada pela presença de variáveis explicativas com informações redundantes (competitivas entre si), as quais distorcem o sinal esperado. Por outro lado, sinais incoerentes, quando se sabe o sentido esperado da variação, podem servir como indício desta possível redundância.

As perturbações não precisam ser grandes, uma vez que o índice é uma proporção, e não devem ultrapassar, nos extremos, o domínio das variáveis. Assim, utilizou-se o valor fixo da perturbação de 1/1000 para todas as variáveis, o que é conveniente, tendo-se em conta que, após o escalonamento, todas possuem a mesma escala, sendo limitadas entre zero e um.

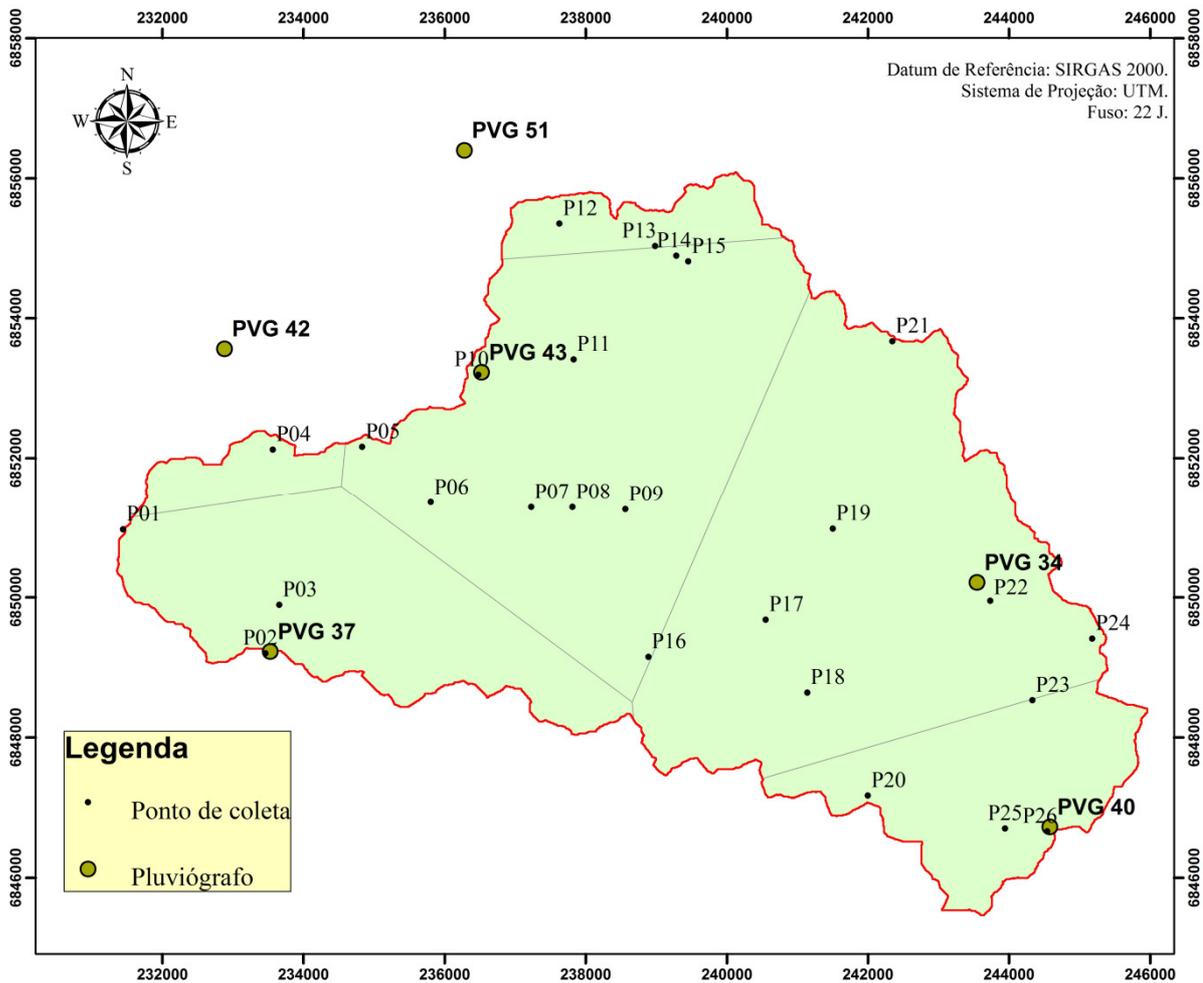
² Comunicação pessoal

5 RESULTADOS E DISCUSSÃO

5.1 Análise das chuvas utilizadas como entrada nos modelos de RNAs testados

Na Figura 13 é mostrada a área de influência de cada pluviômetro, tendo por base os polígonos de Thiessen. Em seis dos pontos de coleta considerados foram usados dois pluviômetros, pois tais pontos situaram-se próximos a dois polígonos. Na Tabela 3 são listadas, para cada ponto de coleta de solo, a informação de qual pluviômetro foi selecionado para a inserção dos dados de chuva nos modelos RNA testados.

Figura 13 - Distribuição dos pluviômetros na bacia do Taboão e influência de cada um deles sobre os pontos de coleta de solo, tendo por base o método de Thiessen



A partir dos dados de chuva, correspondente a cada ponto de coleta, foram calculados as chuvas passadas horárias (1, 2, 3, 4, 5, 6 e 12 horas) e diárias (1, 2, 3, 5, 10, 15, 20, 25, 30

dias) ocorridas antes da coleta de solo. Estes dados foram usados como variáveis de entrada do modelo de RNA. Além das chuvas passadas foram utilizados as médias móveis das chuvas passadas horárias e diárias com ponderação exponencial, conforme explicado no item 3.2.1 na metodologia dessa pesquisa.

Tabela 3- Pluviógrafos selecionados para cada um dos pontos de coleta de solo, tendo por base os polígonos de Thiessen

Ponto	Pluviógrafo selecionado
P01	37/42
P02	37
P03	37
P04	42
P05	42
P06	43
P07	43
P08	43
P09	43
P10	43
P11	43
P12	51
P13	51/43
P14	43/51
P15	43/51
P16	43/34
P17	34
P18	34
P19	34
P20	40
P21	34
P22	34
P23	34/40
P24	34
P25	40
P26	40

A variável correspondente à chuva média móvel ponderada horária exponencialmente foi testada para a obtenção dos valores da meia-vida, preliminarmente, com o cálculo dos coeficientes de correlação entre esta variável e o teor de umidade correspondente. Três situações distintas foram testadas: i) apenas com as chuvas antecedentes de uma a seis horas; ii) adicionando-se às anteriores também as chuvas antecedentes das seis às 12 horas; e iii) adicionando-se também as chuvas correspondentes entre 12 e 24 horas.

A Tabela 4 apresenta uma parte dos resultados obtidos, em torno do valor ótimo, onde R00, R12 e R24 correspondem às correlações obtidas em cada uma das três situações.

Portanto, os melhores resultados preliminares ocorreram para a meia-vida de 1,2 dias, e com uso de chuvas de hora em hora até seis horas e entre seis e 12 horas para comporem as médias móveis ponderadas exponencialmente. Nesse caso, os pesos resultantes (w) foram: 0,439; 0,246; 0,138; 0,078; 0,044; 0,024; e 0,030.

Tabela 4- Resultados das correlações da média móvel das chuvas passadas ponderadas horárias exponencialmente com o teor de água no solo, obtidos em função das meia-vidas testadas (em horas)

% Meia-vida em horas	R00	R12	R24
0,1	0,278	0,278	0,278
0,2	0,278	0,278	0,278
1,0	0,273	0,300	0,300
1,1	0,273	0,306	0,306
1,2	0,272	0,308	0,307
1,3	0,271	0,306	0,304
1,4	0,271	0,300	0,296
1,5	0,271	0,291	0,285

onde: R00 = chuvas antecedentes de 1 a 6 horas, R12 = chuvas antecedentes de 1 a 12 horas, e R24 = chuva antecedente de 1 a 24 horas

Preliminarmente, a variável correspondente à média móvel das chuvas passadas ponderada diárias exponencialmente, foi testada para a obtenção dos valores da meia-vida, com o cálculo dos coeficientes de correlação entre essa variável e o teor de água no solo correspondente, apenas com as chuvas antecedentes de um dia, dois dias e três dias. As chuvas com maior antecedência (de 5 a 30 dias) teriam pesos muito pequenos, entretanto, podem ser muito importantes para representar as condições de umidade de mais longo período, não podendo, em princípio, ser substituídas no modelo pela média móvel ponderada exponencialmente. Na Tabela 5 são apresentados os resultados das correlações dessas chuvas com os teores de água no solo correspondentes.

Tabela 5 - Resultados das correlações da média móvel das chuvas diárias passadas ponderadas exponencialmente com o teor de água no solo obtidos em função das meia-vidas testadas (em dias)

Meia-vida (dias)	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9	1
Correlação	0,147	0,149	0,151	0,154	0,154	0,154	0,153	0,151	0,149	0,147

Assim, o valor aproximado da meia-vida foi de 0,5 dias, com os pesos correspondentes (w) iguais a: 0,750; 0,188; e 0,047.

5.1.1 Análise das variáveis topográficas da bacia e das propriedades físicas do solo utilizadas como entrada nos modelos de RNAs testados

Na Tabela 6 são mostradas as propriedades físicas do solo (tipo de solo; densidade do solo; resistência à penetração no solo para as camadas de 0 a 20 cm e de 20 a 40 cm; e percentual de areia, silte e argila), as características topográficas (altitude, declividade e distância do ponto ao trecho do rio mais próximo e o desnível do ponto ao trecho do rio mais próximo), além dos pluviógrafos utilizados no cálculo das chuvas, considerando os 26 pontos em que foram coletadas amostras de solo para determinação da umidade gravimétrica e as 24 datas (ou 25 momentos) em que essas coletas foram efetuadas. Tais variáveis foram selecionadas para entrada nos modelos de RNAs testados.

Observa-se que os pontos de coleta de solo encontram-se entre as altitudes 340 e 473 metros, com declividade entre 0,0 e 14,8%, distância do trecho do rio mais próximo variando entre 18 e 566 metros e desnível do ponto até o trecho do rio mais próximo entre 0,0 e 36,25 metros. A densidade do solo varia entre 1,40 e 1,73 g/cm³, a resistência à penetração no solo está compreendida entre 1007,15 e 2732,45 kPa para a camada de 0 a 20 cm e entre 1530,29 e 3009,57 kPa para a camada entre 20 e 40 cm; enquanto que o percentual o de areia varia entre 11,88 e 52,02%, o de silte entre 14,63 e 38,62%, e o de argila varia entre 24,29 e 64,67%.

Os pontos amostrados estão distribuídos sobre os solos do tipo Latossolo Vermelho Distroférico (2 pontos na subclasse LVdf1 e 5 na subclasse LVdf2), Latossolo Vermelho Distrófico (7 pontos na subclasse LVd1 e 5 pontos na subclasse LVd2), e Nitossolo Vermelho Eutroférico (7 pontos). Esses solos compõem 89,78% do total de solos presentes na bacia. As demais classes (e/ou subclasses) não foram coletadas por representarem apenas um pequeno percentual dos solos da bacia (10,22%).

Tabela 6 – Propriedades físicas do solo e topográficas da bacia, e listagem dos pluviômetros utilizados no cálculo das chuvas, considerando os 26 pontos de coleta de solo e as 24 datas (ou 25 momentos) em que as coletas foram realizadas

Ponto	Tipo de solo	Teor (%)			Densidade do solo (g/cm ³)	Resistência à penetração no solo 0-20cm (Kpa)	Resistência à penetração no solo 20-40cm (Kpa)	Altitude (m)	Pluviômetro	Declividade (%)	Distância do ponto ao trecho do rio mais próximo (m)	Desnível do ponto até o trecho do rio mais próximo (m)
		Areia	Silte	Argila								
P01	NVef	16,52	38,44	45,04	1,40	1371,70	2116,95	351	37/42	2,62	43	0,14
P02	LVd2	13,77	35,43	50,80	1,64	2384,90	2499,95	410	37	0,00	566	19,20
P03	LVdf2	15,33	20,88	63,79	1,53	1964,90	2858,29	382	37	8,33	181	12,07
P04	LVdf2	19,99	32,76	47,25	1,64	1264,90	2083,33	419	42	5,31	333	21,51
P05	LVdf1	15,87	35,82	48,31	1,58	1267,00	1530,29	429	42	5,31	509	36,25
P06	NVef	11,88	33,67	54,45	1,46	1378,55	1855,81	396	43	8,41	78	5,88
P07	NVef	18,50	38,62	42,88	1,54	1197,65	1712,48	378	43	5,56	42	2,72
P08	LVd1	18,16	37,56	44,28	1,60	1550,70	1841,71	397	43	0,00	214	6,72
P09	LVd1	20,74	27,84	51,42	1,58	1384,40	1926,81	435	43	0,00	335	10,00
P10	LVdf2	16,70	19,79	63,51	1,69	1302,90	2486,00	433	43	3,53	220	5,22
P11	NVef	17,00	25,64	57,36	1,56	1712,65	2635,14	389	43	0,65	236	10,00
P12	LVdf1	15,49	19,84	64,67	1,52	1325,15	2460,14	455	51	2,64	170	20,01
P13	LVdf2	14,66	29,21	56,13	1,56	1187,20	2637,67	448	51/43	4,61	174	13,20
P14	NVef	16,99	35,55	47,46	1,63	1544,15	1711,81	427	43/51	7,64	187	12,89
P15	NVef	23,66	29,41	46,93	1,51	1287,70	2976,52	417	43/51	7,39	18	1,79
P16	LVd1	27,64	27,32	45,04	1,45	1869,10	2485,95	411	43/34	2,53	286	10,14
P17	LVdf2	18,52	26,23	55,25	1,47	1067,75	1786,52	415	34	2,91	252	7,76
P18	NVef	30,81	21,00	48,19	1,59	1167,85	2606,67	402	34	4,66	21	0,56
P19	LVd2	32,98	27,54	39,48	1,60	2237,90	1945,19	452	34	3,85	189	20,43
P20	LVd2	24,78	24,51	50,71	1,49	1279,95	1868,90	457	40	2,17	429	12,36
P21	LVd2	18,78	26,95	54,27	1,55	1007,15	2301,00	477	34	0,00	484	25,13
P22	LVd2	31,84	17,08	51,08	1,69	1984,95	2813,62	446	34	5,26	99	2,34
P23	LVd1	52,02	23,69	24,29	1,61	1330,80	1801,29	474	34/40	0,00	265	9,84
P24	LVd1	50,32	14,63	35,05	1,68	1339,65	2077,38	483	34	4,40	111	3,34
P25	LVd1	38,00	21,50	40,50	1,60	1333,35	2366,19	470	40	2,15	329	2,98
P26	LVd1	38,00	21,50	40,50	1,73	2732,45	3009,57	483	40	0,00	191	0,00

5.2 Análise das estatísticas descritivas do teor de água no solo

No APÊNDICE B são apresentados os resultados do teor de água no solo (umidade gravimétrica), em porcentagem, considerando os 26 locais de amostragem e as 24 datas (ou 25 momentos) em que as coletas foram realizadas. Conforme já mencionado, esses valores foram utilizados para treinamento, validação e teste dos modelos de RNAs avaliados, bem como para a determinação das estatísticas de desempenho das redes durante essas etapas.

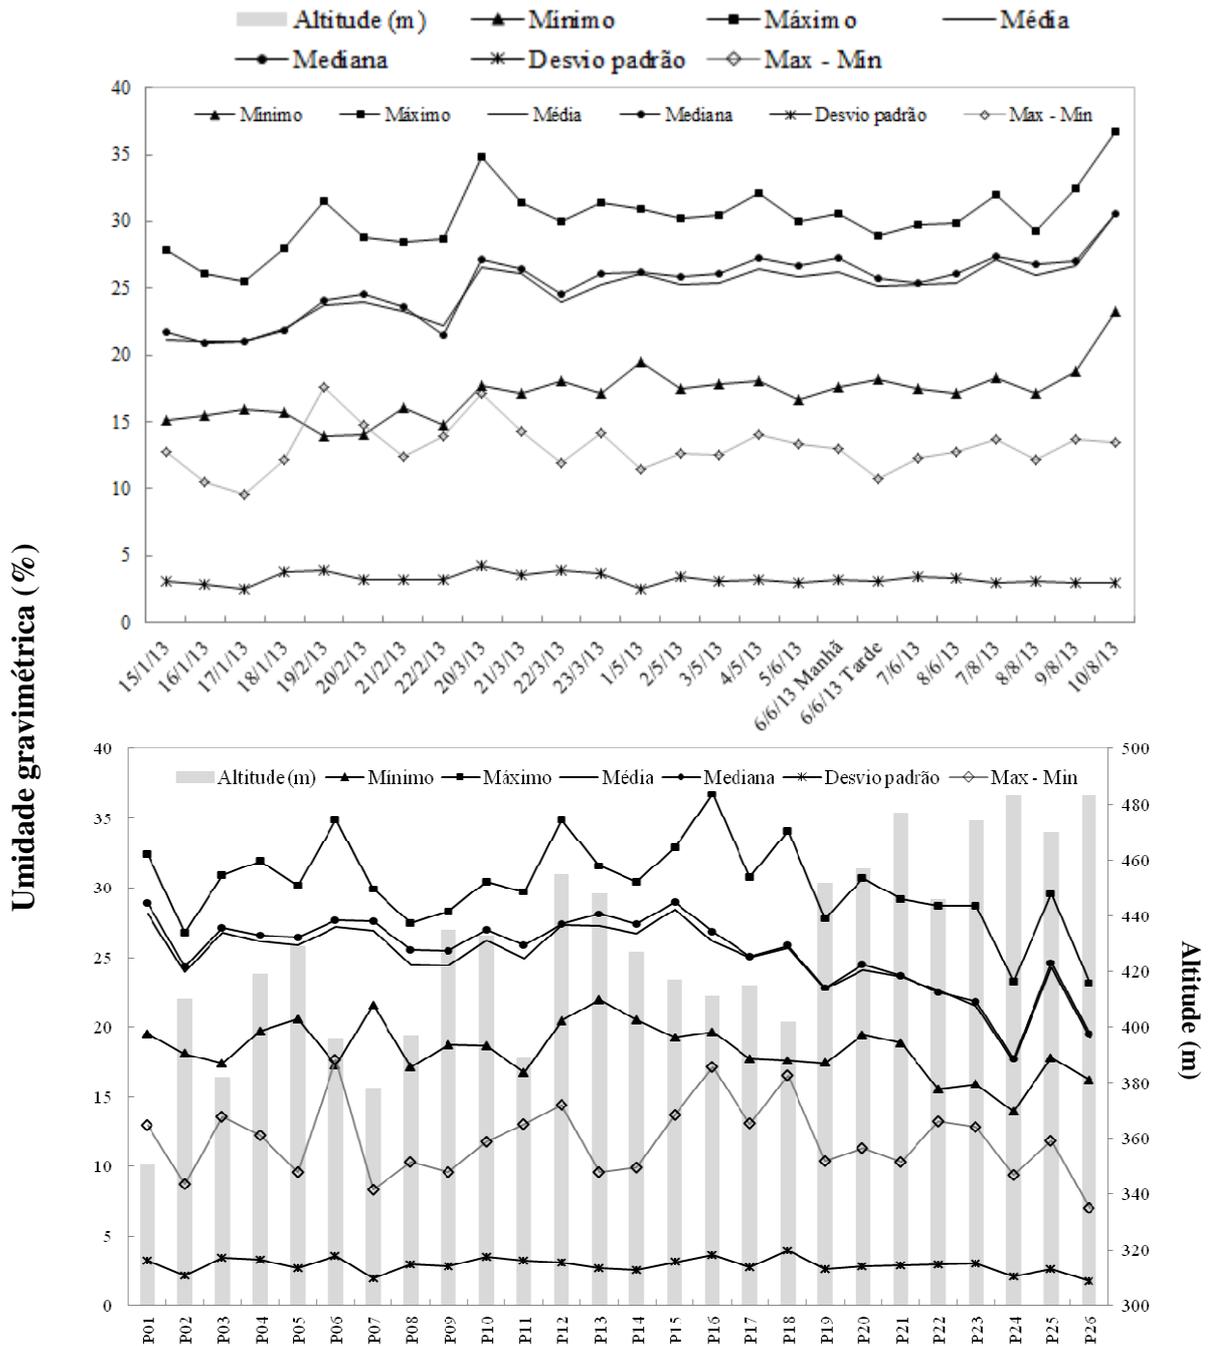
De um total de 650 amostras analisadas (considerando os 25 momentos em que as coletas foram realizadas e os 26 pontos), 44 delas foram excluídas, por serem considerados inconsistentes em razão de problemas ocorridos durante a amostragem ou nas análises de laboratório. A umidade gravimétrica medida entre janeiro e agosto de 2013 (período amostrado), considerando todos os pontos de coleta, variou entre 13,93% e 36,75%, com média de 24,88%, mediana de 26,10%, e desvio padrão médio de 3,25%.

Na Figura 14 é exposta a variação temporal e espacial da umidade gravimétrica, considerando os 26 pontos de coleta de solo e os 25 momentos em que as coletas foram realizadas. No gráfico superior são mostrados os valores máximos, mínimos e médios da umidade gravimétrica para cada data de coleta, além da mediana, do desvio padrão e das diferenças entre o valor máximo e o mínimo de umidade em cada uma das datas (considerando todos os pontos amostrados na data). Observa-se que o maior valor de umidade registrado é igual a 36,75% e o menor é de 13,93%, com mediana variando entre 20,93 e 30,58%, sendo o maior desvio padrão registrado igual a 4,24% e o menor igual a 2,48%. A maior diferença observada entre o valor máximo e mínimo da umidade, para as diferentes datas e considerando os diferentes pontos (analisados em cada data), é igual a 17,58% e a menor diferença é 9,57%.

Medeiros (2004) realizou um estudo experimental na bacia Donato (sub-bacia embutida na bacia do Taboão, objeto dessa pesquisa), objetivando verificar as possíveis relações existentes entre a variabilidade espaço-temporal do teor de água no solo e os fatores ambientais relacionados à topografia e ao solo. Para isso, a autora analisou um conjunto de mais de 2000 medições do teor de água no solo, coletadas numa malha regular em toda a bacia, nas profundidades de 0, 30 cm e 60 cm, com detalhamento em dois perfis com 280 m (Perfil P1) e 320 m (Perfil P3) de comprimento. As medições do teor de água no solo foram realizadas pelo método gravimétrico na camada superficial, e com TDR nas camadas inferiores. A umidade gravimétrica (g/g) na superfície do solo variou entre 14,4 e 51,5%, sendo a densidade média do solo superficial igual a 1,24 g/cm³. O valor inferior (14,4%) é

muito próximo aos encontrados nesta pesquisa (13,93%), porém o valor superior da autora (51,5%) é bem maior que o desta pesquisa (36,75%). Isto pode ser explicado porque a autora coletou amostras durante um evento de chuva extremo, sendo que estes valores estavam próximos a saturação. Os resultados também demonstraram que o teor de água no solo apresenta altos valores no período de inverno (jul/ago) e valores inferiores no período do verão (dez/jan).

