

UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO DE CIÊNCIAS AGRÁRIAS
DEPARTAMENTO DE CIÊNCIAS FLORESTAIS E DA MADEIRA

ESTEVÃO GIACOMIN ALVES

ESTIMAÇÃO DA UMIDADE DO SOLO USANDO FOTOGRAFIAS
DIGITAIS E REDES NEURAS ARTIFICIAIS

JERÔNIMO MONTEIRO
ESPÍRITO SANTO

2012

ESTEVIÃO GIACOMIN ALVES

ESTIMAÇÃO DA UMIDADE DO SOLO USANDO FOTOGRAFIAS
DIGITAIS E REDES NEURAS ARTIFICIAIS

Monografia apresentada ao
Departamento de Ciências
Florestais e da Madeira, da
Universidade Federal do Espírito
Santo, como requisito parcial para
obtenção do título de Engenheiro
Florestal.

JERÔNIMO MONTEIRO
ESPÍRITO SANTO
2012

ESTEVÃO GIACOMIN ALVES

ESTIMAÇÃO DA UMIDADE DO SOLO USANDO FOTOGRAFIAS
DIGITAIS E REDES NEURAIAS ARTIFICIAIS.

Monografia apresentada ao Departamento de Ciências Florestais e da Madeira da
Universidade Federal do Espírito Santo, como requisito parcial para obtenção do título
de Engenheiro Florestal.

Aprovado em 18 de outubro de 2012

COMISSÃO EXAMINADORA



SIDNEY SÁRA ZANETTI
Prof. D.Sc, DCFM - CCA – UFES
Orientador



ROBERTO AVELINO CECÍLIO
Prof. D.Sc, DCFM – CCA – UFES
Examinador



OTACILIO JOSÉ PASSOS RANGEL
Prof. D.Sc, – IFES - ALEGRE
Examinador

" Procure ser um homem de valor, em vez de ser
um homem de sucesso."

Albert Einsten

AGRADECIMENTOS

Agradeço primeiramente a Deus, por me guiar, dar saúde e conceder inúmeros livramentos durante toda a minha vida, mesmo eu não merecendo.

Aos meus pais, Audebir e Jucelene, por terem incentivado meus estudos, e terem adiado parte de seus sonhos para que eu pudesse realizar o meu.

As minhas irmãs, Raquel e Priscilane, pelo amor incondicional.

À toda a minha família, tios, primos e avô, pela força e incentivo.

Ao professor Sidney que, com muita paciência, me ajudou na elaboração deste trabalho, e a todos os meus professores, pelos ensinamentos, que serão levados por toda uma vida.

Aos meus amigos Vitor, Gabrieli, Fernando Coelho, Allan e Mariana que me ajudaram diretamente com o experimento.

Aos meus amigos de faculdade em especial: Filipe, todos os amigos da Rep. Fenda do Bikini, Lorena e amigos que moraram comigo, agradeço pelas horas de amizade.

Aos meus amigos futuros Engenheiros Florestais, que ajudaram me dando força e me apoiando, não só na realização desse trabalho, como em toda a minha vida acadêmica.

À todas as pessoas que eu conheci em Alegre, as quais hoje eu posso com muita certeza chama-los de AMIGOS!

RESUMO

O presente trabalho consistiu no desenvolvimento e teste de modelos matemáticos baseados em redes neurais artificiais para estimação da umidade do solo a partir de fotografias do mesmo. Para obtenção dos dados necessários, foram utilizadas amostras de solo de diferentes tipos, com diferentes umidades, coletadas na camada superficial, as quais foram fotografadas usando uma câmera digital comum e suas umidades determinadas pelo método gravimétrico (padrão). Baseando-se no fato de que o solo muda de cor com a alteração de sua umidade, redes neurais foram treinadas (ajustadas) para estimar essa umidade usando fotografias digitais. Após o desenvolvimento, a umidade de amostras de solo foi estimada usando redes neurais e medidas pelo método gravimétrico, visando comparar os resultados, usando métodos estatísticos quantitativos, para identificar o desempenho das redes. Foram testadas 3 diferentes metodologias para coleta dos dados, visando identificar a de melhor desempenho para estimar a umidade através das fotografias, entretanto nenhuma das metodologias se destacou, sendo que em alguns casos as redes neurais artificiais treinadas não apresentaram correlação entre as umidades estimadas e observadas. Isso pode ter acontecido devido à simplicidade dos equipamentos utilizados. O método proposto, apesar de não ter apresentado resultados satisfatórios na maioria dos casos, representa um avanço no processo de estimação indireta da umidade do solo, pois apresenta as vantagens de ser um método prático, rápido, de baixo custo, não destrutivo, e que permite a automação do processo em campo.