Figura 14 – Umidade gravimétrica: variação temporal (gráfico inferior) e espacial (gráfico superior), considerando as coletas realizadas nos 26 pontos entre 15/01/13 e 10/08/13



Fonte: autor

Oliveira, Castro e Goldenfum (2010) realizaram um estudo do comportamento das variáveis hidrológicas do balanço hídrico na mesma sub-bacia, utilizando dois lisímetros de 1 m³ cada, contendo solo indeformado para o período 30/10/2003 a 17/04/2004. Os mínimos valores de umidade volumétrica registrados no solo com palha foram entre 39 e 55%; enquanto que para o solo sem palha entre 37 e 49%. Considerando uma densidade do solo no lisímetro igual a 1,69 g/cm³, os limites resultantes para a umidade gravimétrica seriam 23,07 e 32,54% para o solo com palha, e 21,89 e 28,99% para o solo sem cobertura de palha. Apesar destes valores serem resultados de uma sub-bacia embutida na bacia do Taboão (objeto de monitoramento dessa pesquisa), o limite inferior dos autores (21,89%) é maior que o encontrado nesta pesquisa (13,93%), e o limite superior dos autores (36,75%) é ligeiramente maior que o encontrado nesta pesquisa (32,54%) e bem menor que os de Medeiros (2007) (51,5%), o que comprova que os valores máximos encontrados por esta última autora estavam muito próximos da saturação do solo.

Ainda na mesma área de estudo, Kaufmann, Castro e Pinheiro (2012) quantificaram os escoamentos superficiais e a drenagem de água no solo, para diferentes intensidades de precipitação e manejo agrícola do solo (plantio direto e convencional), utilizando dois lisímetros com 1 m³ cada. Os autores observaram que o lisímetro com plantio direto gerou menor escoamento superficial e maior escoamento de drenagem e, portanto, maior infiltração e menor volume de água armazenada no perfil do solo. Nesse caso, a menor umidade volumétrica registrada no solo com plantio convencional foi igual a 28,78% e a maior foi igual a 50,73%, enquanto que no plantio direto, a umidade mínima registrada foi de 21,39% e a máxima foi igual a 54,62%. Em termos de umidade gravimétrica, considerando uma densidade do solo igual a 1,69 g/cm³, a umidade mínima verificada no plantio convencional foi igual a 17,03% e a máxima foi de 30,02%; e no plantio direto, a mínima registrada foi 12,66% e a máxima foi igual a 32,32%. Esses valores para plantio direto estão relativamente próximos aos mínimos e máximos observados nesse estudo (13,93 e 36,75%, respectivamente).

Feltrin et al. (2013) realizaram o monitoramento da variabilidade espacial da umidade do solo também com uso de lisímetro de 1 m³, considerando um solo com cobertura vegetal de floresta nativa (Bioma Mata Atlântica) e outro com pastagem, em uma bacia localizada no sul do Brasil. O monitoramento foi realizado simultaneamente para as duas coberturas, no período compreendido entre outubro de 2010 e maio de 2011. A umidade volumétrica registrada no solo da floresta variou, aproximadamente, entre 15 e 40%; enquanto que no solo

com pastagem essa variação ficou, aproximadamente, entre 10 e 40%. Considerando que a densidade do solo na floresta para a camada superficial (10 cm de profundidade) é igual a $1,40 \text{ g/cm}^3$ e no solo com pastagem é de $1,37 \text{ g/cm}^3$, os limites mínimos e máximos da umidade gravimétrica na floresta seriam 10,71 e 28,57%, respectivamente, e na pastagem a umidade gravimétrica estaria compreendida entre 7,30 e 29,20%. Esses valores são bem menores do que aqueles observados nessa pesquisa, apesar da precipitação média anual na bacia monitorada pelos autores ser muito semelhante à desse estudo (entre 1700 a 1800 mm). Todavia, a camada superficial dos solos estudados é majoritariamente formada por areia (76,70% para o solo da floresta e 88,50% para o solo com pastagem), o que explicaria os menores teores de água armazenado nos solos presentes na bacia monitorada pelos autores.

É possível visualizar ainda, que a variação da mediana (Figura 14) e também dos máximos, mínimos e do desvio padrão é, geralmente, menor durante o período do inverno, alcançando maiores variações no verão, quando as temperaturas são mais elevadas. De fato, a menor umidade gravimétrica foi verificada durante o verão, no dia 19/01/2013 para o ponto PN4, que está localizado em uma altitude de 483 m. Já a maior umidade gravimétrica foi observada durante o inverno, no dia 10/08/2013 para o ponto PN9, situado em uma altitude de 411 m. Ambos os pontos pertencem ao solo Latossolo Vermelho Distrófico (LVd1).

Na realidade, existe coerência nos resultados obtidos, uma vez que, espera-se que no verão o teor de água no solo seja menor, isso porque as temperaturas são maiores nesse período, o que ocasiona maior demanda evaporativa da água no solo e maior evapotranspiração da vegetação (no caso, durante o cultivo de soja na bacia em estudo). Além disso, o ponto PN4 está em uma altitude mais elevada na bacia e conforme já mencionado (FAMIGLIETTI, RUDNICKI e RODELL, 1998; ZHU e LIN, 2011), o teor de água no solo tende a ser menos elevado nas regiões de maior altitude, em comparação com aquelas mais planas, que recebem as águas drenadas de um número maior de zonas contribuintes. Por outro lado, a maior umidade gravimétrica verificada durante o inverno confirma a influência climática (temperatura do ar, radiação solar, umidade relativa do ar) sobre o armazenamento de água no solo.

No segundo gráfico (inferior) observam-se, para cada um dos pontos, os valores máximos, mínimos e médios da umidade gravimétrica, além da mediana, do desvio padrão e das diferenças entre o valor máximo e o mínimo (amplitude); considerando todas as datas de coleta realizadas em cada um dos pontos. Nesse caso, a mediana dos valores da umidade gravimétrica varia entre 20,93 e 30,58%, sendo o maior desvio padrão registrado igual a

3,95% e o menor igual a 1,78%. A maior diferença observada entre o valor máximo e mínimo da umidade, para os diferentes pontos e considerando as diferentes datas (analisados em cada ponto), é igual a 17,63% e a menor diferença é de 7,00%. Os máximos e mínimos registrados nos pontos são semelhantes aos anteriores. A partir da mediana da umidade nos diferentes pontos amostrados pode-se perceber também, que existe uma variação espacial mais significativa da umidade em alguns pontos em relação a outros.

Essas características demonstram que existe uma variação espacial e temporal do teor de água no solo da bacia, durante o período analisado; indicando que tanto as características físicas da bacia (propriedades físicas do solo e topográficas da bacia) quanto as características climáticas estão influenciando o teor de água presente no solo. Percebe-se, portanto, que tais parâmetros precisam ser considerados na simulação da variação do teor de água no solo da bacia.

Há que se considerar, ainda, que a interferência conjunta dos diversos fatores que afetam o teor de água no solo (tipo de solo, altitude, proximidade do rio, evapotranspiração, chuva, declividade, densidade do solo, etc.) dificulta a total compreensão do que ocorre com a umidade do solo, mesmo porque muitos desses fatores estão inter-relacionados.

5.3 Estimativa do teor de água no solo com modelos baseados em RNAs

Foram testados mais de duzentos modelos baseados em RNAs para a estimativa do teor de água no solo. Para isso, considerou-se a mesma configuração da rede para todos os testes realizados, ou seja, mesmo número de neurônios na camada interna (25 neurônios), mesmo número de iterações (16), e mesmo número de ciclos (30.000). Há que se destacar, entretanto, que, para alguns modelos investigados, o número de ciclos máximo permissível foi alterado para 100.000 ou 300.000, já que se observou que o número de ciclos executados em tais casos não era suficiente. Além disso, utilizou-se a mesma série de treinamento, validação e verificação em todas as situações testadas, porém empregando-se diferentes combinações de variáveis de entrada em cada um dos modelos analisados.

Foram selecionados 86 modelos para apresentação nesta pesquisa. No APÊNDICE C são apresentadas as estatísticas de testes destes modelos, obtidas durante o treinamento e a verificação dessas redes, considerando as diferentes combinações de variáveis de entrada. Inicialmente, foram avaliadas as entradas de cada grupo separadamente (chuva, topografia da bacia, propriedades físicas do solo e informações climáticas sem dados de chuva) e, posteriormente, foram realizadas combinações entre esses grupos. Por último, analisou-se

também um modelo contendo todas as variáveis de entrada disponíveis. O número máximo de variáveis de entrada analisadas foi igual a 40 e o número mínimo foi quatro variáveis.

O desempenho dos 86 modelos durante o treinamento foi bastante variável, dependendo das entradas testadas. Entretanto, em algumas situações analisadas, o desempenho observado foi semelhante quando se omitia ou se considerava determinadas variáveis de entrada, principalmente aquelas do grupo da topografia da bacia. O NS variou entre 0,07 e 0,87, com um valor médio de $0,63 \pm 0,19$ e mediana de 0,70. O Ea (95) variou entre 2,82 e 7,06%, com média de $4,59 \pm 1,11\%$ e mediana de 4,31%; e o Eamáx apresentou uma variação entre 4,52 e 11,25%, com média de $7,68 \pm 1,74\%$ e mediana de 7,85%. Por outro lado, o erro médio (Ea) variou entre 1,06 e 3,00%, com média de $1,73 \pm 0,46\%$ e mediana de 1,57%, e o RMSE variou entre 1,40 e 3,69%, com média de $2,25 \pm 0,58\%$ e mediana de 2,08%.

No processo de verificação desses modelos, o desempenho observado foi geralmente menor. O NS variou entre 0,16 e 0,77, com um valor médio de $0,52 \pm 0,17$ e mediana de 0,56. O Ea (95) variou entre 3,63 e 8,34%, com média de $5,69 \pm 1,17\%$ e mediana de 5,69%; e o Eamáx apresentou uma variação entre 5,77 e 16,42%, com média de $8,56 \pm 1,88\%$, e mediana de 8,46%. Por outro lado, o erro médio (Ea) variou entre 1,52 e 3,09%, com média de $2,26 \pm 0,44\%$ e mediana de 2,22%, e o RMSE variou entre 2,01 e 3,88%, com média de $2,87 \pm 0,53\%$ e mediana de 2,82%. O menor desempenho durante a verificação dos modelos é esperado, já que nesse processo utiliza-se uma série diferente daquela usada para determinar os parâmetros das RNAs testados (processo de treinamento). Quanto melhor o desempenho do modelo durante essa fase, mais elevada é a capacidade de generalização da rede testada, ou seja, essa rede conseguirá representar mais adequadamente teores de água no solo diferentes daqueles utilizados durante o treinamento da rede (determinação do modelo).

Na Tabela 7 são apresentadas as diferentes combinações de entrada testadas para os 31 principais modelos de RNA analisados, e a Tabela 8 mostra as estatísticas de desempenho desses modelos, obtidas durante o treinamento e a verificação desses modelos. Esses modelos foram escolhidos tendo por base: melhor desempenho durante a verificação; bom desempenho do modelo e facilidade de obtenção das variáveis de entrada; e bom desempenho do modelo e necessidade de poucas variáveis de entrada ou presença de variáveis de entrada facilmente obtidas. Também foram apresentados os modelos que utilizam somente as variáveis de cada um dos grupos (propriedades físicas do solo, topografia da bacia, chuva ou variáveis climatológicas sem dados de chuva), além de algumas variações dos melhores modelos.

Nas Figuras 15 a 18 são apresentadas, para os quatro grupos (M02- topografia da bacia, M03-propriedades físicas do solo, M05- informações climáticas sem dados de chuva, e M08- chuva), a relação entre os dados calculados e observados de umidade gravimétrica em analogia à reta de ajuste ideal, além da relação entre o erro (diferença) verificado entre esses dados e os valores observados de umidade gravimétrica, e o comportamento dos valores calculados e observados, ao longo do tempo, considerando-se a série utilizada para verificação dos modelos.

O modelo M02, relativo aos dados topográficos da bacia (declividade, altitude, distância do ponto ao trecho mais próximo do rio e desnível do ponto até o trecho mais próximo do rio), apesar de apresentar bom desempenho (segundo melhor), com NS de 0,41 no treinamento e 0,39 na verificação, requereu um elevado número de ciclos (300.000 ciclos) para treinamento da rede, limitando sua aplicabilidade. De maneira geral, essa rede não ajusta adequadamente os valores observados aos calculados (Figura 15a), e não consegue representar os extremos da umidade gravimétrica, subestimando ou superestimando tais picos. (Figura 15b). Usualmente, valores de umidade superiores a 25% são subestimados e os inferiores são superestimados pelo modelo. Contudo, essa rede consegue captar, simplificadamente, a variação do comportamento da umidade gravimétrica ao longo do tempo (Figura 15c).

O modelo baseado nas propriedades físicas do solo (M03) apresenta melhor distribuição do RMSE em comparação com os outros três (gráficos b das Figuras 15 a 18). Percebe-se claramente que o modelo M03 (Figura 16), que utiliza as propriedades físicas do solo (tipo de solo; densidade do solo; tensão da água no solo; resistência à penetração no solo para as camadas de 0 a 20 cm e 20 a 40 cm; e % de areia, silte e argila), apresenta melhor desempenho em relação aos demais (modelos M02, M05 e M08), alcançando NS de 0,63 no treinamento e 0,50 na verificação da rede. Esse modelo também apresentou os menores erros entre os valores observados e calculados, sendo o erro máximo absoluto ($E_{a \max}$) igual a 8,99 e 7,83%, o erro médio absoluto (E_a) de 1,69 e 2,34%, a raiz quadrada do erro quadrático médio (RMSE) de 2,33 e 2,96%, com 95% dos erros absolutos ($E_a(95)$) apresentando valor de até 4,70 e 6,12%, para o treinamento e a verificação, respectivamente. Dentre os grupos, essa é a rede que melhor ajusta os dados de umidade gravimétrica calculados aos observados (Figura 16a), e também representa com maior precisão a variação do comportamento da umidade gravimétrica ao longo do tempo, mesmo que não simule satisfatoriamente os valores extremos (Figura 16c). Em geral, os valores de umidade superiores a 25% são subestimados

pelo modelo, enquanto que os menores que 25% são comumente superestimados pela rede (Figura 16b).

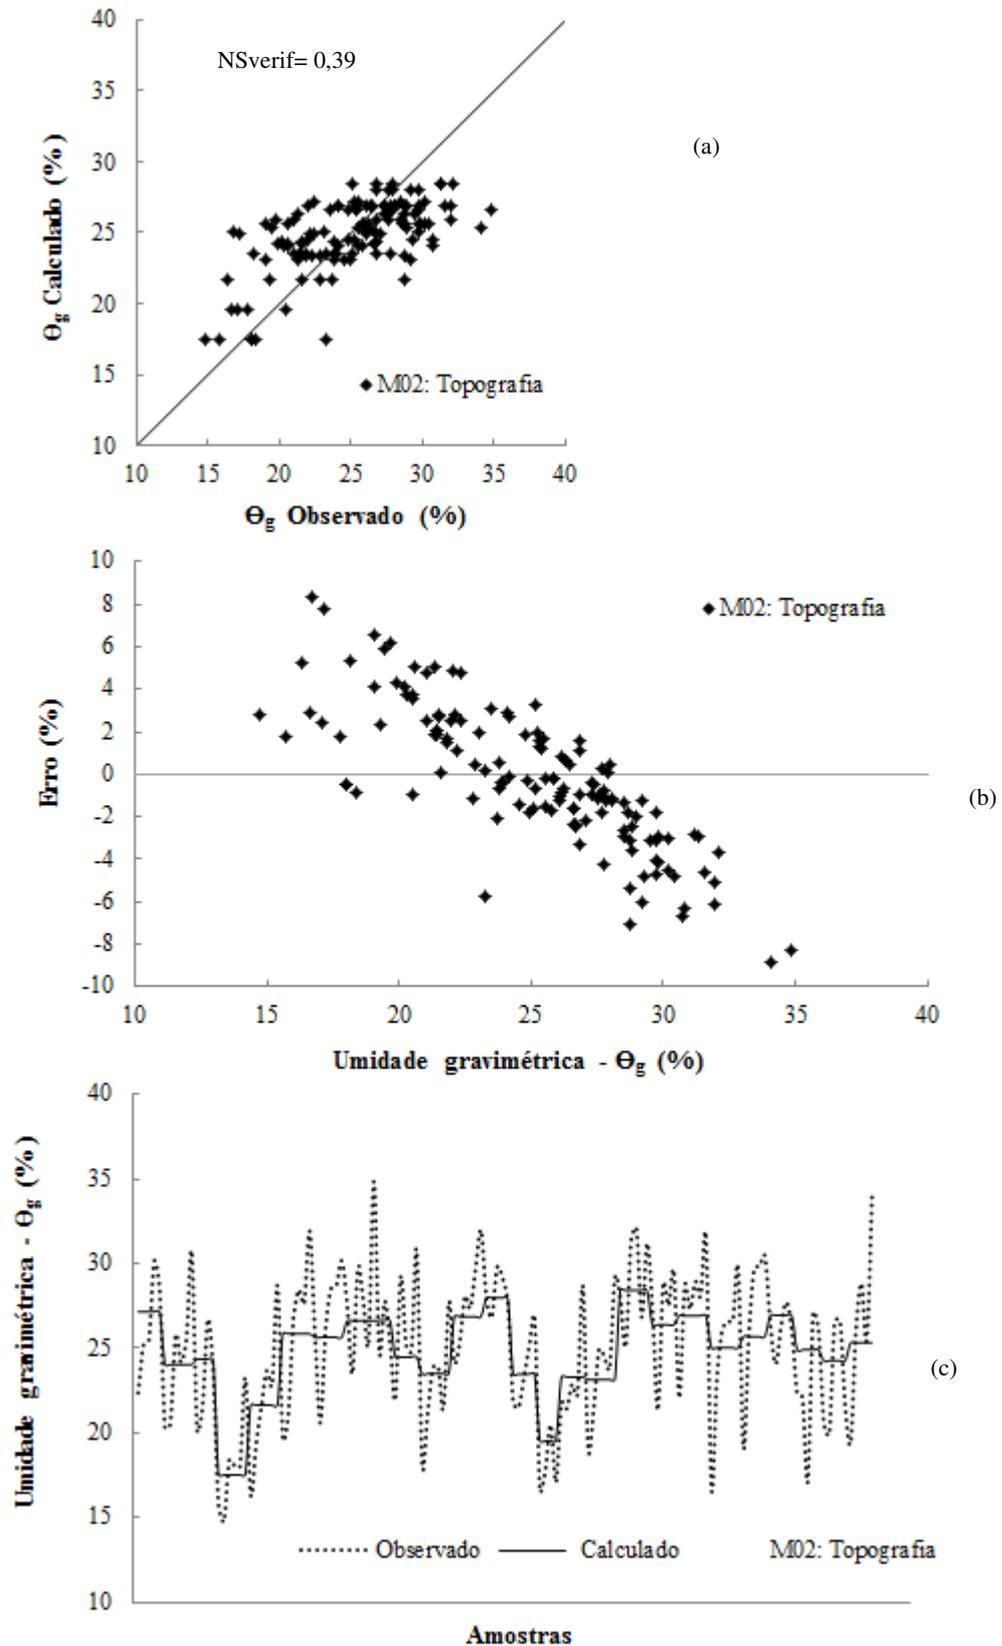
Por outro lado, o pior desempenho foi observado para o modelo M05 que utiliza somente variáveis climáticas sem chuva (estações do ano, evapotranspiração de referência, temperatura do ar máxima e temperatura do ar mínima, umidade relativa do ar máxima e umidade relativa do ar mínima, pressão atmosférica, radiação solar global, velocidade do vento e temperatura na relva), apresentando NS de 0,27 no treinamento e 0,28 na verificação. De fato, esse modelo apresenta a pior relação entre os dados calculados e observados (Figura 17a), e não consegue representar o comportamento da umidade gravimétrica ao longo do tempo (Figura 17c), subestimando ou superestimando consideravelmente os valores observados (Figura 17b), exercendo baixa influência sobre a estimativa do teor de água no solo. Essa característica pode estar relacionada à presença de cobertura vegetal e de palha na superfície do solo, que mantém a temperatura da superfície estável, impedindo a ação direta dos raios solares e limitando os processos de evaporação, o que, por consequência, mantém os teores de água na superfície do solo. Dessa forma, pode-se inferir que as variáveis climáticas (sem consideração da chuva) tem uma influência pequena sobre a estimativa dos teores de água armazenados no solo para este manejo de solo.

Elshorbagy e Parasuraman (2008) também observaram que as informações climáticas (valores médios diários de precipitação, temperatura do ar, temperatura do solo na turfa e nas camadas de solo, e radiação solar) não exerciam grande influência sobre a estimativa da umidade do solo em diferentes profundidades e coberturas vegetais. A rede desenvolvida pelos autores apresentou um ajuste, entre a umidade calculada e a observada, muito semelhante ao verificado nessa pesquisa.

Tabela 8 – Resumo das estatísticas para os 31 principais modelos de RNA analisados (treinamento e verificação)

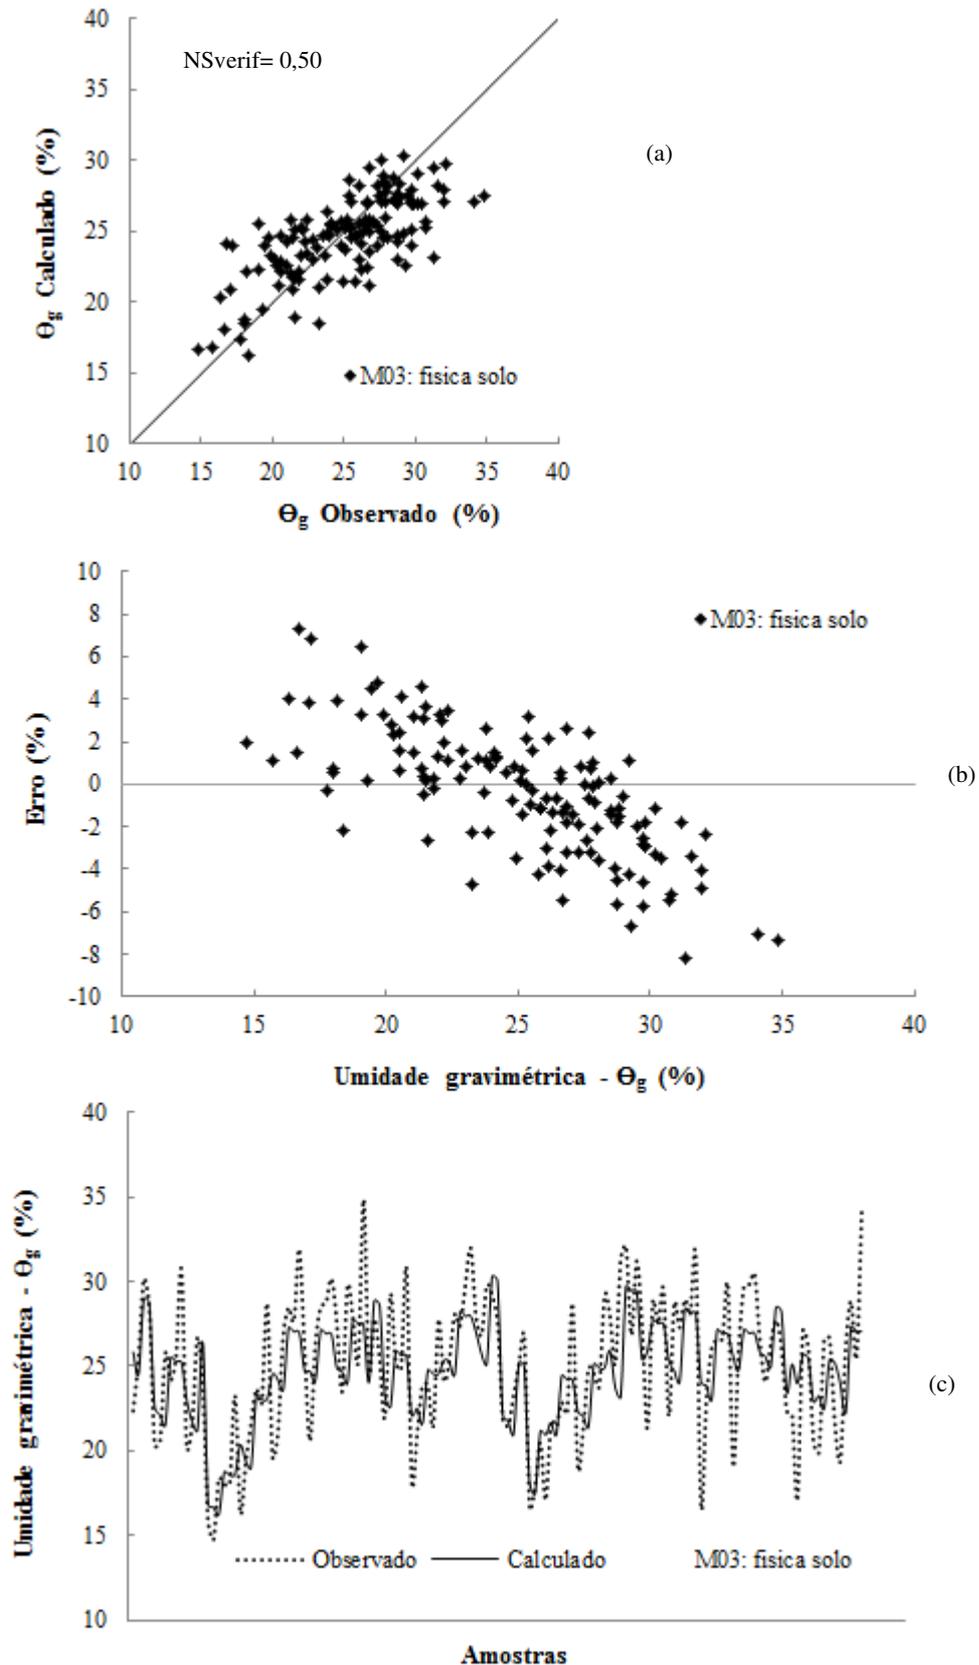
Modelo	Nº de entradas	Ciclos (mil)	Nit	nh	J	Treinamento					Verificação				
						Ea(95)	Ea máx	Média (Ea)	RMSE	NS	Ea(95)	Ea máx	Média (Ea)	RMSE	NS
M69	11	100	16	25	4534	4,46	7,99	1,56	2,08	0,7	3,71	7,54	1,52	2,01	0,77
M74	14	30	16	25	13703	3,78	6,41	1,31	1,77	0,78	5,13	8,38	1,86	2,46	0,66
M43	27	30	16	25	8485	3,67	6,56	1,36	1,75	0,79	3,92	6,95	1,69	2,18	0,74
M56	26	30	16	25	18859	3,23	4,55	1,12	1,48	0,85	6,11	9,67	2,42	3,05	0,48
M71	14	30	16	25	7323	4,11	8,08	1,51	2,05	0,71	3,63	8,61	1,54	2,02	0,77
M73	14	30	16	25	8172	4,24	8,03	1,51	2,05	0,71	3,72	8,48	1,57	2,07	0,76
M78	7	30	16	25	17135	4,64	8,75	1,76	2,32	0,63	4,59	6,43	1,96	2,47	0,65
M86	8	30	16	25	5167	4,77	7,91	1,82	2,37	0,61	5,21	7,68	1,87	2,46	0,66
M66	12	60	100	25	6111	4,35	8,25	1,5	2,04	0,71	3,9	8,72	1,58	2,11	0,75
M53	26	100	16	25	9946	3,64	6,24	1,32	1,71	0,8	4,5	7,14	1,69	2,16	0,74
M49	25	30	16	25	8225	3,99	5,62	1,38	1,80	0,78	4,31	7,39	1,72	2,22	0,73
M59	26	30	16	25	6867	3,7	5,5	1,37	1,77	0,78	4,41	6,52	1,71	2,2	0,73
M46	27	30	16	25	7000	3,64	6,12	1,36	1,75	0,79	4,23	6,02	1,76	2,22	0,72
M47	26	30	16	25	8043	3,60	5,69	1,38	1,76	0,79	4,12	6,94	1,79	2,24	0,72
M55	26	30	16	25	7755	3,38	6,02	1,33	1,71	0,8	4,39	7	1,77	2,26	0,72
M57	26	30	16	25	7757	3,88	8,11	1,44	1,87	0,76	4,7	5,77	1,71	2,23	0,72
M42	28	30	16	25	7786	3,46	5,24	1,28	1,65	0,81	4,36	6,44	1,78	2,29	0,71
M45	27	30	16	25	10311	3,83	5,77	1,32	1,74	0,79	4,70	6,90	1,77	2,28	0,71
M54	26	30	16	25	9807	3,28	5,8	1,28	1,64	0,82	4,18	6,71	1,86	2,28	0,71
M72	38	30	16	77	1984	4,6	8,8	1,75	2,28	0,64	4,56	8,46	1,83	2,32	0,70
M27	23	30	16	25	9002	4,31	6,32	1,54	2,02	0,72	4,83	7,68	1,87	2,34	0,69
M44	27	30	16	25	8253	3,38	5,39	1,30	1,65	0,81	4,90	6,49	1,81	2,35	0,69
M28	22	30	16	25	5746	4,42	7,64	1,63	2,11	0,69	4,89	6,05	1,96	2,42	0,67
M34	17	30	16	25	7830	4,88	7,85	1,62	2,43	0,59	5,58	8,06	2,22	2,8	0,56
M14	19	30	16	25	14887	4,66	7,26	1,74	2,22	0,66	5,73	6,63	2,36	2,91	0,52
M21	24	30	16	25	14479	3,27	5,40	1,23	1,58	0,83	5,80	9,01	2,28	2,93	0,52
M03	8	100	16	25	30877	4,70	8,99	1,69	2,33	0,63	6,12	7,83	2,34	2,96	0,50
M17	17	30	16	25	7416	4,93	7,08	1,92	2,48	0,58	5,95	8,74	2,52	3,11	0,46
M02	4	300	16	9	44516	5,85	10,63	2,28	2,94	0,41	6,22	8,91	2,62	3,27	0,39
M08	16	30	16	25	4542	6,18	9,41	2,44	3,11	0,34	6,82	9,79	2,81	3,48	0,32
M05	10	30	16	25	478	6,71	9,81	2,56	3,27	0,27	6,32	9,61	2,85	3,54	0,28

Figura 15 - Umidade gravimétrica observada e calculada em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados de umidade gravimétrica (b), e comportamento dos valores calculados e observados, ao longo do tempo (c); considerando apenas as variáveis de entrada relacionadas à topografia da bacia



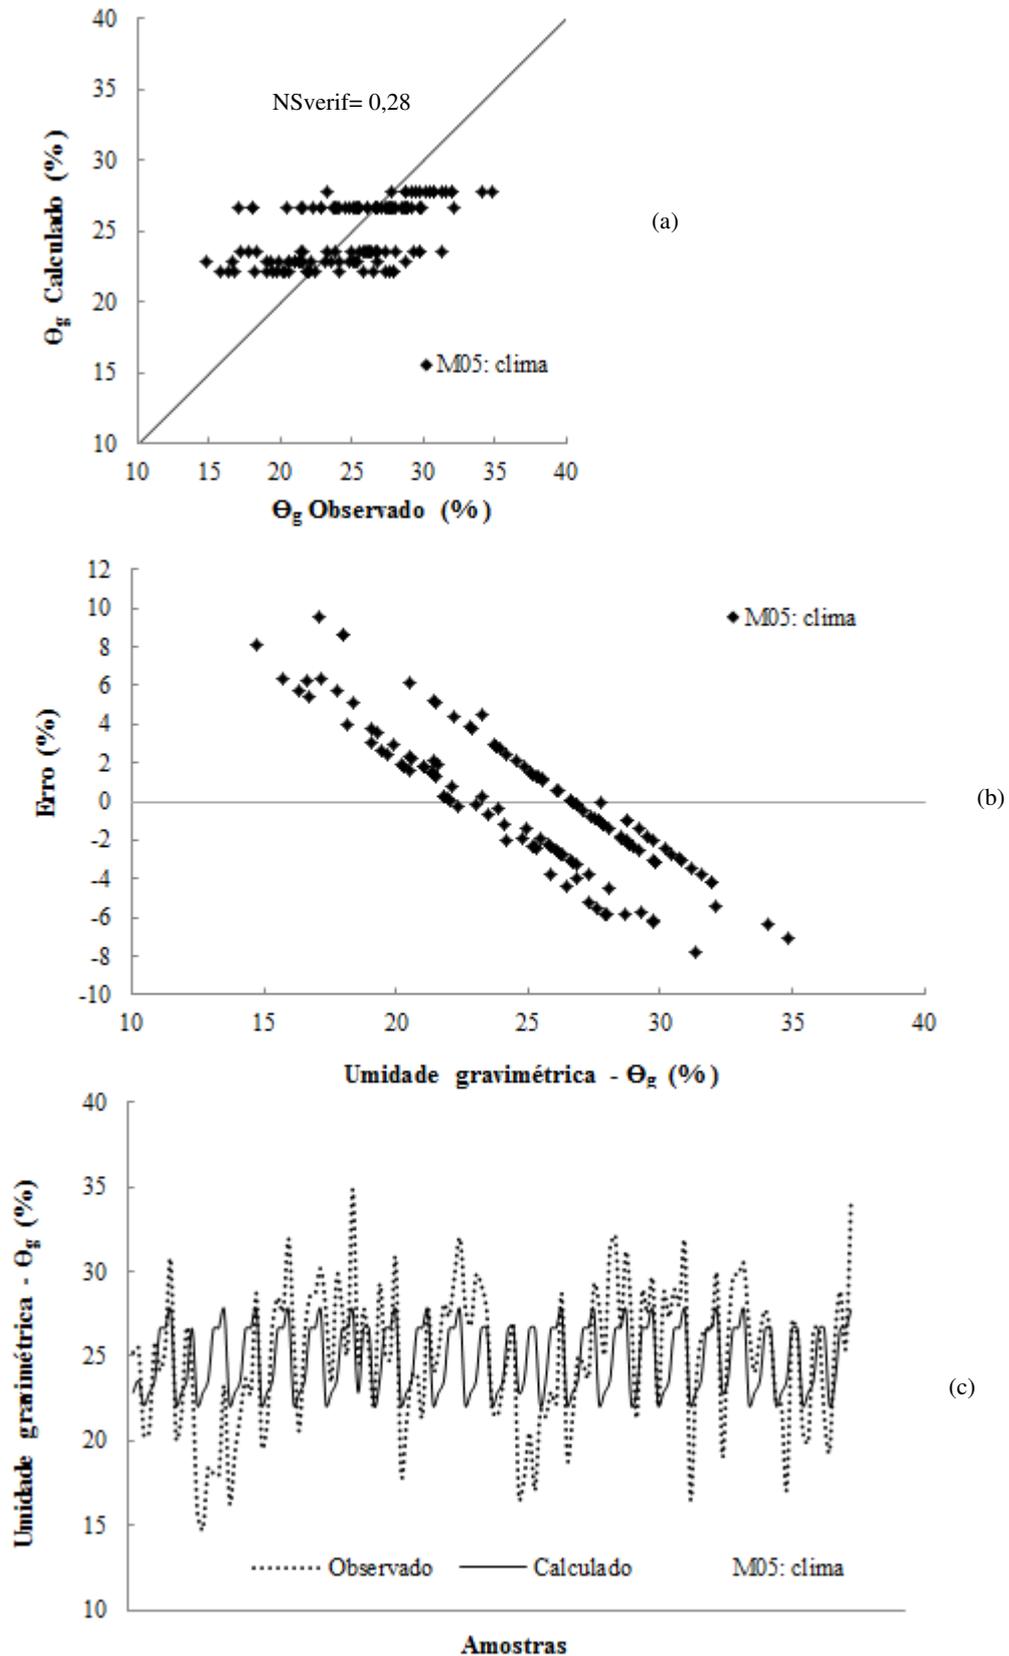
Fonte: autor

Figura 16 – Umidade gravimétrica observada e calculada em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados de umidade gravimétrica (b), e comportamento dos valores calculados e observados, ao longo do tempo (c); considerando apenas as variáveis de entrada relacionadas às propriedades físicas do solo



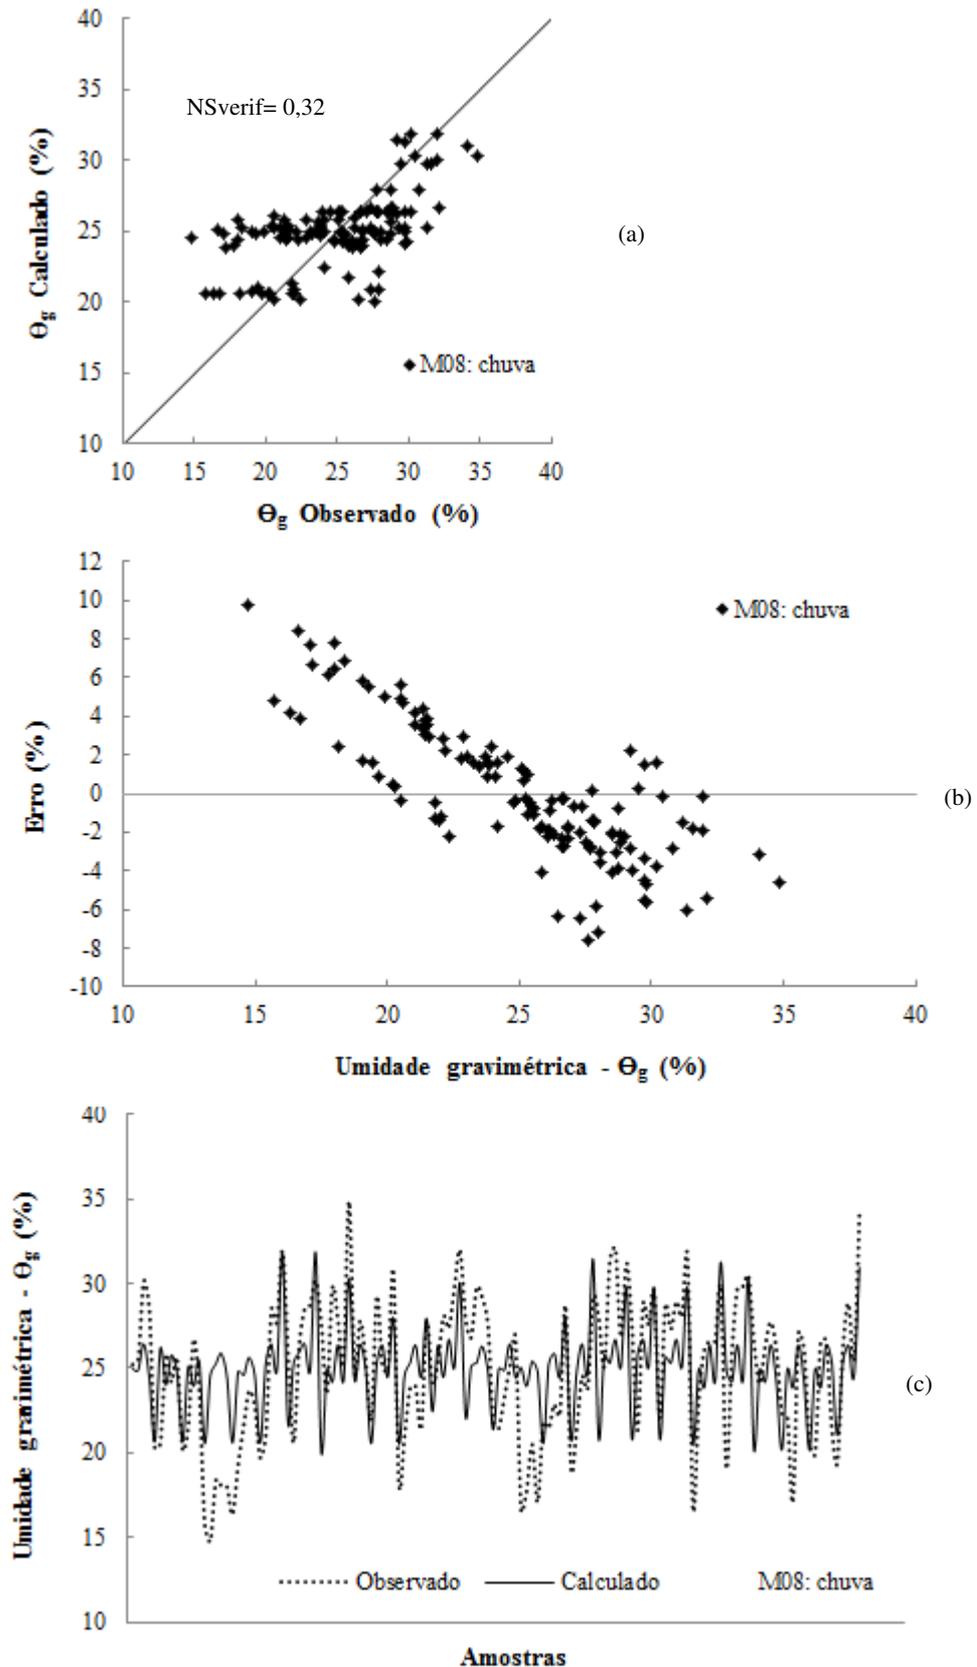
Fonte: autor

Figura 17 – Umidade gravimétrica observada e calculada em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados de umidade gravimétrica (b), e comportamento dos valores calculados e observados, ao longo do tempo (c); considerando apenas as variáveis de entrada relacionadas ao clima da bacia (sem dados de chuva)



Fonte: autor

Figura 18 – Umidade gravimétrica observada e calculada em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados de umidade gravimétrica (b), e comportamento dos valores calculados e observados, ao longo do tempo (c); considerando apenas as variáveis de entrada relacionadas à chuva antecedente às coletas



Fonte: autor

Por outro lado, o NS da rede quando se emprega o modelo M08, relacionado ao grupo das chuvas (chuva de 1, 2, 3, 4, 5, 6, 12, 24, 48, e 72 horas, 5, 10, 15, 20, 25 e 30 dias), foi igual a 0,34 e 0,32 para o treinamento e a verificação, respectivamente. O modelo apresenta melhor ajuste para os valores mais elevados de umidade gravimétrica (Figura 18a), que comumente correspondem ao período do inverno. Os extremos não são adequadamente representados, e o comportamento da umidade gravimétrica ao longo do tempo por vezes apresenta boa relação entre os dados calculados e observados, mas em outras é o oposto do esperado (Figura 18c), o que diminui o desempenho do modelo. De maneira geral, o modelo subestima valores de umidade superiores a 25% e superestima os inferiores (Figura 18b).

Esses resultados demonstram que, para a situação analisada nessa bacia, a utilização somente de informações de chuva antecedente, ou mesmo seu uso conjunto com dados climáticos, não é suficiente para uma estimativa adequada do teor de água no solo, sendo necessário o emprego conjunto de dados relacionados às propriedades físicas do solo e à topografia da bacia para obtenção de resultados mais precisos da variação espacial e temporal do teor de água no solo.

O modelo contendo 38 variáveis de entrada, todas menos as duas chuvas ponderadas, (M70, com 25 neurônios na camada intermediária) apresenta um bom desempenho no treinamento (NS=0,72), mas um desempenho relativamente menor durante a verificação da capacidade de generalização da rede (NS=0,61). Adicionalmente, testou-se uma variação desse modelo, utilizando-se 77 neurônios (conforme sugere HECHT NIELSEN (1990) pela expressão $2n+1$, onde n é o número de variáveis de entrada) na camada intermediária (M72). Nesse caso, a capacidade de generalização da RNA foi superior ao modelo que emprega menor número de neurônios, com NS 0,70 na verificação, embora o desempenho apresentado durante o treinamento tenha sido menor (NS=0,64). Todavia, o tempo requerido para o treinamento dessa rede foi superior ao daquela.

Cabe salientar, ainda, que os modelos que empregam todas as variáveis de entrada, podem estar repetindo informações (presença de variáveis semelhantes) e confundindo a RNA, mesmo tendo mostrado desempenho satisfatório no treinamento e verificação. Comumente, essa característica tende a gerar um decréscimo do desempenho da rede e, por isso, a retirada de algumas variáveis pode acarretar a melhoria desse desempenho (OLIVEIRA et al., 2011). Isso pode ser observado em 16 dos 86 modelos testados (M42, M43, M45 a M47, M49, M53 a M55, M57, M59, M66, M69, M71, M73, e M75), os quais apesar de utilizarem menor número de variáveis de entrada, apresentam melhor desempenho

(maior NS) durante a verificação do modelo em comparação com o M72, que emprega 38 variáveis de entrada. O mesmo pode ser observado em relação ao modelo M70, sendo que, nesse caso, 23 dos 86 modelos analisados (M23, M24, M27 a M29, M42 a M47, M49, M50, M52 a M55, M57 a M59, M62, M66, M68, M69, e M71 a M75) mostram um NS superior ao observado para o modelo com maior número de variáveis de entrada, considerando a fase de verificação dos modelos.

Há que se ponderar, também, que o requerimento de um grande número de variáveis de entrada (38 variáveis) pode ser um fator limitante para a aplicação desses modelos (M70 e M72) na estimativa do teor de água no solo, uma vez que, tais modelos demandam maior dispêndio financeiro e tempo para aquisição das informações de entrada dessas redes, o que dificulta e onera o processo de modelagem. Além disso, a simplicidade de modelos com menor número de variáveis de entrada facilita a interpretação do modelo gerado, bem como, a compreensão da relação entre as variáveis e os resultados obtidos na aplicação do modelo.

Os dois melhores modelos observados (modelos considerados mais adequados para a situação analisada na pesquisa) foram o M69 e o M71, que empregam informações relacionadas à topografia da bacia, às propriedades físicas do solo e à chuva. Nas Figuras 19 e 20 apresenta-se a relação entre a umidade gravimétrica observada e calculada em analogia à reta de ajuste ideal, além do erro (discrepância) entre os valores calculados e observados, e o comportamento dos valores calculados e observados, ao longo do tempo; considerando o processo de verificação dos modelos com melhor desempenho (M69 e M71). Comumente, os dois modelos apresentam um comportamento muito semelhante e um desempenho próximo para os diferentes parâmetros estatísticos analisados, entretanto o M71 possui uma leve melhor distribuição dos erros em torno do eixo zero, indicando que as discrepâncias na estimativa da umidade gravimétrica são menores nesse modelo.

O modelo M69 considera 11 variáveis de entrada: a altitude, a distância do ponto ao trecho mais próximo do rio, a declividade, a tensão da água no solo, o tipo de solo; a densidade do solo, a resistência à penetração no solo para a camada de 0 a 20 cm, as chuvas de 15 e 25 dias, e as chuvas médias ponderadas horárias e chuvas médias ponderadas diárias. Essa rede apresenta NS igual a 0,70 e 0,77, Ea (95) igual a 4,46 e 3,71%, Eam_{ax} de 7,99 e 7,54%, erro média (Ea) de 1,56 e 1,52%, e RMSE igual a 2,08 e 2,01%, para o treinamento e a verificação, respectivamente. O ajuste entre os valores observados e calculados é muito bom, com alguns valores muito próximos (Figura 19a) e, embora alguns extremos não sejam bem representados, os erros são relativamente bem distribuídos (Figura 19b), sendo o número

de valores subestimados e superestimados muito próximo (66 e 68, respectivamente). Essa rede consegue acompanhar, de maneira muito satisfatória, a variação do comportamento da umidade gravimétrica ao longo do tempo (Figura 19c), entretanto alguns extremos são subestimados e outros superestimados.

O modelo M71 diferencia-se do anterior por empregar como entrada o percentual de areia, silte e argila no lugar da variável tipo de solo, tendo portanto 13 variáveis de entrada. Essa rede apresenta NS igual a 0,71 e 0,77, Ea (95) igual a 4,11 e 3,63%, Eamáx de 8,08 e 8,61%, erro média (Ea) de 1,51 e 1,54%, e RMSE igual a 2,05 e 2,02% para o treinamento e a verificação, respectivamente. A exemplo do anterior, esse modelo também apresenta um ajuste muito bom entre os valores observados e calculados, estando alguns desses valores muito próximos da reta do ajuste ideal (Figura 20a). Em contrapartida, alguns extremos não estão bem representados, embora os erros apresentem-se relativamente bem distribuídos em torno do eixo zero (Figura 20b); sendo o número de valores subestimados e superestimados muito próximos (66 e 68, respectivamente). Essa RNA também acompanha, muito satisfatoriamente, a variação do comportamento da umidade gravimétrica ao longo do tempo (Figura 20c), mas conforme já comentado alguns extremos não são bem representados.

Não obstante, é importante destacar que a determinação do percentual de areia, silte e argila, para cada ponto de interesse, demanda maior tempo e recursos financeiros para coleta e processamento das variáveis de entrada; se comparadas ao emprego da variável de entrada tipo de solo. Essa última pode ser obtida diretamente de um mapa de tipo de solo previamente construído, o que torna mais simplificado o processo de aquisição dessa informação para um novo ponto de interesse.

Ambos os modelos requerem coletas e medições em campo para verificação de variáveis relacionadas às propriedades físicas do solo (densidade do solo e resistência à penetração no solo, além da granulometria para o modelo M71), específicas para cada ponto de interesse. Essa necessidade depende tempo e recursos financeiros e, por isso, em alguns casos pode ser interessante a utilização de modelos mais simplificados, que demandem pouca ou nenhuma coleta em campo. Tais modelos poderiam ser empregados nas situações em que a precisão requerida para a estimativa do teor de água no solo não seja excessivamente rigorosa, ou para os casos em que não existam muitos dados monitorados no local de interesse, ou ainda, quando não há muitos recursos disponíveis para obtenção dessas informações.

Figura 19 – Umidade gravimétrica observada e calculada em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados de umidade gravimétrica (b), e comportamento dos valores calculados e observados, ao longo do tempo (c); considerando o modelo com melhor desempenho M69

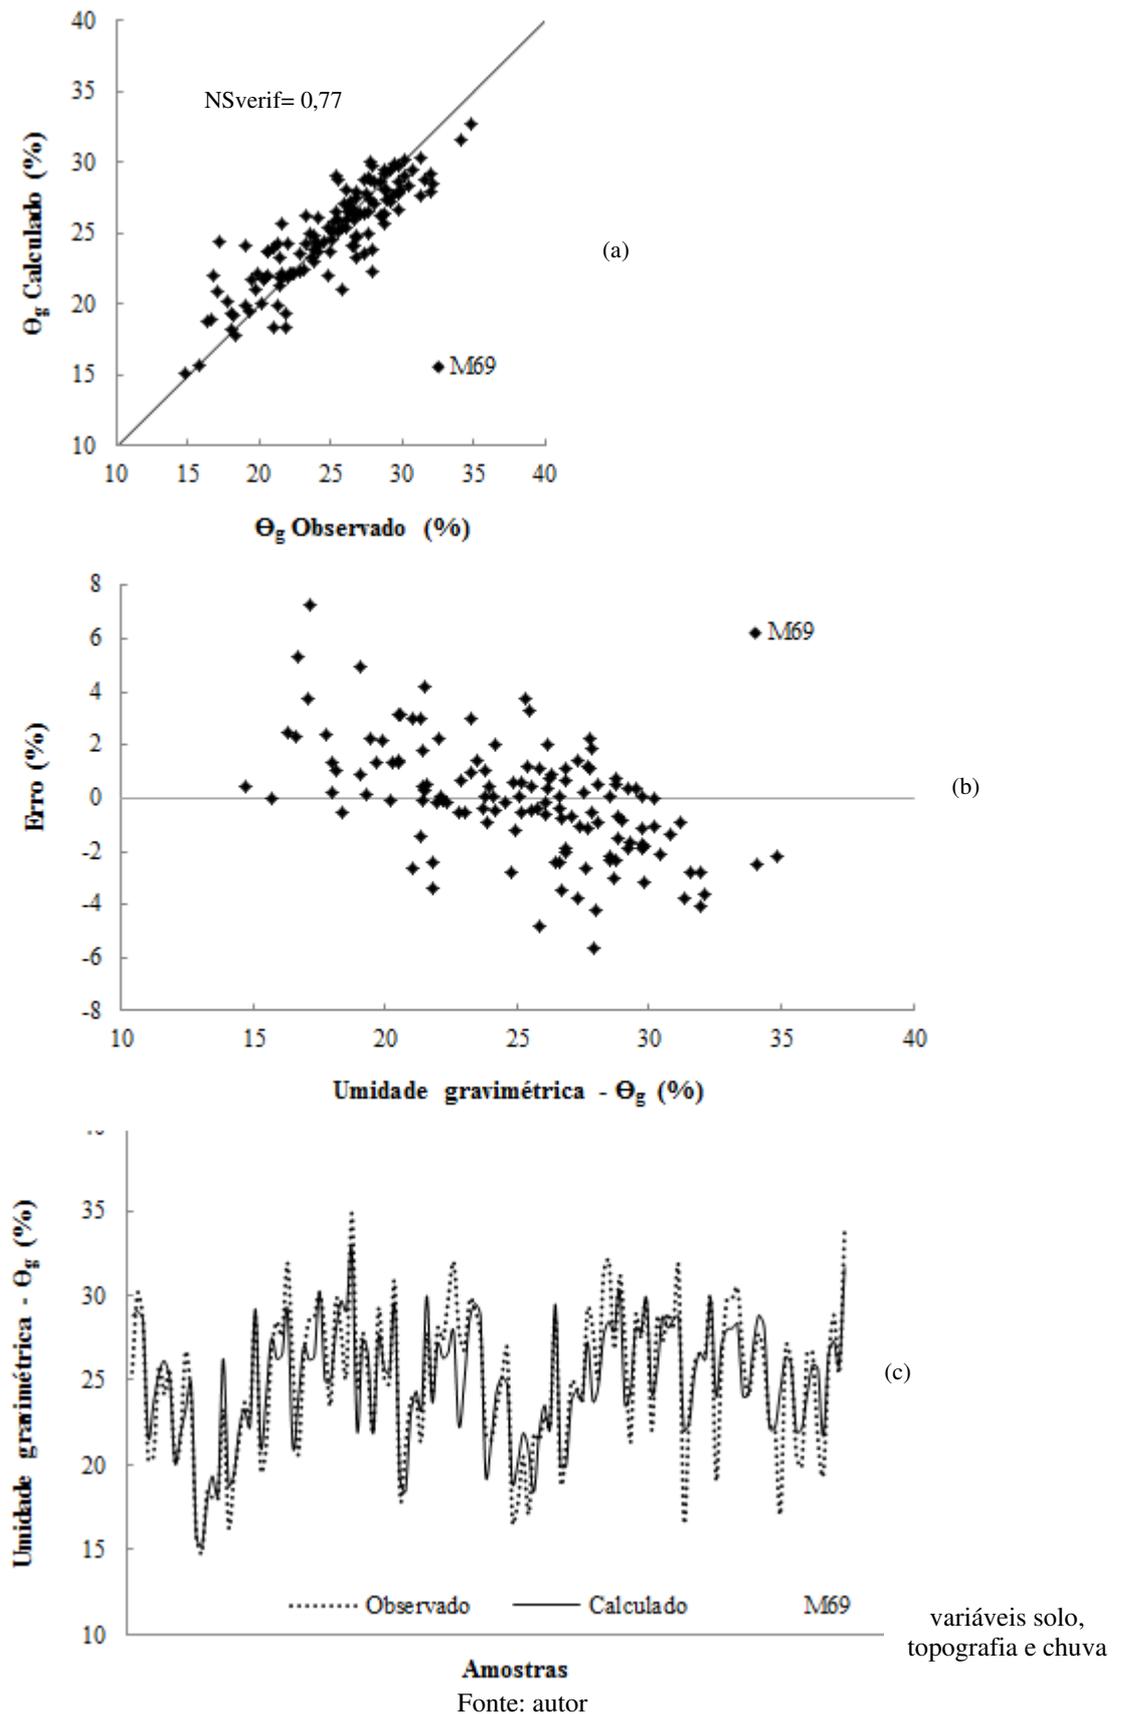
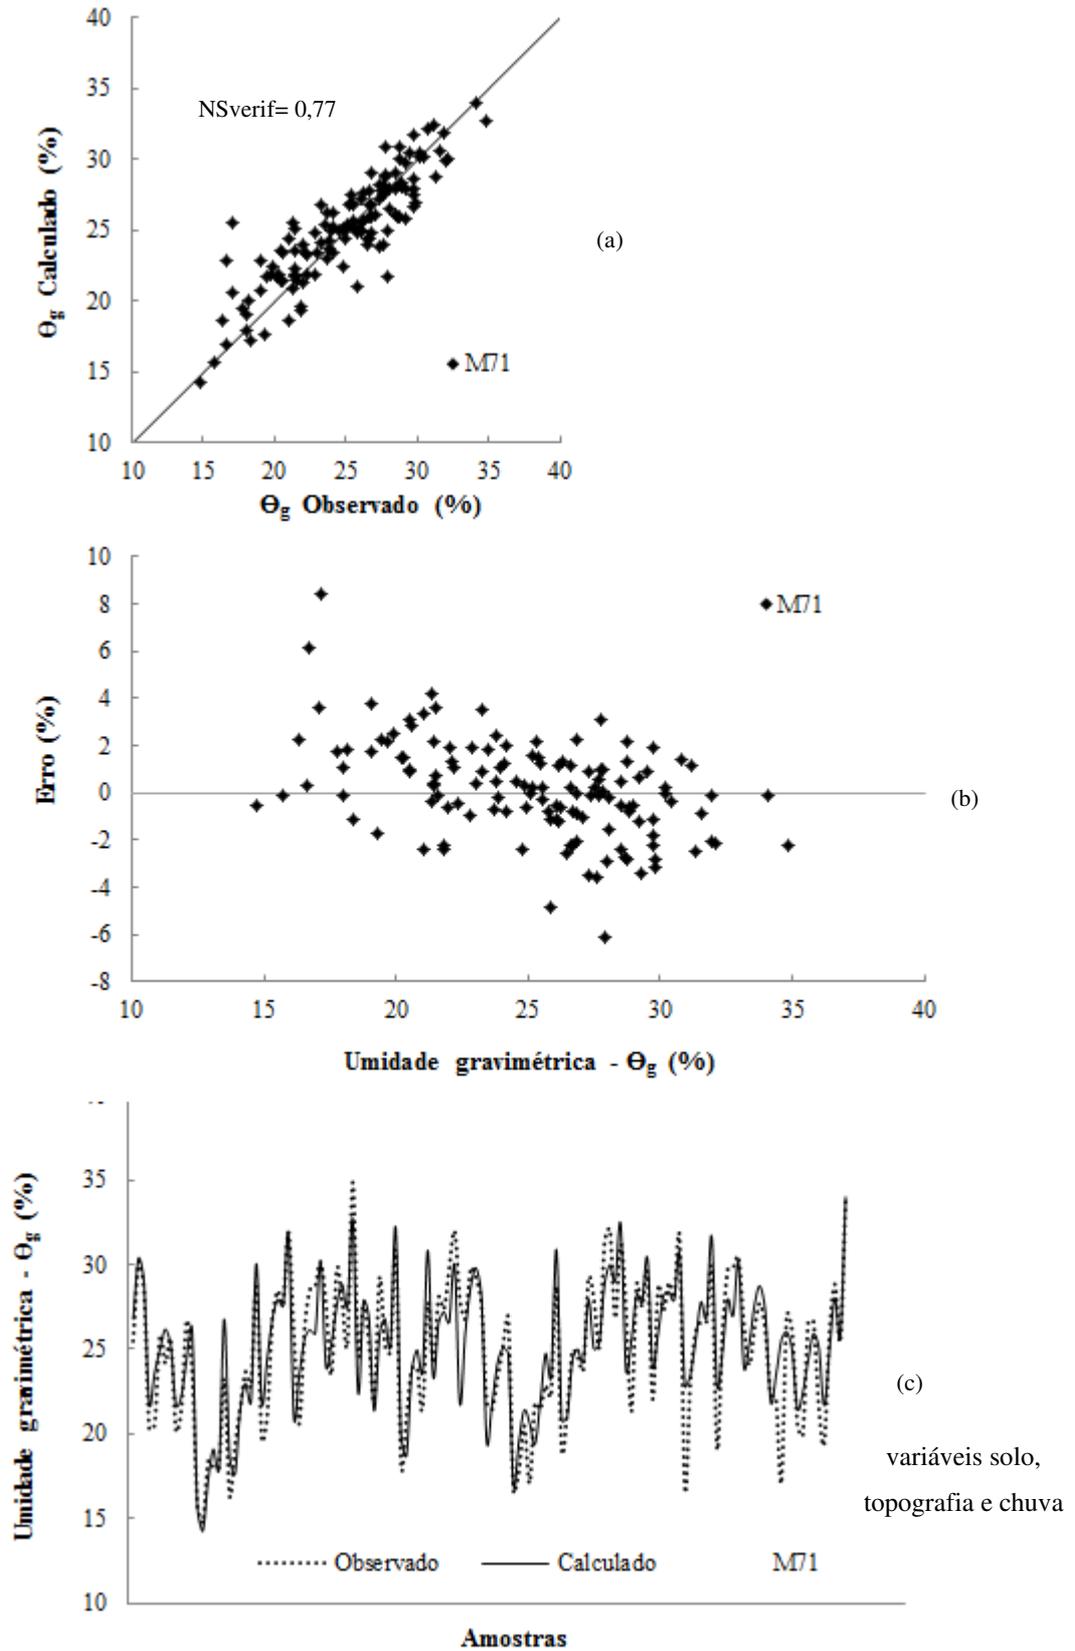


Figura 20 – Umidade gravimétrica observada e calculada em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados de umidade gravimétrica (b), e comportamento dos valores calculados e observados, ao longo do tempo (c); considerando o modelo com melhor desempenho M71



Para atender essa necessidade, testou-se o desempenho dos modelos M14 e M78, que consideram apenas variáveis de entrada facilmente obtidas, relacionadas à topografia da bacia (altitude, declividade e desnível), e às chuvas (chuvas de 1, 2, 3, 4, 5, 6, 12, 24, 4 e 72 horas, 5, 10, 20, 25 e 30 dias para o M14, e além dessas, chuva média ponderada horária e chuva média ponderada diária para o M78).

Nas Figuras 21 e 22 são apresentadas a relação entre os dados calculados e observados de umidade gravimétrica em analogia à reta de ajuste ideal, além da relação entre o erro verificado entre os valores calculados e observados (discrepância), e o comportamento dos valores calculados e observados, ao longo do tempo; considerando os modelos M14 e M78, respectivamente. Nesse caso, observa-se que o desempenho dos modelos diminui em relação aos dois modelos definidos como melhores (M69 e M71), mas ainda é um desempenho considerado de médio a bom (Figuras 21a e 22a). Além disso, esses modelos apresentam maior facilidade para obtenção das variáveis de entrada requeridas.

Em geral, os erros verificados durante o treinamento são levemente menores para o modelo M14, mas, por outro lado, no processo de verificação da capacidade de generalização das redes, o modelo M78 mostrou menores erros. Para o M14, o NS é igual a 0,66 e 0,52, o Ea (95) é 4,66 e 5,73%, o Eamax é 7,26 e 6,63%, enquanto que o erro média (Ea) é 1,74 e 2,36%, e o RMSE é 2,22 e 2,91%; considerando o treinamento e a verificação, respectivamente. Já o M78 apresenta NS igual a 0,63 e 0,65, Ea (95) de 4,64 e 4,59%, Eamax de 8,75 e 6,43%, erro médio (Ea) de 1,76 e 1,96%, e RMSE igual a 2,32 e 2,47; para o treinamento e a verificação da rede, respectivamente.

Ambos os modelos tendem a subestimar os valores de umidade gravimétrica superiores a 25%, e a superestimar a umidade gravimétrica inferior a esse percentual (Figuras 21b e 22b), embora a discrepância do M78 mostre-se relativamente menor (Figura 22b). De maneira geral, o modelo M78 consegue representar melhor a variação da umidade gravimétrica ao longo do tempo, apesar de não ajustar satisfatoriamente os extremos (Figura 22c). O M14 além de não representar adequadamente os picos, apresenta, em algumas vezes, divergências no comportamento da umidade gravimétrica; delimitando a existência de alguns picos de máximo em lugar de alguns mínimos e vice-versa (exemplos em destaque na cor cinza, Figura 21c).

Figura 21 – Umidade gravimétrica observada e calculada em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados de umidade gravimétrica (b), e comportamento dos valores calculados e observados, ao longo do tempo (c); considerando o modelo com melhor desempenho M14 com dados de topografia e chuva

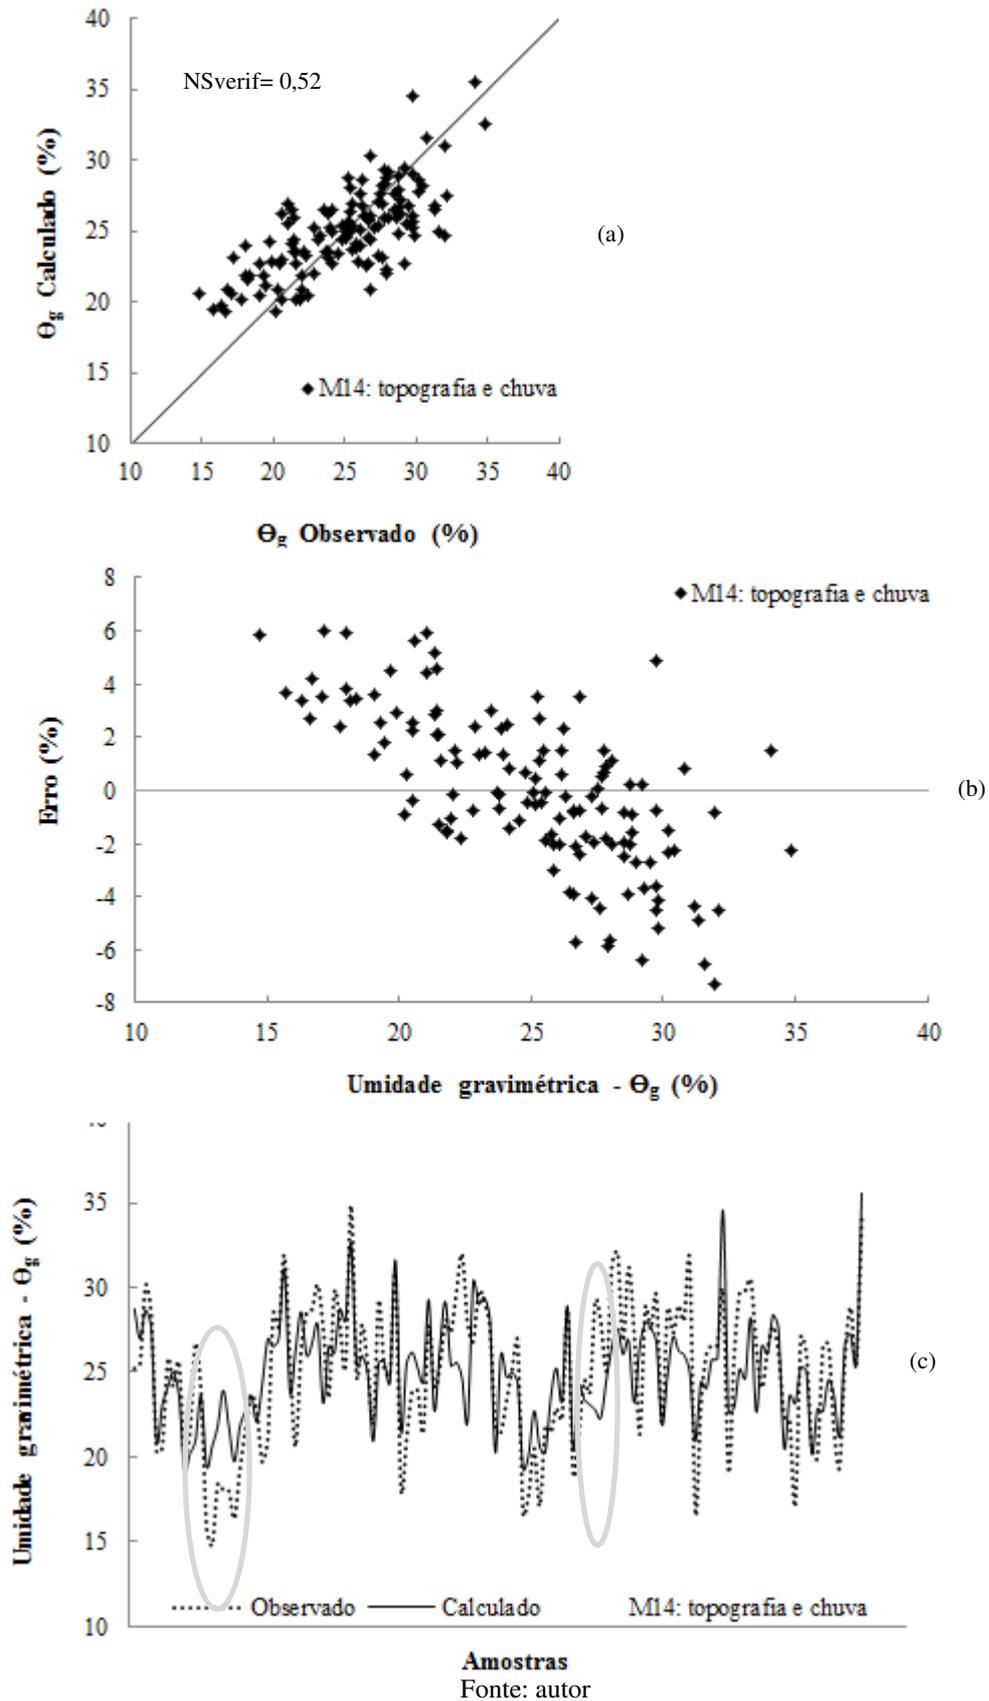
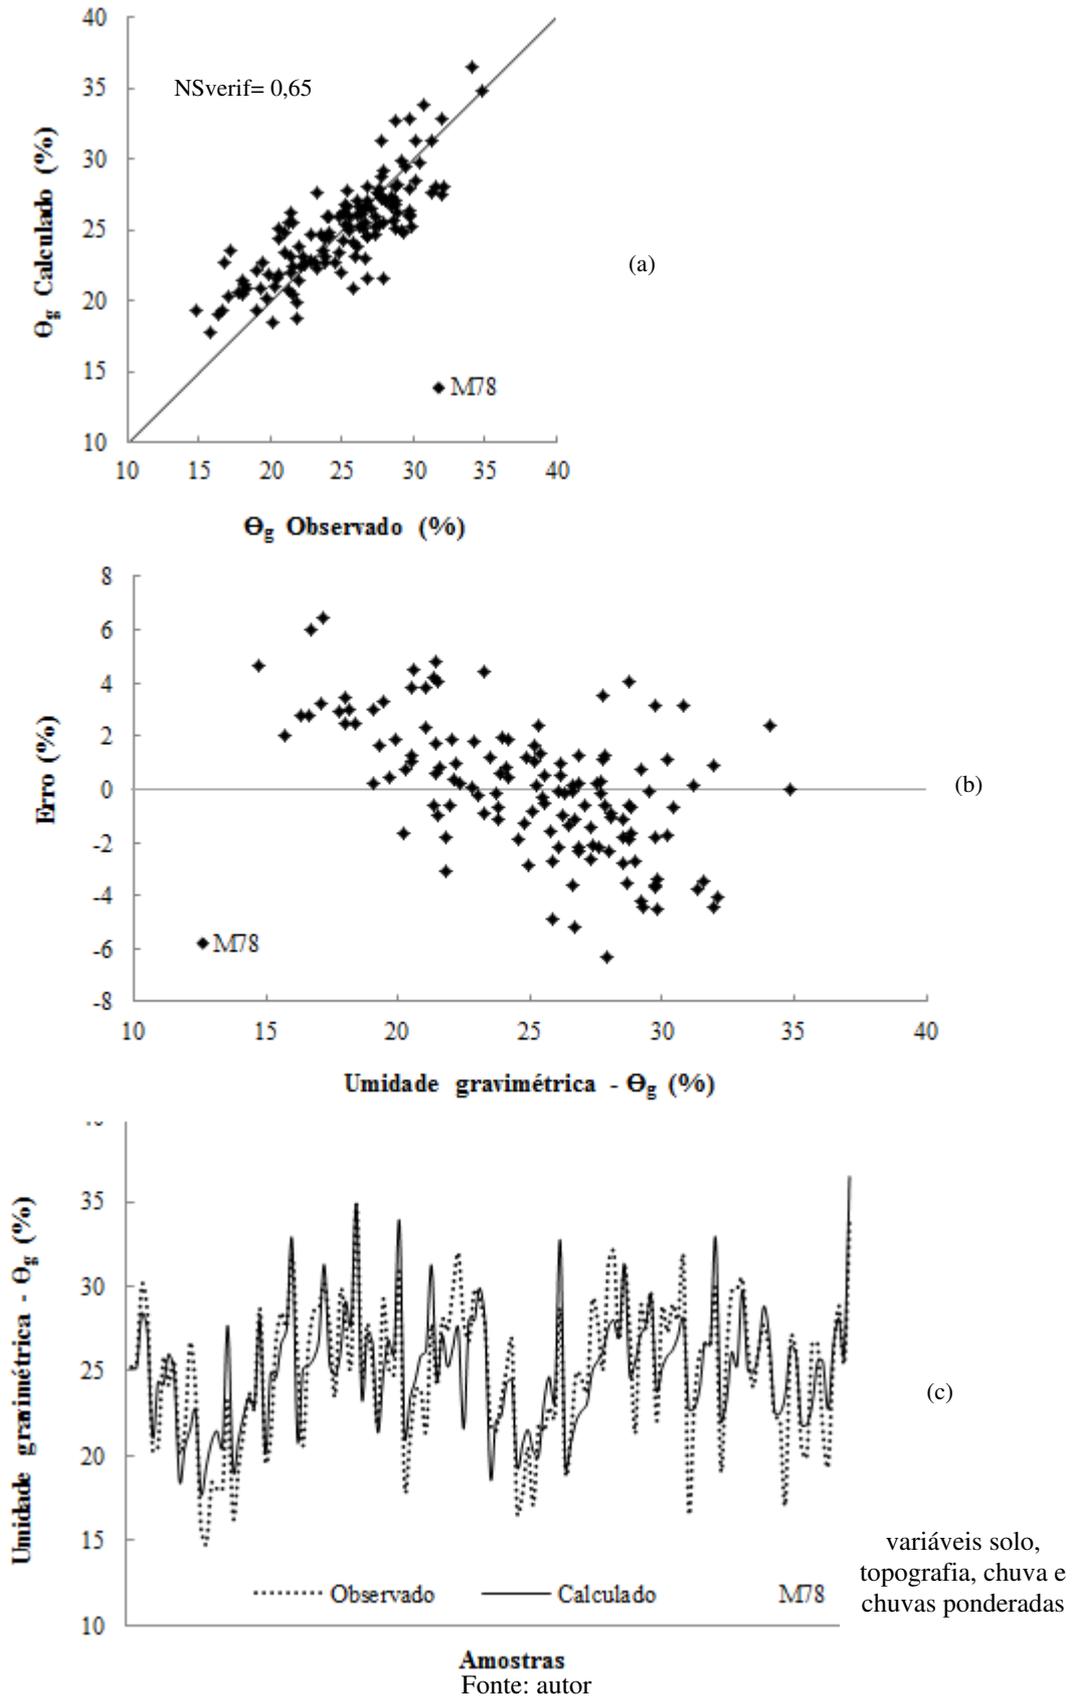


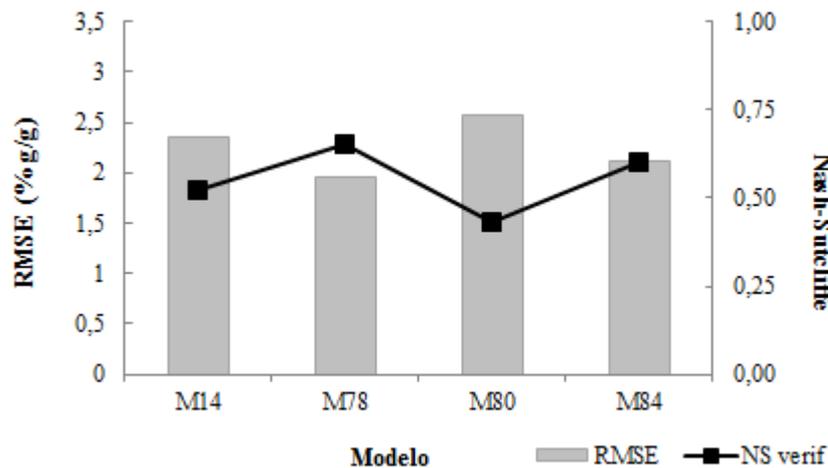
Figura 22 – Umidade gravimétrica observada e calculada em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados de umidade gravimétrica (b), e comportamento dos valores calculados e observados, ao longo do tempo (c); considerando o modelo com melhor desempenho M78 com dados de topografia e chuva e chuva média ponderada horária e chuva média ponderada diária.



Adicionalmente, foram testadas variações nos melhores modelos obtidos (M69 e M79) e também naqueles modelos com obtenção mais facilitada das variáveis de entrada (M14 e M78). Essas alterações envolveram o acréscimo de algumas variáveis ou a supressão de outras, na busca de melhorias no desempenho desses modelos. Comumente, observa-se que a adição das informações climáticas (sem dados de chuva) promove um decréscimo na eficiência dos modelos, o que já era esperado, tendo-se em vista que a análise de grupos mostrou baixa influência dessas variáveis sobre a estimativa do teor de água no solo.

Essa característica pode ser observada na Figura 23, onde se apresenta o RMSE e o NS da verificação nos modelos simplificados M78 e M14, e as modificações originadas pela introdução das variáveis de entrada do tipo climáticas. A utilização da chuva ponderada no modelo M78 melhora significativamente o NS e o RMSE em relação ao M14, que emprega as chuvas sem ponderação. Por outro lado, a introdução da variável evapotranspiração de referência reduz o NS e eleva o RMSE para o M80 em analogia ao M78 ou ao M14. Já o emprego das demais variáveis climáticas (temperatura do ar máxima e temperatura do ar mínima, umidade relativa do ar máxima e umidade relativa do ar mínima, pressão atmosférica, velocidade do vento e radiação solar) associadas à evapotranspiração de referência, melhora o desempenho do modelo M84 em relação ao M14, mas apresenta uma leve piora no referente ao M78.

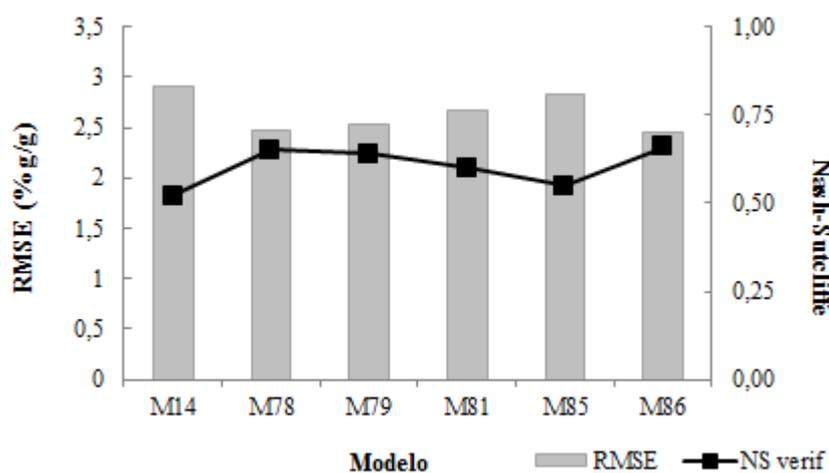
Figura 23 – Variação do desempenho dos modelos em função da adição das variáveis de entrada do tipo climáticas - M14 (modelo com variáveis topográficas e chuvas), M78 (igual M14 + chuvas ponderadas), M80 (igual ao M14 + ET0), M84 (igual ao 14 + todas variáveis climáticas). A chuva ponderada corresponde a chuva média ponderada horária, chuva média ponderada diária, e chuva de 15 dias e 25 dias.



Fonte: autor

Na Figura 24 é apresentada a variação do desempenho na verificação dos modelos M14 e M78 em função da adição das variáveis de entrada climáticas e do tipo de solo. A adição de uma variável simplificada representando o grupo das propriedades físicas do solo (tipo de solo), em conjunto com os mesmos dados topográficos do M14 e M78, e somadas aos dados de chuva de 15 e 25 dias e às chuvas médias ponderadas horárias e diárias, melhora em pequena proporção o desempenho do modelo M78 e em maior proporção a eficiência do M14. Nesse cenário (modelo M86), o NS é igual a 0,61 no treinamento e 0,66 na verificação contra um NS de 0,52 e 0,65 para o M14 e M78, respectivamente. No entanto, aumenta também a dificuldade de obtenção das variáveis de entrada, já que esse modelo exige a construção de um mapa de tipo de solo da área de interesse. O modelo M79 (semelhante ao M14 + mesmas variáveis climáticas do M84 + o tipo de solo) apresenta melhor desempenho em relação ao M14, mas uma leve queda do NS e um aumento do RMSE em analogia ao M78, enquanto que o M81 (= M79, mas sem pressão atmosférica, velocidade do vento e radiação solar) decresce a qualidade do M78, mas melhora a do M14. Já o modelo M85 (= M79, com adição do período do ano e da temperatura da relva) diminui o desempenho do M78 e quase não altera o do M14.

Figura 24 –Variação do desempenho dos modelos em função da adição das variáveis de entrada do tipo climáticas e tipo de solo- M14 (modelo com variáveis topográficas e chuvas), M78 (igual M14 + chuvas ponderadas), M79 (igual ao M14 + tipo de solo), M81 (igual ao 79 - pressão, vento e ET0), M85 (igual ao M79+estação climática + temperatura na superfície do solo), M86 (igual ao M78 + tipo de solo). A chuva ponderada corresponde à chuva média ponderada horária, chuva média ponderada diária e chuva de 15 dias e 25 dias.



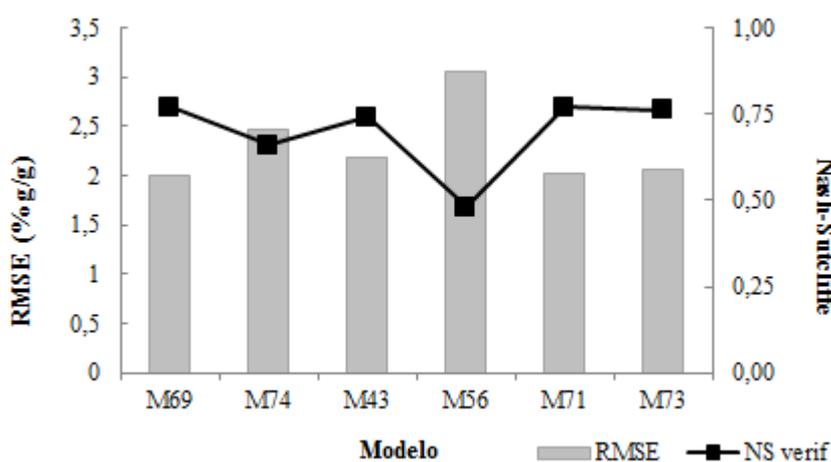
Fonte: autor

O mesmo pode ser expresso em relação aos melhores modelos em relação à variável resistência à penetração no solo para as camadas de 20 a 40 cm. Nesse cenário, percebe-se que o M74 apresenta pior desempenho (RMSE= 2,46% e NS=0,66) em analogia ao M69

(RMSE=2,01 g/g e NS=0,77), quando suprimida naquele a variável resistência à penetração no solo entre 20 e 40 cm. Semelhantemente, o modelo M43 tem seu desempenho diminuído significativamente (RMSE=2,18% e NS=0,74) quando essa mesma variável é retirada no modelo M56 (RMSE=3,05% e NS=0,48). Da mesma forma, a supressão da resistência à penetração no solo para as camadas de 20 a 40 cm presente no modelo M71 (RMSE=2,02% e NS=0,77), provoca um decréscimo no desempenho na verificação do modelo M73 (RMSE=2,07% e NS=0,76), embora menos significativo (Figura 25).

Outras variáveis relacionadas às propriedades físicas do solo também mostraram decréscimo no desempenho dos melhores modelos, conforme pode ser visualizado no APÊNDICE C, embora alguns deles tenham apresentado desempenhos satisfatórios, mesmo sendo inferior aos melhores modelos encontrados. Por outro lado, o uso de uma ou outra variável relacionada à topografia, comumente mantém o mesmo desempenho do modelo ou ocasiona um decaimento muito pequeno, sendo opcional a escolha pelo emprego de uma ou outra.

Figura 25 – Variação do desempenho dos modelos em função da adição de variáveis de entrada - M69 (características topográficas sem desnível, tipo de solo, densidade e resistência 0 a 10 cm, chuvas ponderadas), M74 (igual ao M69 + resistência penetração 20 a 40 cm), M43 (igual ao M74 + granulometria+chuvas - chuva ponderada), M56 (igual ao M43 - resistência a penetração 0 a 20 cm), M71 (igual ao M43 -tipo de solo+chuva ponderada), M73(igual ao M71 - resistência ao penetrômetro 0 a 20 cm). A chuva ponderada corresponde a chuva média ponderada horária, chuva média ponderada diária e chuva de 15 dias e 25 dias.



Fonte: autor

De maneira geral, pode-se dizer que a importância de uma dada variável de entrada na melhoria do desempenho de um modelo RNA depende do conjunto de variáveis utilizadas, ou seja, a influência conjunta de todas as variáveis e os efeitos que uma gera na outra define sua importância na estimativa do teor de água no solo. Assim, para um determinado modelo, a

introdução ou a supressão de uma dada variável poderá alterar significativamente o desempenho do modelo (melhorar ou piorar), mas também poderá mostrar-se pouco relevante para outro modelo que possua entradas diferentes. De fato, já se afirmava anteriormente que a estimativa do teor de água no solo é ainda um grande desafio, isso em razão de sua variação espacial e temporal, que é influenciada pela interferência conjunta dos diferentes fatores que afetam esse teor de água.

5.4 Análise de sensibilidade e de importância das variáveis de entrada dos modelos RNA

Foi realizada uma análise de sensibilidade e de importância das variáveis de entrada dos modelos, conforme já detalhado na metodologia. Essa análise confirma que a importância de uma dada variável depende do conjunto das variáveis com as quais ela é utilizada. A Tabela 9 apresenta os resultados da análise de sensibilidade e de importância para os cinco modelos finais selecionados, incluindo os melhores modelos (M69 e M71) e aqueles cujas variáveis de entrada são mais fáceis de ser obtidas (M14, M78 e M86).

Para os melhores modelos (M69 e M71), a tensão de água no solo, a chuva de 15 dias e a chuva média ponderada horária são as três variáveis mais importantes, enquanto que a densidade do solo é a menos relevante entre as variáveis utilizadas. Já para os modelos mais simples, a variável menos importante é a declividade, e as três mais importantes dependem do modelo considerado. Para o M14, as três variáveis principais são as chuvas de 12 horas, 15 dias e 6 horas, respectivamente; enquanto que para o M78 as mais importantes são as chuvas de 15 dias e 1 dia, e a altitude do ponto. Por outro lado, para o M86, as três variáveis de entrada mais relevantes estão relacionadas à chuva (chuvas de 15 dias e 1 dia, e chuva média ponderada horária), sendo que a variável relacionada à topografia (altitude) aparece na 5ª posição de importância.

De fato já se esperava que as chuvas (ou pelo menos uma parcela delas) estivessem entre as variáveis mais importantes dos modelos, isso porque o teor de água no solo é, primeiramente, uma resposta direta das entradas de água na bacia. Da mesma forma, a tensão de água no solo é uma resposta direta dos teores de água presentes nesse solo, então é plausível que essa variável seja uma das mais influentes do modelo. Existe uma relação bastante conhecida entre a tensão de água no solo e a umidade, que é expressa pela curva de retenção de água no solo. É comum medir-se a tensão de água no solo para estimar-se o teor de água no solo, porém para a estimativa deste teor para toda uma bacia hidrográfica exigiria

a instalação de vários tensiômetros. Porém, nesta pesquisa foram usados os dados de apenas um tensiômetro para estimar a umidade dos 26 pontos distribuídos nesta bacia de 78 km².

Em geral, pelo menos uma variável topográfica encontra-se entre as 7 primeiras em termos de importância, o que também é coerente, já que essas variáveis exercem influência significativa sobre a distribuição espacial do teor de água no solo, havendo maior armazenamento de água nas regiões menos elevadas. Outra variável que aparece entre as 6 principais (nos modelos que empregam tais variáveis) está relacionada ao solo, confirmando que as propriedades físicas do solo afetam o armazenamento e a distribuição da água nesse solo, principalmente nos solos que apresentam partículas coloidais (mais finas), caracterizadas pela presença de íons e, portanto, fortemente atrativas das moléculas de água.

A análise de sensibilidade das variáveis de entrada mostrou que nem sempre os modelos conseguem reproduzir o que deveria ocorrer no ambiente natural (assinalados em cinza na tabela), ou seja, muitas vezes uma variável demonstra sensibilidade negativa quando deveria ser positiva, e vice-versa. Dessa forma, por exemplo, um valor negativo em uma variável de chuva indicaria que o teor de água tenderia a diminuir com o aumento dessa variável, mas na prática, sabe-se que nos ambientes naturais isso ocorre de forma contrária, ou seja, o teor de água aumenta à medida que aumentam as chuvas, já que a disponibilidade de água é maior.

No referente aos melhores modelos, observa-se que o M69 apresenta 4 das 11 variáveis analisadas com sensibilidade divergente em relação ao que ocorreria no ambiente natural; enquanto que o M71 esse número é um pouco menor (5 das 14 variáveis são divergentes). Já os modelos mais simplificados mostram uma tendência maior de divergência. Assim, para o M14, 11 das 19 variáveis apresentam sensibilidade diferente da esperada no ambiente natural, o M78 possui 5 das 7 variáveis com divergência em relação ao comportamento esperado, por último, o M86 apresenta divergência na sensibilidade para 4 das 8 variáveis de entrada utilizadas. Para esses modelos mais simples, esse aumento no número de variáveis divergentes é também reflexo da diminuição do desempenho desses modelos em relação àqueles.

Tabela 9- Resultados da análise de sensibilidade e importância das variáveis de entradas dos 5 modelos finais selecionados (M69, M71, M14, M78 e M86)

Modelo	Ordem	Variável	Sensibilidade	Importância
M69	1%	Tens Man (bar)	-0,273	2,368
	2%	Ch Ac 15d	-0,253	1,955
	3%	Ch Pond hor	0,131	0,797
	4%	Altitude (m)	-0,28	0,657
	5%	Ch Pond dia	0,095	0,587
	6%	Tipo de solo	0,118	0,566
	7%	Distancia rio (m)	0,094	0,548
	8%	Ch Ac 25d	-0,174	0,543
	9%	Declividade	0,109	0,249
	10%	Res. Pen. 0 a 19cm	-0,04	0,089
	11%	Densidade solo	-0,083	0,046
M71	1%	Tens Man (bar)	-0,317	2,987
	2%	Ch Ac 15d	-0,16	1,315
	3%	Ch Pond hor	0,158	1,112
	4%	Ch Ac 25d	-0,171	0,466
	5%	Granul. Silte (%)	0,096	0,382
	6%	Ch Pond dia	0,089	0,368
	7%	Distancia rio (m)	0,05	0,353
	8%	Res. Pen. 0 a 19cm	-0,101	0,287
	9%	Granul. Areia (%)	-0,023	0,151
	10%	Granul. Argila (%)	0,057	0,133
	11%	Altitude (m)	-0,13	0,115
	12%	Declividade	0,059	0,091
	13%	Res. Pen. 20 a 40cm	0,073	0,055
	14%	Densidade solo	-0,006	0,008
M14	1%	Ch Ac 12h	0,207	2,133
	2%	Ch Ac 15d	-0,35	1,946
	3%	Ch Ac 6h	-0,206	1,358
	4%	Ch Ac 10d	-0,027	1,021
	5%	Ch Ac 24h	0,089	0,631
	6%	Altitude (m)	-0,339	0,529
	7%	Ch Ac 2h	-0,081	0,478
	8%	Ch Ac 20d	-0,206	0,432
	9%	Ch Ac 5h	-0,096	0,405
	10%	Ch Ac 72h	-0,006	0,346
	11%	Ch Ac 1h	0,061	0,25
	12%	Desnível (m)	0,101	0,222
	13%	Ch Ac 48h	0,044	0,199
	14%	Ch Ac 30d	0,017	0,172
	15%	Ch Ac 25d	-0,064	0,148
	16%	Ch Ac 4h	0,053	0,148
	17%	Ch Ac 3h	-0,052	0,106
	18%	Ch Ac 5d	-0,012	0,096
	19%	Declividade	0,066	0,06
M78	1%	Ch Ac 15d	-0,366	3,023
	2%	Ch Pond dia	0,285	2,393
	3%	Altitude (m)	-0,348	0,835
	4%	Ch Ac 25d	-0,207	0,637
	5%	Desnível (m)	0,053	0,436
	6%	Ch Pond hor	-0,019	0,281
	7%	Declividade	0,078	0,1
M86	1%	Ch Ac 15d	-0,417	2,909
	2%	Ch Pond dia	0,309	2,546
	3%	Ch Pond hor	0,201	1,307
	4%	Ch Ac 25d	-0,167	0,502
	5%	Altitude (m)	-0,295	0,492
	6%	Tipo de solo	0,091	0,278
	7%	Desnível (m)	0,051	0,096
	8%	Declividade	0,023	0,075

Legenda:
 indica que o modelo não consegue representar adequadamente o que deveria ocorrer no ambiente real
 + = aumenta umidade quanto > variável
 - = diminui umidade quanto > variável

Essa não correspondência é devido a um mecanismo interno do modelo, que procura compensar determinadas variáveis, ajustando os pesos de maneira a obter melhor desempenho. Assim sendo, no processo de busca da solução, uma dada variável pode receber um peso muito elevado, o que requer que a outra receba um valor negativo para compensar a primeira, uma vez que ambas influenciam a mesma saída. Na realidade, o sentido físico talvez requeresse que o peso da segunda variável fosse positivo. Esta inversão de sinais pode ser responsável, em muitos casos, pela inversão da sensibilidade.

6 CONCLUSÕES E RECOMENDAÇÕES

Esta pesquisa investigou a possibilidade de se estimar a variação espacial e temporal do teor de água no solo, a partir de abordagens baseadas em RNAs e utilizando informações climáticas e de chuva, além das propriedades físicas do solo e topográficas da bacia. Ao mesmo tempo, pretendeu-se identificar as variáveis de entrada de maior importância para essa estimativa.

A partir dos resultados encontrados pode-se dizer que é possível estimar a umidade do solo, com boa eficiência (NS=0,77, modelos M69 e M71), empregando dados topográficos da bacia, propriedades físicas do solo e dados de chuva, para a área em estudo. As informações climáticas, por outro lado, não afetam significativamente essa estimativa (NS=0,28 para M05), podendo até diminuir a eficiência do modelo (NS=0,68 para o M83 em comparação com o M71).

Também é plausível a determinação dos fatores mais importantes na estimativa do teor de água no solo, através da realização de uma análise de sensibilidade das variáveis de entrada das RNAs. Nos dois melhores modelos desenvolvidos (M69 e M71), a tensão de água no solo, a chuva de 15 dias e a chuva média ponderada horária são as três principais variáveis dos modelos e a densidade do solo é a menos importante. Já para os modelos mais simples (M14, M78 e M86), a variável menos importante é a declividade e as três mais importantes dependem do modelo considerado (chuvas de 12 horas, 15 dias e 6 horas para o M14, chuvas de 15 dias e 1 dia, e a altitude do ponto para o M78, e chuvas de 15 dias e 1 dia, e chuva média ponderada horária para o M86). Por outro lado, a análise de sensibilidade demonstrou que nem sempre os modelos conseguem reproduzir o que deveria ocorrer no ambiente natural, apresentando uma sensibilidade negativa do teor de água em função do aumento da variável quando esta deveria ser positiva, e vice-versa.

Cabe destacar, entretanto, que a importância de uma dada variável no desempenho de um modelo RNA depende do conjunto de variáveis utilizadas, ou seja, a influência conjunta de todas as variáveis e os efeitos que uma gera na outra definirá sua relevância na estimativa do teor de água no solo. Portanto, uma variável mais importante em um dado modelo poderá ser menos relevante quando associada a outro conjunto de variáveis, em um modelo diferente.

Desse modo, não é possível estabelecer com exatidão quais variáveis seriam as mais sensíveis e importantes para todos os modelos com RNAs para estimativa do teor de água no solo, mas sim, é possível dizer que as variáveis físicas do solo e a chuva demonstram grande

influência na estimativa desse teor e que as variáveis climáticas (sem a chuva) não mostram grande interferência.

Da mesma forma, a utilização de muitas variáveis de entrada não gera, necessariamente, o melhor desempenho do modelo, pois uma variável pode mascarar a outra e, até mesmo, atrapalhar a eficiência do modelo (NS=0,70 para o modelo M72 e NS=0,61 para o M71, que empregam 40 variáveis de entrada). Além disso, o custo financeiro e o dispêndio de tempo para aquisição dessas variáveis será muito maior, bem como, a dificuldade de interpretação dos resultados em função de cada variável de entrada.

Alternativamente, o usuário que não possua muitas informações disponíveis e/ou recursos para obtê-las poderá estimar o teor de água no solo utilizando modelos mais simplificados (M14, M78 e M86), que empregam dados de chuva monitorados e informações extraídas de mapas. Nesse caso, existe um decaimento do desempenho do modelo, mas a facilidade de obtenção das variáveis de entrada é muito maior, em comparação ao número de variáveis requeridas pelos melhores modelos definidos (M69 e M77).

Os modelos que empregam somente informações relacionadas à topografia da bacia e à chuva, por exemplo, alcançaram desempenho de 0,65 e 0,52 quando se utiliza chuva ponderada (M78) e não ponderada (M14), respectivamente. Por outro lado, o acréscimo da variável de entrada tipo de solo, em associação à topografia e à chuva ponderada, ocasiona uma leve melhoria no desempenho do modelo M78 (NS=0,66 para M86).

A partir desta pesquisa será possível no futuro, testar a aplicabilidade dos modelos gerados para estimativas do teor de água no solo em regiões físico-climáticas homogêneas, respeitando-se os domínios das variáveis de entrada para os quais as redes foram estabelecida. Em regiões físico-climáticas diferentes, a mesma metodologia desenvolvida nesta pesquisa pode ser utilizada, porém incluindo-se outras variáveis importantes para a região (diferente geologia, diferentes tipos de solos, etc.).

É preciso destacar, entretanto, que os modelos para estimativas do teor de água no solo que tem por base RNAs são modelos do tipo empírico, não baseados no funcionamento físico do sistema e, por isso, o comportamento descrito por algumas variáveis de entrada pode não ser representativo daquele que ocorre realmente no meio natural.

Como recomendações dessa pesquisa são sugeridas:

- Ampliação do período de monitoramento das variáveis de entrada do modelo e do teor de água no solo, objetivando melhor identificação da variação temporal

desse teor, com consideração mais precisa dos valores extremos dos teores de água no solo. Isso também possibilitaria melhor caracterização da influência sazonal dos diferentes fatores sobre o teor de água no solo. Nesse caso, sugere-se a realização de coletas de amostras para 1 ano completo, 2 e 3 anos;

- Testar a utilização de novas variáveis de entrada para os modelos RNA desenvolvidos, que possam contribuir para a variação temporal e espacial do teor de água no solo, tais como: as propriedades químicas do solo, o teor de matéria orgânica, o CTC, o pH, e cátions;
- Desenvolver modelos com RNAs sazonais, que sejam representativos das condições de teor de água no solo para os períodos do verão e do inverno;
- Aplicar restrições nos modelos com RNAs que preservem os significados físicos das variáveis de entrada, conforme seu comportamento no meio natural.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABBASI, Y.; GHANBARIAN-ALAVIJEH, B.; LIAGHAT, A.M.; SHORAFI, M. Evaluation of Pedotransfer Functions for Estimating Soil Water Retention Curve of Saline and Saline-Alkali Soils of Iran. **Pedosphere**, v. 21, n. 2, p. 230-237, 2011.
- ALBERTSON, J.; MONTALDO, N. Temporal dynamics of soil moisture variability: 1. Theoretical basis. **Water Resources Research**, v. 39, n. 10, SWC 1-14, 2003.
- ALLEN, R.G.; PEREIRA, L.S.; RAES, D.; SMITH, M. **Crop Evapotranspiration: guidelines for computing crop water requirements**. FAO Irrigation and Drainage Paper No. 56, 1998. 300p.
- ARYA, L.M.; PARIS, J.F. A physicoempirical model to predict soil moisture characteristics from particle-size distribution and bulk density data. **Soil Science Society of America Journal**, v. 45, p. 1023-1030, 1981.
- ARSOY, S.; OZGUR, M.; KESKIN, E.; YILMAZ, C. Enhancing TDR based water content measurements by ANN in sandy soils. **Geoderma**, v. 195-196, p. 133-144, 2013.
- ASCE (Task Committee on Application of Artificial Neural Networks in Hydrology). Artificial neural networks in hydrology. I: Preliminary concepts. **Journal of Hydrologic Engineering**, v. 5, n. 2, p. 115-123, 2000.
- BARONI, G., ORTUANI, B., FACCHI, A., GANDOLFI, C. The role of vegetation and soil properties on the spatio-temporal variability of the surface soil moisture in a maize cropped field. **Journal of Hydrology**, v. 489, p. 148-159, 2013.
- BLONQUIST, J.M.; JONES, S.B.; ROBINSON, D.A. Standardizing characterization of electromagnetic water content sensors: Part 2. Evaluation of seven sensing systems. **Vadose Zone Journal**, v. 4, p. 1059-1069, 2005.
- BORGES, A L. DE O, BORDAS, M.P. Choix de bassins représentatifs et expérimentaux pour l'étude de l'érosion sur le plateau basaltique sudaméricain. **IAHS Publication**, v. 174, p. 161-169, 1988.
- BOWDEN, G J., DANDY, G.C.; MAIER, H.R. Input determination for neural network models in water resources applications. part 1 - background and methodology. **Journal of Hydrology**, v. 301, n. 1-4, p. 75-92, 2005.
- BOTULA, Y.-D.; CORNELIS, W.M.; BAERT, G.; VAN RANST, E. Evaluation of pedotransfer functions for predicting water retention of soils in Lower Congo (D.R. Congo). **Agricultural Water Management**, v. 111, p. 1-10, 2012.
- BOYER, J.S.; KRAME, P. J. Soil and Water. In: BOYER, J.S.; KRAME, P.J. (editors). **Water relations of plants and soils**. San Diego, 1995, p.84-114.

- BRADY, N.C.; WEIL, R.R. Elementos da natureza e propriedades do solo. 3. ed. Tradução técnica de Igor Fernando Lepsch. Porto Alegre: *Bookman*, 2013, 686 p.
- BROCCA, L.; MORBIDELLI, R.; MELONE, F.; MORAMARCO, T. Soil moisture spatial variability in experimental areas of central Italy. **Journal of Hydrology**, v. 333, p. 356-373, 2007.
- BROCCA, L.; MELONE, F.; MORAMARCO, T.; MORBIDELLI, R. Spatio-temporal variability of soil moisture and its estimation across scales. **Water Resources Research**, v. 46, W02516, 2010.
- BRYANT, R.; MORAN, M.S.; THOMA, D.P.; COLLINS, C.D.H.; SKIRVIN, S.; RAHMAN, M.; SLOCUM, K.; STARKS, P.; BOSCH, D.; GONZÁLEZ-DUGO, M.P. Measuring surface roughness height to parameterize radar backscatter models for retrieval of surface soil moisture. **IEEE Geoscience and Remote Sensing Letters**, v. 4, n. 1, p. 137-141, 2007.
- BUTTLE, J.M.; DILLON, P.J.; EERKES, G.R. Hydrologic coupling of slopes, riparian zones and streams: an example from the Canadian Shield. **Journal of Hydrology**, v. 287, p. 161-177, 2004.
- CARLUER, N.; DE MARSILY, G. Assessment and modelling of the influence of man-made networks on the hydrology of a small watershed: implications for fast flow components, water quality and landscape management. **Journal of Hydrology**, v. 285, p. 76-95, 2004.
- CARVALHO, A.P.; ABRÃO, P.U.R.; FASOLO, P.J.; POTTER, R.J. **Levantamento semidetalhado dos solos da bacia do arroio Taboão (Pejuçara/Ijuí RS)**. Publicação interna, IPH/UFRGS, Porto Alegre, 1990. 41p. + Mapa 1:25.000.
- CASTRO, N.M. dos R. **Ruissellement et érosion sur des bassins versants de grande culture du plateau basaltique du sud du Brésil (Rio Grande do Sul)**. 224p. Tese (doutorado em Geografia Física Hidrologia e Geomorfologia) - Université Louis Pasteur, Strasbourg, 1996.
- CASTRO, N.M.R. dos; CHEVALLIER, P.; GOLDENFUM, J.A. Projeto Potiribu-Atualização 1989-1998. Dados básicos de Fluviometria e Pluviometria. **Recursos Hídricos**, Porto Alegre, v. 35, p. 01-61, 2000.
- CASTRO, N.M.R. dos; PINHEIRO, A.; FERNANDES, C.V.S.; PAIVA, E.M.C.D.; MERTEN, G.H.; MINELLA, J.P.G.; PAIVA, J.B.D.; GOLDENFUM, J.A.; SILVA, M.R.; GASTALDINI, M.C.C.; BRAGA, S.M. **Relatório Final das atividades desenvolvidas de março 2007 a maio de 2010**. Universidade Federal do Rio Grande do Sul, Relatório de pesquisa, 2010. 316p.
- CAUDURO, F. A. & DORFMAN, R. Manual de Ensaio de Laboratório de Campo para Irrigação e Drenagem. Colab. José Bofill Santaló. Porto Alegre: PRONI: IPH - UFRGS, 19???. 216 p.
- CERNÝ, R. Time-domain reflectometry method and its application for measuring moisture content in porous materials: A review. **Measurement**, v. 42, p. 329-336, 2009.

CHAI, S.-S.; WALKER, J.P.; MAKARYNSKY, O.; KUHN, M.; VEENENDAAL, B.; WEST, G. Use of Soil Moisture Variability in Artificial Neural Network Retrieval of Soil Moisture. **Remote Sensing**, v. 2, p. 166-190, 2010.

CHEN, C.-F.; SON, N.-T.; CHANG, L.-Y.; CHEN, C.-C. Monitoring of soil moisture variability in relation to rice cropping systems in the Vietnamese Mekong Delta using MODIS data. **Applied Geography**, v. 31, p. 463-475, 2011.

CHEVALLIER, P.; CASTRO N.M.R. As precipitações na região de Cruz Alta e Ijuí (RS-Brasil). In: **Anais Simpósio Brasileiro de Recursos Hídricos**, 10., 1991, Rio de Janeiro, Anais 3, Rio de Janeiro: ABRH/APRH, 1991. p. 183-192

CHO, E.; CHOI, M. Regional scale spatio-temporal variability of soil moisture and its relationship with meteorological factors over the Korean peninsula. **Journal of Hydrology**, v. 516, n. 4; p. 317-329, 2014.

COELHO, L. DOS S.; FREIRE, R.Z.; SANTOS, G.H. dos; MENDES, N. Identification of temperature and moisture content fields using a combined neural network and clustering method approach. **International Communications in Heat and Mass Transfer**, v. 36, n. 4, p. 304-313, 2009.

CONTADOR, J.F.L.; MANETA, M.; SCHNABEL, S. Prediction of near-surface soil moisture at large scale by digital terrain modeling and neural networks. **Environmental Monitoring and Assessment**, v. 121, p. 213-232, 2006.

CORNELIS, W.M.; RONSYN, J.; VAN MEIRVENNE, M.; HARTMANN, R. Evaluation of pedotransfer functions for predicting the soil moisture retention curve. **Soil Science Society of America Journal**, v. 65, p. 638-648, 2001.

DEPINÉ, H.; CASTRO, N.M.R.; PINHEIRO, A.; PEDROLO, O.C. Preenchimento de falhas de dados horários de precipitação utilizando redes neurais artificiais. **Revista Brasileira de Recursos Hídricos**, v. 19 n.1, pp. 51-63, 2014.

DOBRIYAL, P.; QURESHI, A.; BADOLA, R.; HUSSAIN, S.A. A review of the methods available for estimating soil moisture and its implications for water resource management. **Journal of Hydrology**, v. 458-459, p.110-117, 2012.

DORNELLES, F.; GOLDENFUM, J.A.; PEDROLLO, O.C. Artificial neural network methods applied to forecasting river levels. **Revista Brasileira de Recursos Hídricos**, v. 18, p. 45-54, 2013.

ELSHORBAGY, A.; PARASURAMAN, K. On the relevance of using artificial neural networks for estimating soil moisture content. **Journal of Hydrology**, v. 362, n. 1-2, p. 1-18, 2008.

EMBRAPA - EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA. Centro de Pesquisa Agropecuária do Meio-Norte. **Determinação da curva de retenção de água no solo em laboratório**, 2007. 2p.

ENTIN, J.K.; ROBOCK, A.; VINNIKOV, K.Y.; HOLLINGER, S.E.; LIU, S. NAMKHAI, A. Temporal and spatial scales of observed soil moisture in the extratropics. **Journal of Geophysical Research**, v. 105, n. D9, p. 11865-11877, 2000.

FAMIGLIETTI, J.; RUDNICKI, J.; RODELL, M. Variability in surface moisture content along a hillslope transect, Rattlesnake Hill, Texas. **Journal of Hydrology**, v. 210, n. 1, p. 259-281, 1998.

FAMIGLIETTI, J.S.; RYU, D.; BERG, A.A.; RODELL, M.; JACKSON, T.J. Field observations of soil moisture variability across scales. **Water Resources Research**, v. 44, W01423, 2008.

FELTRIN, R.M.; PAIVA, J.B.D. de; PAIVA, E.M.C.D. de; SARI, V.; BRITES, L.S. seasonal variation in soil water content for forest and pasture in southern Brazil. **Transactions of the ASABE**, v. 56, n. 6, p. 1365-1370, 2013.

GIRARDI, R.V., CASTRO; N.M. de, PINHEIRO, A.; GOLDENFUN, J.A.; SILVEIRA, A.L.L. da. Avaliação do efeito de escala em características de chuva e vazão em sub-bacias embutidas da bacia do Potiribu – RS. **Revista Brasileira de Recursos hídricos**, v. 16, n. 2, p. 49-63, 2011.

GOMEZ-PLAZA, A.; MARTINEZ-MENA, M.; ALBALADEJO, J.; CASTILLO, V.M. Factors regulating spatial distribution of soil water content in small semiarid catchments. **Journal of Hydrology**, v. 253, p. 211-226, 2001.

GONG, Y.; CAO, Q.; SUN, Z. The effects of soil bulk density, clay content and temperature on soil water content measurement using time-domain reflectometry. **Hydrological Processes**, v. 17, p. 3601-3614, 2003.

GRANT, L.; SEYFRIED, M.; MCNAMARA, J. Spatial variation and temporal stability of soil water in a snow-dominated, mountain catchment. **Hydrological Processes**, v. 18, n. 18, p. 3493-3511, 2004.

HÉBRARD, O.; VOLTZ, M.; ANDRIEUX, P.; MOUSSA, R. Spatio-temporal distribution of soil surface moisture in a heterogeneously farmed Mediterranean catchment. **Journal of Hydrology**, v. 329, p. 110-121, 2006.

HECHT-NIELSEN, R. **Neurocomputing**. Addison - Wesley Publishing Company, 1990. 433p.

HU, Y.H.; HWANG, J.-N. **Handbook of neural network signal processing**. United States of America: CRC Press LLC, 2002. 384p.

HU, W.; SHAO, M.A.; WANG, Q.J.; REICHARDT, K. Time stability of soil water storage measured by neutron probe and the effects of calibration procedures in a small watershed. **Catena**, v. 79, n.1, p. 72-82, 2009.

HUPET, F.; VANCLOOSTER, M. Intraseasonal dynamics of soil moisture variability within a small agricultural maize cropped field. **Journal of Hydrology**, v. 261, p. 86-101, 2002.

HUZA, J.; TEULING, A.J.; BRAUD, I.; GRAZIOLI, J.; MELSEN, L.A.; NORD, G.; RAUPACH, T.H.; Uijlenhoet, R. Precipitation, soil moisture and runoff variability in a small river catchment (Ardèche, France) during HyMeX Special Observation Period. **Journal of Hydrology**, v. 516, p. 330-342, 2014.

IBGE. Instituto Brasileiro de Geografia e Estatística. Censo demográfico 2010. Disponível em: <<http://www.ibge.gov.br>>. Acesso em: 11 mar. 2012.

IPAGRO. **Atlas agroclimático do Estado do Rio Grande do Sul**. Porto Alegre: IPAGRO, v. 3, mapa n. 232, 1989.

JIANG, H.; COTTON, W.R. Soil moisture estimation using an artificial neural network: a feasibility study. **Can. J. Remote Sensing**, v. 30, n. 5, p. 827-839, 2004.

JONES, S.B.; WRAITH, J.M.; OR, D. Time domain reflectometry measurement principles and applications. **Hydrological Processes**, v. 16, p. 141-153, 2002.

KASABOV, N. **Foundations of neural networks, fuzzy systems and knowledge engineering**. Cambridge: Massachusetts institute of technology, 1998. 550p.

KAUFMANN, V.; CASTRO, N.M.DOS R.; PINHEIRO, A. Escoamentos Superficiais e de Drenagem em Solo com Diferentes Manejos e Intensidades de Chuvas Simuladas. **Revista Brasileira de Recursos Hídricos**, v. 17, n. 4, p. 273-285, Out/Dez 2012.

KIRKHAM, M.B. **Principles of soil and plant water relations**. United States of America: Elsevier Academic Press, 2005. 500p.

KÖKSAL, E.S.; CEMEK, B.; ARTIK, C.; TEMIZEL, K.E.; TASAN, M. A new approach for neutron moisture meter calibration: artificial neural network. **Irrigation Science**, v. 29, p. 369-377, 2011.

KOLMOGOROV, A.N. On the representation of continuous functions of many variables by superposition of continuous functions of one variable and addition. **Doklady Akademii Nauk SSR**, v. 114, p. 953-956, 1957.

KORNELSEN, K.C.; COULIBALY, P. Advances in soil moisture retrieval from synthetic aperture radar and hydrological applications. **Journal of Hydrology**, v. 476, p. 460-489, 2013.

KORRES, W.; REICHENAU, T.G.; SCHNEIDER, K. Patterns and scaling properties of surface soil moisture in an agricultural landscape: An ecohydrological modeling study. **Journal of Hydrology**, v. 498, p. 89-102, 2013.

KRÖSE, B.; SMAGT, P.V.D. **An introduction to Neural Networks**. University of Amsterdam. Eighth edition, 1996. 135p.

LAKSHMI, V., JACKSON, T.J., ZEHRFUHS, D. Soil moisture-temperature relationships: results from two field experiments. **Hydrological Processes**, v. 17, n. 15, p. 3041-3057, 2003.

- LI, J.; ISLAM, S. Estimation of root zone soil moisture and surface fluxes partitioning using near surface soil moisture measurements. **Journal of Hydrology**, v. 259, p. 1-14, 2002.
- LIMA, J.E.F.W.; SILVA, E.M. da; KOIDE, S.; SANTOS, R.M. dos. Avaliação do Desempenho de Sonda de Capacitância no Monitoramento da Umidade de Latossolos do Cerrado em Condições de Campo. **Revista Brasileira de Recursos Hídricos**, v. 17, n. 1, p. 23-32, 2012,
- MAEDA, K.; TANAKA, T.; PARK, H.; HATTORI, S. Spatial distribution of soil structure in a suburban forest catchment and its effect on spatio-temporal soil moisture and runoff fluctuations. **Journal of Hydrology**, v. 321, p. 232-256, 2006.
- MAHMOOD, R., LEGATES, D. R.; MEO, M. The role of soil water availability in potential rainfed rice productivity in Bangladesh: applications of the CERESRice model. **Applied Geography**, v. 24, p. 139-159, 2004.
- MAIER, H.R.; DANDY, G.C. Determining inputs for neuralnetwork models of multivariate time series. **Microcomputers in Civil Engineering**, v. 12, n. 5, p. 353-368, 1997.
- MANFREDA, S.; RODRIGUEZ-ITURBE, I. On the spatial and temporal sampling of soil moisture fields. **Water Resources Research**, v. 42, W05409, 2006.
- MARIANO, J.C.Q.; SANTOS, G.O.; HERNANDEZ, F.B.T. **Software para cálculo da evapotranspiração de referência diária pelo método de Penman-Monteith**. In: CONIRD – Congresso Nacional de Irrigação e Drenagem, XXI. Petrolina: ABID, 20 a 25 de novembro de 2011, 2011. 6p.
- MATOS, A.B; PEDROLLO, O.C.; CASTRO, N.M.R. Efeito do Controle de Montante de Sub-bacias Embutidas na Previsão Hidrológica de Curto Prazo com Redes Neurais: Aplicação à Bacia de Ponte Mística. **Revista Brasileira de Recursos Hídricos**, V. 19, n.1 –Jan/Mar, 87-99, 2014.
- MCCULLOCH, W.S.; PITTS, W.H. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biosphysics*, v. 5, p. 115-133, 1943.
- MEDEIROS, J.D.F. **Variabilidade espacial do conteúdo de água no solo na bacia do Arroio Donato-RS**. 141p. Tese (Doutorado em Recursos Hídricos e Saneamento Ambiental) – Instituto de Pesquisas Hidráulicas, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2004.
- MEDEIROS, J.D.F.; CASTRO, N.M.R.; GOLDENFUM, J.A.; CLARKE, R.T.. Calibração de sondas do TDR em latossolo. **Revista Brasileira de Recursos Hídricos**, v. 12, n. 2, p.19-25, 2007.
- MEDINA, H.; TARAWALLY, M.; DEL VALLE, A.; RUIZ, M.E. Estimating soil water retention curve in rhodic ferralsols from basic soil data. **Geoderma**, v. 108, p. 277-285, 2002.
- MITTELBAACH, H.; LEHNER, I.; SENEVIRATNE, S.I. Comparison of four soil moisture sensor types under field conditions in Switzerland. **Journal of Hydrology**, v. 430-431, p. 39-49, 2012.

- MOHAMMADI, M.H.; VANCLOOSTER, M. Predicting the soil moisture characteristic curve from particle size distribution with a simple conceptual model. **Vadose Zone Journal**, v. 10, p. 594-602, 2011.
- MOHANTY, B.P.; FAMIGLIETTI, J.S.; SKAGGS, T.H. Evolution of soil moisture spatial structure in a mixed vegetation pixel during the Southern Great Plains 1997 (SGP97). Hydrology experiment. **Water Resources Research**, v. 36, p. 3675-3686, 2000.
- MOORE, R.J. **Real-time forecasting of flood events using transfer function noise models: Report, Part 2**. Wallingford, Institute of Hydrology, 1980. 155p.
- MOUSSA, R.; VOLTZ, M.; ANDRIEUX, P. Effects of the spatial organization of agricultural management on the hydrological behaviour of a farmed catchment during flood events. **Hydrological Processes**, v. 16, n. 2, p. 393-412, 2002.
- MUALEM, Y. A new model for predicting the hydraulic conductivity of unsaturated porous media, **Water Resource Research**, v. 12, n.3, p.513-522, 1976.
- MUÑOZ-CARPENA, R. **Field devices for monitoring soil water content**. Agricultural and Biological Engineering Department, University of Florida. BUL343. 2012. Acessado em: junho de 2014. Disponível em: <<http://edis.ifas.ufl.edu>>.
- NASCIMENTO, P.S.; BASSOI, L.H.; PAZ, V.P.S.; VAZ, C.M.P.; NAIME, J.M.; MANIERI, J.M. Estudo comparativo de métodos para a determinação da curva de retenção de água no solo. **Irriga**, v. 15, p.193-207, 2010.
- NASH, J.E.; SUTCLIFFE, J.V. River flow forecasting through conceptual models part I - A discussion of principles. **Journal of Hydrology**, v. 10, n. 3, p. 282-290, 1970.
- NIEMANN, K.O.; EDGELL, M.C.R. Preliminary analysis of spatial and temporal distribution of soil moisture on a deforested slope. **Physical Geography**, v. 14, n. 5, p. 449-464, 1993.
- NIMER, E. **Climatologia do Brasil**. 2.ed. Rio de Janeiro: IBGE, 1989. 422p.
- NOBORIO, K. Measurement of soil water content and electrical conductivity by time domain reflectometry: a review. **Computers and Electronics in Agriculture**, n.31, p. 213-237, 2001.
- OLIVEIRA, N.T. de. **Influência da palha no balanço hídrico em lisímetros**. 99p. Dissertação (Mestrado em Recursos Hídricos e Saneamento Ambiental) – Instituto de Pesquisas Hidráulicas, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2006.
- OLIVEIRA, N.T. de; CASTRO, N.M. dos R.; GOLDENFUM, J.A. Influência da Palha no Balanço Hídrico em Lisímetros. **Revista Brasileira de Recursos Hídricos**, v. 15, n. 2, p. 93-103, Abr/Jun 2010.
- OLIVEIRA, G.G. de; PEDROLLO, O.C.; CASTRO, N.M. dos R. **Metodologia de análise de sensibilidade e exclusão de variáveis de entrada em simulação hidrológica por redes neurais artificiais (RNAs): resultados preliminares**. In: XIX SIMPÓSIO BRASILEIRO DE

RECURSOS HÍDRICOS. 19., 27 de novembro a 01 de dezembro de 2011, Maceió (AL).
Anais... Maceió: ABRH, 2011, p. 1-19.

PALOSCIA, S.; PAMPALONI, P.; PETTINATO, S.; SANTI, E. A Comparison of Algorithms for Retrieving Soil Moisture from ENVISAT/ASAR Images. **IEEE Transactions on Geoscience and Remote Sensing**, v. 46, n. 10, p. 3274-3284, 2008.

PALOSCIA, S.; PETTINATO, S.; SANTI, E.; NOTARNICOLA, C.; PASOLLI, L.; REPPUCCI, A. Soil moisture mapping using Sentinel-1 images: Algorithm and preliminary validation. **Remote Sensing of Environment**, v. 134, p. 234-248, 2013.

PALTINEANU, I.C.; STARR, J.L. Real-time soil water dynamics Using multisensor capacitance probes: laboratory calibration. **Soil Science Society of America Journal**, v.61, p.1576-1585, 1997.

PEDROLLO, O. 2014. Índice de sensibilidade e índice de importância. [informação oral, fornecida pelo autor em 01/03/2014]

PENNA, D.; BORGA, M.; NORBIATO, D.; DALLA FONTANA, G. Hillslope scale soil moisture variability in a steep alpine terrain. **Journal of Hydrology**, v. 364, p. 311-327, 2009.

PENNA, D.; BORGA, M.; SANGATI, M.; GOBBI, A. Dynamics of Soil Moisture. Subsurface Flow and Runoff in a Small Alpine Basin. **IAHS Publications**, v. 336, p. 96-102, 2010.

PENNA, D.; BROCCA, C.; BORGA, M.; FONTANA, G.D. Soil moisture temporal stability at different depths on two alpine hillslopes during wet and dry periods. **Journal of Hydrology**, v. 477, p. 55-71, 2013.

PUMA, M.J.; CELIA, M.A.; RODRIGUEZ-ITURBE, R.; GUSWA, A.J. Functional relationship to describe temporal statistics of soil moisture averaged over different depths. **Advances in Water Resource**, v. 28, p. 553-566, 2005.

QIU, Y.; FU, B.; WANG, J.; CHEN, L. Soil moisture variation in relation to topography and land use in a hillslope catchment of the Loess Plateau, China. **Journal of Hydrology**, v. 240, p. 243-263, 2001.

RAMÍREZ-BELTRAN, A.N.D.; CASTRO, J.M.; HARMSSEN, E.; VÁSQUEZ, R. Stochastic transfer function model and neural networks to estimate soil moisture. **Journal of the American Water Resources Association**, v. 44, n. 4, p. 847-865, 2008.

REICHARDT, K; TIMM, L. C. **Solo, Planta e atmosfera: Conceitos, processos e aplicações**. Barueri, SP: Manole, 2004. 478p.

REZAEI, L.; SHABANPOUR, M.; DAVATGAR, N. Estimating the soil water retention curve from soil particle size distribution using the Arya and Paris model for Iranian soils. **Turkish Journal of Agriculture & Forestry**, v. 35, n.6. p. 649-657, 2011.

RICHARDS, L.A.; FIREMAN, M. Pressure-plate apparatus for measuring moisture sorption and transmission by soils. **Soil Science**, v.56, p. 395-404, 1943.

ROMANO, N. Soil moisture at local scale: measurements and simulations. **Journal of Hydrology**, v. 516, p. 6-20, 2014.

ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological Review**, v. 65, n. 6, 1958.

RUMELHART, D.E.; HINTON, G.E.; WILLIAMS, R.J. Learning representations by back-propagating errors. **Nature**, v. 323, p. 533-536, 1986.

SAID, S.; KOTHYARI, U.C.; ARORA, M.K. ANN-Based Soil Moisture Retrieval over Bare and Vegetated Areas Using ERS-2 SAR Data. **J. Hydrol. Eng.**, v. 13, n. 6, p. 461-475, 2008.

SALAS, J.D.; DELLEUR, J.; YEVJEVICH, V.; LANE, W. **Applied Modeling of Hydrologic Time Series.**, Colorado/USA: Water Resources Publications, 1980. 484p.

SANTI, E.; PETTINATO, S.; PAMPALONI, P.; MACELLONI, G.; BROGIONI, M. An algorithm for generating soil moisture and snow depth maps from microwave spaceborne radiometers: HydroAlgo. **Hydrological Earth System Science**, v. 16, p. 3659-3676, 2012.

SANTOS, R.M. **Calibração de sensores FDR (Frequency Domain Reflectometry) para estimativa da umidade do solo.** 2005. 53p. Dissertação (Mestrado) - Universidade Federal da Bahia, Cruz das Almas, 2005.

SCHMUGGE, T.J.; JACKSON, T.J.; MCKIM, H.L. Survey of methods for soil moisture determination. **Water Resources Research**, v. 16, n. 6, p. 961-979, 1980.

SILVA, P.M.O., MELLO, C.R., SILVA, A.M., COELHO, G. Modelagem da hidrografia de cheia em uma bacia hidrográfica da região Alto Rio Grande. **R. Bras. Eng. Agric. Amb.**, 12, p.258-265, 2008.

SRIVASTAVA, P.K.; HAN, D.; RAMIREZ, M.R.; ISLAM, T. Machine Learning Techniques for Downscaling SMOS Satellite Soil Moisture Using MODIS Land Surface Temperature for Hydrological Application. **Water Resource Manage**, v. 27, n. 8, p. 3127-3144, 2013.

STANGL, R.; BUCHAN, G.D.; LOISKANDL, W. Field use and calibration of a TDR-based probe for monitoring water content in a high-clay landslide soil in Austria. **Geoderma**, v. 150, n. 1-2, p. 24-31, 2009.

SUR, C.; JUNG, Y.; CHOI, M. Temporal stability and variability of field scale soil moisture on mountainous hillslopes in Northeast Asia. **Geoderma**, v. 207-208, p. 234-243, 2013.

THIESSEN, A.H. Precipitation averages for large areas. **Monthly Weather Review**, v. 39, p. 1082-1089, 1911.

TOMMASELLI, J.T.G. **Influência de algumas características do solo na calibração de um aparelho de TDR (Time-Domain Reflectometry).** 1997. 109p. Tese (Doutorado em Engenharia Nuclear na Agricultura) – Centro de Energia Nuclear, Universidade de São Paulo, Piracicaba, 1997.

TOPP, G.C.; DAVIS, J.L.; ANNAN, A.P. Eletromagnetic determination of soil water content: Measurements in coaxial transmission lines. **Water Resources Research**, v.16p. 574-582, 1980.

TOWNER, G.D. The Effect of Air Bubbles on the Response of Tensiometers. Research notes, **Journal of Agricultural Engineering Research**, v. 28, n. 6, p. 565-568, 1983.

VAN GENUCHTEN, M.T. A closed-form equation for predicting the hydraulic conductivity of unsaturated soils. **Soil Science Society of America Journal**, v. 44, p. 892-898, 1980.

VAZ, C.M.P.; JONES, S.; MEDING, M.; TULLER, M. Evaluation of standard calibration functions for eight electromagnetic soil moisture sensors. **Vadose Zone Journal**, v. 12. 2013

VERECKEN, H., KAMAI, T., HARTER, T., KASTEEL, R., HOPMANS, J., VANDERBORGHT, J. Explaining soil moisture variability as a function of mean soil moisture: a stochastic unsaturated flow perspective. **Geophysical Research Letters**, v. 34, n. 22, L22402 (p. 1-6), 2007.

VERECKEN, H., HUISMAN, J.A., PACHEPSKY, Y., MONTZKA, C., VAN DER KRUK, J., BOGENA, H., WEIHERMÜLLER, L., HERBST, M., MARTINEZ, G., VANDERBORGHT, J. On the spatiotemporal dynamics of soil moisture at the field scale. **Journal Hydrological**, v. 516, p. 76-96, 2014.

VIERO, A.C. **Análise da geologia, geomorfologia e solos no processo de erosão por voçorocas: bacia do Taboão/RS**. 119p. Dissertação (Mestrado em Recursos Hídricos e Saneamento Ambiental) – Instituto de Pesquisas Hidráulicas, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2004.

VOGL, T.P.; MANGIS, J.K.; RIGLER, A.K.; ZINK, W.T.; ALKON, D.L. Accelerating the Convergence of the Back-Propagation Method. **Biological Cybernetics**, v. 59, p. 257-63, 1988.

WALCZAC, R.T.; MORENO, F.; SLAWINSKI, C. FERNANDEZ, E.; ARRUE, J.L. Modeling of soil water retention curve using soil solid phase parameters. **Journal of Hydrology**, v. 329, n. 3-4, p. 527-533, 2006.

WANG, L.; QU, J.J. Satellite remote sensing applications for surface soil moisture monitoring: a review. **Front Earth Sci. China**, v. 3, n. 2, p. 237-247, 2009.

WEIHERMULLER, L.; HUISMAN, J.A.; LAMBOT, S.; HERBST, M.; VERECKEN, H. Mapping the spatial variation of soil water content at the field scale with different ground penetrating radar techniques. **Journal of Hydrology**, v. 340, p. 202-216, 2007.

WESTERN, A.W., BLÖSCHL, G., GRAYSON, R.B. Geostatistical characterisation of soil moisture patterns in the Tarrawarra Catchment. **Journal of Hydrology**, v. 205, p. 20-37, 1998.

WESTERN, A.W.; GRAYSON, R.B.; BLÖSCHL, G. **scaling of soil moisture**: a hydrologic perspective. **Annual Review of Earth and Planetary Sciences**, v.30, p. 149-180, 2002

WESTERN, A.W; ZHOU, S.-L.; GRAYSON, R.B.; MCMAHON, T.A.; BLÖSCHL, G.; WILSON, D.J. Spatial correlation of soil moisture in small catchments and its relationship to dominant spatial hydrological processes. **Journal of Hydrology**, 286, p.114-134, 2004.

WIDROW, B.; HOFF, M.E. Adaptive Switching Circuits. **Ire Wescon Convention Record**, v.4, Supleme, p. 96-104, 1960.

WIGNERON, J.P.; PARDE, M.; WALDTEUFEL, P.; CHANZY, A.; KERR, Y.; SCHMIDL, S.; SKOU, N. Characterizing the dependence of vegetation model parameters on crop structure, incidence angle, and polarization at L-band. **IEEE Transactions on Geoscience and Remote Sensing**, v. 42, n. 2, p. 416-425, 2004.

ZHANG, G., PATUWO, B.E.; HU, M. Y. Forecasting with artificial neural networks: the state of the art. **International Journal of Forecasting**, [S.l.], v.14, Issue 1, p.35-62, 1998.

ZHU; Q.; LIN, H. Influences of soil, terrain, and crop growth on soil moisture variation from transect to farm scales. **Geoderma**, v. 163, p. 45-54, 2011.

ZHU, Q.; LIAO, K.; XU, Y.; YANG, G.; WU, S.; ZHOU, S. Monitoring and prediction of soil moisture spatial-temporal variations from a hydro-pedological perspective: a review. **Soil Research**, v. 50, p. 625-637, 2012.

ZOU, P.; YANG, J.; FU, J.; LIU, G.; LI, D. Artificial neural network and time series models for predicting soil salt and water content. **Agricultural Water Management**, v. 97, n. 12, p. 2009-2019, 2010.

ZUCCO, G.; BROCCA, L.; MORAMARCO, T.; MORBIDELLI, R. Influence of land use on soil moisture spatial-temporal variability and monitoring. **Journal of Hydrology**, v. 516, p. 193-199, 2014.

APÊNDICES

Autor	Local	Área da bacia/ área analisada	Objetivo	Características da rede	Algoritmo de treinamento	Variáveis de entrada testadas	Variáveis mais sensíveis	Variáveis de entrada adotadas no modelo final	Período de dados/ N° de registros	Intervalo de tempo	NS/R²/R	Outras observações/conclusões
Arsoy et al. (2013)	região de Marmara, Turquia	-	prever umidade do solo para solos arenosos com diferentes texturas e níveis de compactação	rede progressiva (3 camadas) n° de neurônios (camada intermediária: 8 (RNA-8) e alternativamente 11 (RNA-11))	retropropagativo com algoritmo de otimização Levenberg-Marquardt	permissividade elétrica aparente, densidade seca, teor de finos, e gravidade específica	todos os modelos mantiveram a permissividade como entrada. A densidade e o teor de finos mostraram igual importância, enquanto que a gravidade específica foi a variável que menos afetou o modelo	permissividade elétrica aparente, densidade seca, teor de finos, e gravidade específica	120 amostras, considerando 5 níveis de conteúdo de água (0%, 2,5%, 5,0%, 7,0% e 10%) e 3 tipos de densidade do solo, para os 8 tipos de solo arenoso (areia bem graduada, areia pobremente graduada, areia argilosa, areia silteosa, areia bem graduada argilosa, areia bem graduada silteosa, areia pobremente graduada argilosa, areia pobremente graduada silteosa)	amostras escolhidas aleatoriamente para utilização de todos os tipos de solo	RNA-8: NS variou entre 0,971 e 0,998 (treinamento) para a estimativa da umidade dos diferentes tipos de solo e RNA-11: NS variou entre 0,998 e 0,9981 para a estimativa da umidade dos diferentes tipos de solo	RNA proposta é mais precisa em relação aos demais modelos de calibração analisados. RMSE=0,009 cm³/cm³ (RNA-8) e 0,006 cm³/cm³ (RNA-11), divergência máxima 3,2% (RNA-8) e 2,0% (RNA-11), divergência média= 0,6% (RNA-8) e 0,5% (RNA-11), solos com alto teor de argila: utilizar água adsorvida como um parâmetro de entrada da rede.
Chai et al. (2010)	bacia do rio Goulburn, Austrália	40 km x 40 km	estimar a umidade do solo em regiões menores, a partir de imagens de satélite de regiões maiores	rede progressiva, 1 e 2 camadas intermediárias (testadas), com número de neurônios variando entre 2 e 100	retropropagativo com método de otimização Brodyen-Fletcher-Goldfarb-Shanno	temperatura de brilho polarizada vertical e horizontal (TBH e TBV), índice de vegetação NDVI, e temperatura da superfície terrestre (LST)	-	TBH e TBV	1600 dados para cada data	7/11/05 para treinamento, validação e teste 14/11/05 e 21/11/05 para teste	2 camadas intermediárias (50 neurônios cada): R²=0,84 (entradas: TBH, TBV e LST) e 1 camada intermediária (20 neurônios): R²=0,88 (entradas: TBH e TBV)	RMSE= 2,79% v/v (2 camadas intermediárias) e 2,86% v/v (1 camada intermediária) A precisão da recuperação da umidade do solo foi melhorada através da divisão da área em regiões menores (até 4 km), sendo a variabilidade espacial da umidade do solo calculada a partir da região menor, por meio de RNA
Coelho et al. (2009)	Curitiba, Paraná, Brasil	-	estimar a umidade no perfil do solo (0 a 3 m)	rede neural de base radial (rede progressiva com 3 camadas), testados 2 a 6 neurônios na camada intermediária	método de treinamento não-supervisionado Gath-Geva	temperatura do ar, umidade relativa do ar, e radiação solar direta e difusa	-	temperatura do ar, umidade relativa do ar, e radiação solar direta e difusa	8760 amostras	1 ano de dados horários	R² variou entre 0,1024 a 0,9996 (treinamento) e entre 0,1024 e 0,9990, considerando as diferentes camadas no perfil do solo e variando o n° de neurônios na camada intermediária R² médio ≥ 0,9796 para todos os casos (considerando treinamento e verificação)	Os baixos valores de R² foram encontrados quando se utilizou 2 e 3 neurônios na camada intermediária, sobretudo para a profundidade de 3 m no perfil do solo. O melhor R² para a superfície ocorreu com 4 neurônios na camada intermediária (R²=0,9965 no treinamento e 0,9980 para a validação), para 1 m ocorreu com 5 neurônios na camada intermediária (R²=0,9996 no treinamento e 0,9995 na validação), para 2 m ocorreu com 4 neurônios na camada intermediária (R²=0,9998 no treinamento e 0,9998 na validação), e para 3 m ocorreu com 5 neurônios na camada intermediária (R²=0,9996 no treinamento e 0,9990 na validação)
Contador, Maneta e Schusabel (2006)	bacia experimental de Parapuños, Espanha	99,5 ha	prever a umidade do solo a partir de variáveis topográficas e de cobertura do solo, utilizando um número restrito de pontos de amostragem	rede progressiva com 3 camadas (camada de entrada, intermediária e de saída), com 5 neurônios na camada de entrada e 1 na camada de saída	retropropagativo	curvatura vertical, curvatura horizontal, índice topográfico, índice de radiação e cobertura vegetal	a cobertura vegetal e a curvatura vertical são as variáveis mais importantes, seguidas pelo índice de umidade topográfica e o índice de radiação, enquanto que a curvatura horizontal é a variável menos sensível	curvatura vertical, curvatura horizontal, índice de umidade topográfica, índice de radiação e cobertura vegetal	182 amostras	final de janeiro de 2004	R² = 0,71	A eficiência da rede foi avaliada pelo RMSE. Melhor ajuste: RMSE = 4,56% e erro relativo (PBIAS) de 0,41%, para o conteúdo volumétrico de água no solo
Elshorbagy e Parussarman (2008)	Bacia de Athabasca, Alberta, Canadá	cada tipo de cobertura do solo (D1, D2 e D3) apresenta área de 1 ha	estimar a umidade do solo na turfa e em diferentes camadas, considerando diferentes tipos de cobertura (D1: 20 cm turfa + 30 cm solo, D2: 15 cm de turfa + 20 cm solo, e D3: 20 cm turfa + 80 cm solo)	RNA de primeira ordem (FONN): modelos M1 a M3, M5 a M9 RNA de alta ordem (HONN): M4, M10 (2ª ordem)	retropropagativo com regularização Bayesiana	valores médios diários de precipitação (P), temperatura do ar (Ta), temperatura do solo (na turfa: Tt e nas camadas de solo: Ts), e radiação solar (Rs)	-	modelo M1: usa P, Ta e Rs modelos M2: = M1 + Tt e Ts modelo M3: Tt e Ts modelo M4: Tt, Ts, (Ts)², (Tt)², TsTt modelo M5 = M2 + P, Ta, Ts anteriores modelo M7: = M2 + ΣP _i modelo M8: = M2 + ΣP _i + ΣTa _i modelo M9: = M2 + ΣP _i + ΣTa _i	384 dados para o treinamento e 384 para o teste da rede	2000 a 2005	R (D1) - M1 a M5: variou entre 0,18 e 0,644 (treinamento) e entre 0,128 a 0,581 (teste) para a turfa. Para as demais camadas variou entre 0,236 e 0,624 (treinamento) e entre 0,209 e 0,56 (teste) R (D2) - M1 a M4: variou entre 0,265 e 0,566 (treinamento) e entre 0,297 a 0,575 (teste) para a turfa. Para as demais camadas variou entre 0,167 e 0,807 (treinamento) e entre 0,179 e 0,789 (teste) R (D3) - M1 a M4: variou entre 0,215 e 0,308 (treinamento) e entre 0,211 a 0,40 (teste) para a turfa. Para as demais camadas variou entre 0,177 e 0,405 (treinamento) e entre 0,165 e 0,386 (teste) R (M6 a M9) - teste: variou entre 0,42 e 0,69 (D1 = 50 cm), entre 0,42 e 0,72 (D2 = 35 cm), e entre 0,40 e 0,79 (D3 = 100 cm) R (M10) - teste: 0,7 para a turfa e para as demais camadas (D1 = 50 cm), 0,74 para a turfa e 0,82 para as demais camadas (D2 = 35 cm), e 0,79 para a turfa e 0,70 para as demais camadas (D3 = 100 cm)	RMSE (D1): variou entre 0,04 e 0,051 cm/cm (treinamento) e entre 0,042 e 0,051 cm/cm (teste) para a turfa. Para as demais camadas variou entre 0,015 e 0,018 cm/cm (treinamento) e entre 0,016 e 0,018 cm/cm (teste) RMSE (D2): variou entre 0,062 e 0,072 cm/cm (treinamento) e entre 0,061 e 0,1 cm/cm (teste) para a turfa. Para as demais camadas variou entre 0,014 e 0,021 cm/cm (treinamento) e entre 0,014 e 0,023 cm/cm (teste) RMSE (D3): variou entre 0,043 e 0,044 cm/cm (treinamento) e entre 0,042 e 0,045 cm/cm (teste) para a turfa. Para as demais camadas variou entre 0,012 e 0,013 cm/cm (treinamento) e entre 0,012 e 0,013 cm/cm (teste) RMSE (M6 a M9) - teste: variou entre 0,03 e 0,06 cm/cm (D1 = 50 cm), entre 0,05 e 0,08 cm/cm (D2 = 35 cm), e entre 0,040 e 0,042 cm/cm (D3 = 100 cm) RMSE (M10) - teste: para D1 (50 cm) e D3 (100 cm) = 0,03 cm/cm na turfa e 0,01 cm/cm nas demais camadas, para D2 (35 cm) = 0,05 cm/cm na turfa e 0,01 cm/cm nas demais camadas
Jiang e Cotton (2004)	Oklahoma (OK) Mesonet	-	estimar a umidade do solo, com alta resolução espacial e temporal, a partir de dados de sensoriamento remoto	RNA de "counter-propagation": rede híbrida que combina 2 redes de base (Mapas Auto-Organizáveis de Kohonen + rede linear de Grossberg)	treinamento não supervisionado + algoritmo de mapeamento linear	temperatura da superfície (infravermelho), índice de vegetação NDVI, precipitação acumulada (30 dias)	-	temperatura da superfície (infravermelho), índice de vegetação NDVI, precipitação acumulada (30 dias)	-	maio a setembro de 1999 (treinamento), maio a setembro de 2000 (teste)	R = 0,9529 (treinamento) e 0,9971 (teste)	o modelo tende a superestimar os resultados quando a umidade do solo (perfil vertical de 0-75cm) é baixa e subestimar quando ela é alta
Köksal et al. (2011)	área experimental do Centro de Pesquisas Agrícolas de Bafru do Instituto de Pesquisas em Recursos Hídricos e Solo de Samsun, República da Turquia	-	desenvolver modelos de calibração do medidor de umidade de nêutrons, utilizando RNAs	rede progressiva: n° de camadas e neurônios na camada intermediária depende da profundidade do solo 0-30 cm e 30-60 cm : 3 camadas com 10 neurônios na intermediária; 60-90 cm: 4 camadas com 15 neurônios nas intermediárias 90-120 cm: 3 camadas com 15 neurônios na intermediária 0-120 cm: 4 camadas com 15 neurônios nas intermediárias	algoritmo retropropagativo Levenberg Marquadt	razão de contagem: profundidade de medição na camada	-	razão de contagem: profundidade de medição na camada	-	18 de maio de 2009 e 30 de julho de 2009	R² calibração - treinamento com dados da camada: 0,94 (0-30 cm); 0,95 (30-60 cm); 0,87 (60-90 cm); e 0,88 (90-120 cm) R² = 0,97 (treinamento com dados de 0-120 cm)	RMSE treinamento = 0,0133 m³/m³ (0-30 cm); 0,097 m³/m³ (30-60 cm); 0,059 m³/m³ (60-90 cm); 0,048 m³/m³ (90-120 cm); e 0,0111 m³/m³ (0-120 cm) RMSE teste= 2,23 m³/m³ (0-30 cm); 1,74 m³/m³ (30-60 cm); 0,60 m³/m³ (60-90 cm); 1,67 m³/m³ (90-120 cm); e 0,0078 m³/m³ (0-120 cm) Estimativa mais precisa: quando se utilizam (em conjunto) todos os dados do perfil do solo para aprendizado da rede (RNAs)
Paloscia et al. (2008)	área agrícola plana, próxima a Alessandria, norte da Itália	300 km²	analisar a possibilidade de estimativas de mapas de umidade do solo de áreas agrícolas, a partir de informações obtidas por um único sensor (ENVISAT/ASAR)	rede progressiva, com 2 camadas intermediárias e 10 neurônios em cada uma dessas camadas	retropropagativo	coeficiente de retroespalhamento (polarização HH e HV e ângulo incidente de 23°) RNA2: coeficiente de retroespalhamento (polarização HH e HV e ângulo incidente de 23°) e rugosidade da superfície do solo	-	coeficiente de retroespalhamento e rugosidade da superfície do solo	-	1991-1994: dados usados para treinamento 11/2003 a 05/2005: imagens usadas para teste da RNA (07/11/03, 30/04/04, 04/06/04, 11/11/04, e 30/05/05)	R²: 0,85 (RNA1) e 0,91 (RNA2)	Erro médio: - 9% Erro padrão da estimativa: 2,75% (RNA1) e 2,16% (RNA2)
Paloscia et al. (2013)	6 áreas de teste: Scrvia, Matera, Cordevole, e Alto Adige, localizadas na Itália 1 área na Austrália (rio Yancoo), 1 área na Espanha (Emporda)	Scrvia (300 km²), Matera (10 x 10 km), Cordevole (95 km²), Alto Adige (100 km²), e Austrália (60 x 60 km)	desenvolver, testar e validar uma RNA (para cada área) para determinação do teor de umidade do solo, utilizando dados do GMS5 Sentinel-1	rede progressiva, com 2 camadas intermediárias e 10 neurônios em cada uma dessas camadas	retropropagativo	coeficiente de retroespalhamento (polarização HH, VV, e HV/VH), índice de vegetação NDVI modelos testados: 1) polarização VV, 2) polarização HH, 3) polarização VV + NDVI, 4) polarização HH + NDVI, 5) polarização VV e VH, 6) polarizações HH e HV	-	coeficiente de retroespalhamento (polarização HH, VV, e HV/VH), índice de vegetação NDVI modelos testados: 1) polarização VV, 2) polarização HH, 3) polarização VV + NDVI, 4) polarização HH + NDVI, 5) polarização VV e VH, 6) polarizações HH e HV	-	Scrvia: 07/11/03, 30/04, 06/06, 22/10 e 26/11/04; 30/05/05; 26/09/08; 24/04 e 29/05/05; Matera: 13/07, 10/10 e 07/05/08; 11/04/09 Cordevole: 14/06, 19/07, 23/08, 27/09 e 01/11/04 Austrália: 12/07/04, 05/09 e 19/12/05; 16/02/09 Alto Adige: 01/05 e 03/06/10 Espanha: 10/05, 14/06, 23/08 e 27/09/10, 25/02 e 27/06/11	Scrvia: R²=0,78 (quando 1 polarização está disponível - VV) e 0,85 (polarização dupla); Alto Adige: R²= 0,67; Austrália: R² =0,62 R² polarização simples (HH ou VV): varia de 0,495 (pol. VV) para 0,65 (pol. VV + NDVI); de 0,854 (pol. HH) para 0,881 (pol. HH + NDVI) R² polarização dupla (VV + VH ou HH + HV): varia de 0,04 (VV) para 0,011 (VV + NDVI) e para 0,59 (VV + VH); de 0,797 (HH) para 0,811 (HH + NDVI) e para 0,872 (HH + HV)	polarização VV: resultados menos favoráveis índice de vegetação NDVI: seu uso melhora o desempenho dos modelos, tanto para polarização VV quanto para a HH Melhores resultados: polarização cruzada Scrvia: RMSE=2,75 (uma polarização disponível - VV) e 2,15 (polarização dupla); Matera: RMSE = 1,8% com uso de NDVI e 9% sem NDVI; Alto Adige: RMSE = 4,91%; Austrália: RMSE = 5,58%; Espanha: RMSE variou entre 3,41% e 6,38% (conforme a data da imagem utilizada), com média de 4,60% quando NDVI foi desconsiderado; e variou entre 2,31% e 8,50% (média de 4,64%) quando o NDVI foi considerado.
Ramírez-Beltrán et al. (2008)	17 estações monitoradas em Porto Rico	-	estimar a variação espacial e temporal da umidade do solo e a umidade no perfil vertical do solo	rede neural auto-organizável (SONN): identifica as semelhanças espaciais entre grids (variabilidade espacial e temporal da umidade do solo) RNA progressiva (3 camadas, com 4 neurônios na camada intermediária): estima a umidade do solo em diferentes profundidades (5, 10, 20, 50, e 100 cm)	RNA: algoritmo de Levenberg-Marquardt	SONN: % de argila e areia, elevação, diferença da temperatura da superfície (max-min), índice de vegetação NDVI e precipitação acumulada no mês. RNA: % de argila e areia, umidade do solo a 20 cm de profundidade, e precipitação acumulada no mês	-	SONN: % de argila e areia, elevação, diferença da temperatura da superfície (max-min), índice de vegetação NDVI e precipitação acumulada no mês. RNA: % de argila e areia, umidade do solo a 20 cm de profundidade, e precipitação acumulada no mês	RNA: 2000 dados para treinamento, 300 para validação e 700 para teste da rede	observações horárias (2005-2008)	-	SONN: RMSE para a estimativa da umidade do solo a 20 cm de profundidade variou entre 0,53% e 8,54% para as 17 estações, com média de 2,31%. RMSE médio foi igual a 1,11% meses secos e 1,92% meses úmidos RNA: RMSE médios 2,50% na verificação do desempenho do modelo. RMSE médio por profundidade: variou entre 2,16% e 6,01%, com média de 4,14% (5 cm di); entre 0,9% e 3,84%, com média de 1,91% (10 cm); entre 1,23% e 2,94%, com média de 2,18% (50 cm); e entre 0,22% e 4,17%, com média de 1,78% (100 cm). RMSE médio das estações, considerando o perfil do solo: variou entre 1,70% e 4,24%, com média de 2,50%. O algoritmo proposto é uma potencial ferramenta para estimar a umidade do solo em intervalos horários, até 1 km de resolução espacial e com até 1 m de profundidade.
Said et al. (2008)	Bacia do rio Solani, Índia	-	estimativa da umidade do solo, a partir de dados do ERS-2 SAR, sobre solo exposto e com pouca vegetação	RNA progressiva, com 3 camadas e número de neurônios na camada intermediária variável (4, 5, 6 ou 8). No total foram testadas 24 RNAs, considerando as diferentes imagens (3 datas + a combinação das datas), diferentes entradas (testadas 4, 5 e 7), e a variação no número de neurônios na camada intermediária	retropropagativo	índice de área foliar (LAI), altura da vegetação (h), conteúdo de água na planta (PWC), altura da rugosidade da superfície (RMS (s)), coeficiente de retroespalhamento (odeg), número digital - DN (localização digital no pixel), cobertura vegetal, e ângulo de incidência combinações testadas: 1) DN, cobertura vegetal, ângulo incidente, s, LAI, PWC, e h; 2) DN, cobertura vegetal, ângulo de incidência, s, e LAI; 3) DN, cobertura vegetal, ângulo de incidência, s, LAI, PWC, e h; 6) odeg, cobertura vegetal, ângulo de incidência, s, LAI, PWC, e h; 7) odeg, cobertura vegetal, ângulo de incidência, s, e LAI; e 8) LAI	utilização de 5 variáveis de entrada foram consideradas suficientes para a estimativa precisa da umidade do solo: odeg, cobertura vegetal, ângulo de incidência, rugosidade da superfície RMS e LAI	-	28/07/03; 29/03/04 e 03/05/04	R² variou entre 0,74 e 0,93 no treinamento; entre 0,72 e 0,89 no teste; e entre 0,70 e 0,91 na validação R² (5 entradas: odeg, cobertura vegetal, ângulo de incidência, rugosidade da superfície RMS e LAI): variou entre - 0,85 a 0,92 R² (3 imagens combinadas): variou entre -0,75 e 0,85 R² (4 variáveis - odeg ou DN, ângulo de incidência, cobertura vegetal e LAI): variou entre - 0,84 e 0,89	RMSE: variou entre 2,6 e 6,3 no treinamento; entre 3,1 e 7,8 no teste; e entre 4,0 e 8,8 na validação Todas as RNAs que usam como entrada o odeg apresentam melhor desempenho que aquelas que utilizam o DN. A desconsideração de PWC e h (uso somente do LAI) não diminui significativamente o R² Utilização das 3 imagens em conjunto: reduzir R² em razão da variação da umidade ao longo do tempo (para um mesmo ponto) O treinamento da rede com 4 variáveis apenas (odeg ou DN, ângulo de incidência, cobertura vegetal e LAI) reduz o desempenho (R²) da rede em comparação com a rede que utiliza 5 entradas	
Sami et al. (2012)	1 área na Mongólia e 1 na Austrália (dados treinamento), 1 área na Itália (bacia de Scrvia - dados de validação), e 4 bacias nos EUA (Little Washita, Little River, Walnut Gulch e Reynolds Creek)	Mongólia e Austrália: 120 kmx120 km (cada área) Scrvia: 100 x 100 km Little Washita: 610 km² - pastagens Little River: 334 km² - vegetação (florestas, áreas de cultivo e pastagens) Walnut Gulch: 148 km² - arbustos e grama Reynolds Creek: 238 km² - pastagem	estimar a umidade do solo, a partir de informações obtidas do sensor AMSR-E, para solo exposto ou com pouca vegetação	rede progressiva multicamada (perceptron), com duas camadas intermediárias e 10 neurônios em cada uma delas	retropropagativo	temperatura de brilho da superfície na banda C, com polarização vertical (TBV); ângulo de incidência (s-50°); índice de polarização banda X-(P _h), TBV na banda Ka	-	umidade do solo: 18 pontos de amostragem na Austrália e 15 na Mongólia: total de 3000 medidas (valores médios diários) - consideradas apenas valores relativos as datas das imagens Treinamento: 6500 dados (experimentais + simulados)	01/01/03 a 31/12/04 (Mongólia e Austrália), e 11/03 a 06/09 (Scrvia)	R²: 0,82 (validação); variou entre 0,28 e 0,52 (teste - órbita ascendente) e entre 0,26 e 0,36 (teste - órbita descendente)	RMSE: 0,035 m³/m³ (validação); variou entre 0,019 e 0,046 (teste - órbita ascendente) e entre 0,020 e 0,065 (teste - órbita descendente)	
Srivastava et al. (2013)	Bacia de Brue, Inglaterra	135,5 km²	melhorar a resolução espacial de dados de umidade do solo obtidos a partir de dados SMOS (disponíveis em escala de 40 km). O desempenho foi comparado com o déficit de umidade do solo obtido através do modelo de Distribuição de Probabilidades (PDM SMD)	rede progressiva com 4 camadas (2 camadas intermediárias), com 2 neurônios na camada de entrada, 2 neurônios em cada camada intermediária, e 1 neurônio na camada de saída	algoritmo de Levenberg-Marquardt	umidade do solo (dados SMOS)	-	dados de temperatura da superfície terrestre (MODIS-LST) com dados de umidade do solo (produto derivado de dados do SMOS)	dados diários (período diário e noturno)	02/11 a 01/12 (8 meses iniciais - calibração e 4 meses finais para validação)	R²= 0,797 (treinamento) e 0,751 (teste) R² teste = 0,617 (período de crescimento vegetação - março a novembro); 0,273 (período de não crescimento - dezembro a fevereiro); e 0,859 (quando considerado o período de crescimento + não-crescimento)	RMSE= 0,012 (treinamento) e 0,011 (teste) RMSE teste = 0,009 m (período de crescimento planta - março a novembro); 0,006 (período de não crescimento - dezembro a fevereiro); e 0,008 (quando considerado o período de crescimento + não-crescimento)
Zou et al. (2010)	Planície Norte da China	-	estimar o teor de água no solo (para o próximo mês), em diferentes profundidades (20, 40 e 60 cm), utilizando dados de umidade calculados pelo modelo ARIMA (defasados no tempo)	rede progressiva com 3 camadas. Número de neurônios na camada intermediária: determinado pelo método de Box-Jenkins número de neurônios por camada: 5-6-1 (20 cm); 3-5-1 (40 cm); 3-2-1 (60 cm); 1-4-1 (perfil do solo)	retropropagativo	a abordagem de Box-Jenkins foi usada para descobrir a apropriado defasagem das variáveis de entrada	-	umidades médias no perfil do solo, determinadas pela análise clássica de Box-Jenkins e calculadas pelo modelo ARIMA (x _{t-1} , x _{t-2} , x _{t-3} , x _{t-4} e x _{t-5})	-	2001 a 2006 (em geral, a cada 5 dias)	R² (perfil do solo): variou entre 0,8912 (2 neurônios na camada intermediária) e 0,8987 (4 neurônios na camada intermediária) R² (profundidade = 20 cm): variou entre 0,0057 (15 neurônios na camada intermediária) e 0,8707 (12 neurônios) R² melhor estatística (combinação R² e MSE): 0,5244 (20 cm); 0,0384 (40 cm); e 0,4297 (60 cm)	MSE (perfil do solo) variou entre 0,000015 (4 neurônios na camada intermediária) e 0,000022 (2 neurônios na camada intermediária) MSE (20 cm): variou entre 0,0001 (2 neurônios na camada intermediária) e 0,0404 (12 neurônios na camada intermediária) MSE melhor estatística: 0,0014 (20 cm); 0,00002 (40 cm); e 0,00004 (60 cm)

APÊNDICE B - Umidade gravimétrica do solo (%), considerando os 26 pontos coletados e as 24 datas (ou 25 momentos) em que as coletas foram realizadas (período compreendido entre 15 de janeiro e 10 de agosto de 2013)

Ponto/Data	15/1/13	16/1/13	17/1/13	18/1/13	19/2/13	20/2/13	21/2/13	22/2/13	20/3/13	21/3/13	22/3/13	23/3/13	1/5/13	2/5/13	3/5/13	4/5/13	5/6/13	6/13 Manhã	6/13 Tard	7/6/13	8/6/13	7/8/13	8/8/13	9/8/13	10/8/13
P01	20,34		19,51	27,91	31,51		27,06	26,82	26,56	25,20	29,99	29,78	28,98	30,17	29,46	29,18	28,91	29,67	28,62	28,31	27,69	31,99	29,32	32,45	
P02	18,08	26,03	21,79	21,82	23,51	24,70	23,89	21,46	26,62	25,78	20,28	23,28	26,02	22,56	23,82	25,12	22,15	24,52	25,68	26,16	26,82	25,57	24,39	24,26	
P03	17,37	19,86	24,50	22,38	26,16	26,93	25,65	25,22	30,17	29,83	29,26	25,50	30,90	25,67	27,91	30,17	26,70	30,10		29,79	28,52	28,44	27,13	28,42	
P04	22,84	22,40	20,96	19,71	20,78	25,08	25,85	21,04	29,86	28,25		26,82	25,48	25,99	26,40	28,48	28,06	29,00	27,26	29,44	27,68	28,98	28,34	26,08	31,93
P05	20,96	21,42	21,08	25,85	24,16	23,60	24,97	20,59	28,55		27,97	26,27	26,03	26,79	27,21	28,54	27,77	27,55	27,08	24,87	28,72	28,33	26,68	25,94	30,18
P06	17,24	22,27	21,89	27,59	25,03	27,25	28,45	23,52	30,91			29,73	27,89	27,69	28,34	27,84	27,39	28,88	28,05	27,52	25,34	31,26	28,90	27,32	34,87
P07	24,25	25,05	21,55	26,48	27,48	25,74	25,60	24,07	29,53	28,33	28,00	26,29	27,87	28,71	25,72	27,74	27,81	28,18	27,08	27,88	26,14	29,88	28,53	28,69	
P08	20,43		18,20	22,35	25,14	25,14	24,33	22,12	26,13	26,66	26,80	17,14	26,91	26,62	25,83	27,06	25,22	27,25	21,87	21,71	26,11	27,44	25,55	26,46	
P09		18,74	19,93	20,54	26,71	24,36	25,01	19,94	21,51	25,59		26,59	26,08	22,59	25,57	26,68	27,24	28,30	27,25	25,19	21,52	25,39	25,67	26,39	
P10	20,60	20,68	21,74		28,45	24,57	26,57		18,67	24,75	20,26	25,88	27,01	26,82	26,82	29,74	27,90	27,59	28,87	29,28	29,84	29,77	28,22	27,68	30,46
P11	20,69	18,64	19,93	16,72	24,04	24,18	24,60	23,05	24,23	27,30		26,06	28,24	25,69	27,45	26,62	26,77	28,25	24,46	25,48	26,61	27,09	27,05	26,42	29,73
P12	25,32	23,82	20,45	24,17		26,44	23,15	25,31	34,85	31,43	28,63	28,06	25,41	26,40	27,41	27,38	28,34		27,01	28,05	29,78	28,09	28,43	27,92	31,98
P13	22,15	21,96	23,63	22,06	23,98	24,60	27,54	28,70	28,31	30,23		27,30	27,73	30,10	27,52	28,96	29,61	28,16	28,77	28,67	28,10	28,22	28,84	27,70	31,55
P14	23,96	20,53	25,47	27,31	27,71	28,80	23,05	21,34	27,72	28,65	24,50		25,15	26,73	27,17	28,81	27,47	26,74	28,47	27,84	27,53	26,62	29,33	30,44	29,51
P15	27,91	23,69	19,25	27,96	26,69	26,03		25,13	32,90	31,03		31,35	28,53	29,58	30,44	32,10	29,97	30,60		29,38	26,84	29,84	26,89	28,51	31,22
P16	21,85	22,73	23,76		27,87	26,93	23,40	24,78	29,78	19,63	19,61		27,72	28,32	27,56	27,81	27,48	26,20	25,38	24,56	25,41	28,24	26,87	28,59	36,75
P17	22,68	25,97	25,31	21,99	24,65	23,81	22,63		17,73	24,87	28,24	29,24	26,50	21,27	24,89	25,20	23,65	25,47	25,71	23,64	24,82	27,26	26,85	26,94	30,78
P18	23,42	21,11	22,33	19,44	22,05	25,26	17,57		28,84	26,80	24,97	26,15	28,10	29,94	28,85	28,85	26,46	24,12	23,60	20,70	25,52	30,04	27,63	30,35	34,11
P19	18,58	17,42		18,16	24,11		21,75	21,03	25,24		21,84	23,85	25,20	21,83	21,58	23,93	23,51	22,63	21,32	22,99	21,46	26,87	23,25	25,69	27,77
P20	21,82	19,42	20,30	20,31	20,16	22,35	21,68	20,53	25,00	25,21		25,76	25,49	23,50	23,87	24,17	26,15	27,66	26,50	26,45	25,55	26,16	24,40	24,54	30,70
P21	21,70	20,75	18,86	19,08	23,20	22,97	20,09	21,33	29,14	28,29	19,70	24,93	23,43	22,23	22,25	24,55	23,96	25,80	24,46	23,68	23,79	25,67	25,43	25,52	29,17
P22	22,29	15,52		21,81	20,46	17,90			21,38	20,82	20,87	21,44	24,09	21,87	22,74	22,89	24,35	23,29	23,63	22,69	22,23	25,94	24,21	28,40	28,72
P23	17,46	16,74	15,90	16,36	19,35	20,54	19,07	19,28	24,71	22,67	21,81	21,59	22,91	21,84	20,82	23,69	21,93	21,93	21,12	24,91	22,82	24,72	22,50	24,45	28,71
P24	15,16		18,41	15,76	13,93	14,03	16,03	14,77	20,95	17,14	18,05	18,39	19,45	17,54	17,87	18,04	16,68	17,55	18,14	17,51	18,01	18,34	17,17	18,77	23,27
P25	24,79		22,23	20,19	17,76	23,36	22,20	21,52	29,58	26,20	25,40	26,71	26,22	25,59	23,61	23,77	24,72	24,56	24,48	21,92		25,79	26,24	27,23	
P26	16,79	18,34	16,17		19,49	20,86	18,13	16,63	23,17		20,23	17,78	20,97	19,75	19,88	20,51	22,16	19,87	19,13	18,47	17,10	20,34	18,68	19,57	

Onde: células vazias representam problemas de inconsistência ocorridos durante as coletas ou nas análises laboratoriais