Palavras-chaves: Teor de Água, Hidrologia, Modelos Empíricos.

SUMÁRIO

LISTA DE TABELAS.....	viii
LISTA DE FIGURAS.....	ix
1 INTRODUÇÃO	1
1.1 Objetivos	2
1.1.1 Objetivo geral	2
2 REVISÃO DE LITERATURA.....	3
2.1 Umidade do Solo.....	3
2.1.1 Métodos para a determinação da umidade no solo	4
2.2 Processamento de Imagens Digitais.....	8
2.2.1 Modelo de Cores – RGB	9
2.3 Redes Neurais Artificiais (RNA).....	11
3 MATERIAL E MÉTODOS.....	14
3.1 Obtenção dos Dados	14
3.1.1 Metodologia A	16
3.1.2 Metodologia B	17
3.1.3 Metodologia C	18
3.2 Treinamento das redes neurais artificiais	21
3.3 Avaliação dos resultados.....	24
4 RESULTADOS E DISCUSSÕES.....	26
4.1 Metodologia A	26
4.1.1 RNA para o Solo 1	26
4.1.2 RNA para o Solo 2	28
4.1.3 RNA para o Solo 3	29
4.1.4 RNA para os Solos 1,2,3	30

4.2 Metodologia B	32
4.2.1 RNA para o Solo 2	32
4.2.2 RNA para o Solo 3	33
4.2.3 RNA para os Solo 2, e Solo 3	34
4.3 . Metodologia C	36
4.3.1 RNA para o Solo 1	36
4.3.2 RNA para o Solo 2	37
4.3.3 RNA para o Solo 3	38
4.4 RNA para todos os dados de diferentes solos e metodologia.....	39
5 CONCLUSÕES	41
6 REFERÊNCIAS BIBLIOGRÁFICAS	42
7 APÊNDICE	46

LISTA DE TABELAS

Tabela 1 – Coordenadas geográficas dos pontos de amostragem dos solos utilizados no estudo	15
Tabela 2 – Características físicas dos solos Latossolo Vermelho-Amarelo e Cambissolo utilizados no experimento	15
Tabela 3– Resumo dos resultados das 20 tipos de RNA`s testadas para estimar a umidade do solo	27
Tabela 4 – Tabela 4 – REQM (raiz do erro quadrático médio) e coef. E (coeficiente de eficiência) para as melhores RNA para cada tipo de solo e metodologia testada	38

LISTA DE FIGURAS

Figura 1 – Círculo de cores aditivas	09
Figura 2 – Cubo representando o espaço de cores RGB	10
Figura 3 – Modelo de neurônio utilizado na rede neural artificial. Fonte: Adaptado de Haykin (2001)	21
Figura 4 – Configuração da rede neural artificial utilizada no estudo	22
Figura 5 – Ajuste entre umidades observadas e estimadas do solo 1 utilizando a rede neural artificial treinada e as respectivas fotografias digitais	28
Figura 6 – Ajuste entre umidades observadas e estimadas do solo 2 utilizando a rede neural artificial treinada e as respectivas fotografias digitais	29
Figura 7 – Ajuste entre umidades observadas e estimadas do solo 3 utilizando a rede neural artificial treinada e as respectivas fotografias digitais	30
Figura 8 – Ajuste entre umidades observadas e estimadas para uma rede treinada para todos os 3 tipos de solo, simultaneamente	31
Figura 9 – Ajuste entre umidades observadas e estimadas do solo 2 utilizando rede neural artificial treinada e as respectivas fotografias digitais	33
Figura 10 – Ajuste entre umidades observadas e estimadas do solo 3 utilizando a rede neural artificial treinada e as respectivas fotografias digitais	34
Figura 11 – Ajuste entre umidades observadas e estimadas para uma rede treinada para todos os 2 tipos de solo, simultaneamente	35
Figura 12 – Ajuste entre umidades observadas e estimadas do solo 1 utilizando a rede neural artificial treinada e as respectivas fotografias digitais	37
Figura 13 – Ajuste entre umidades observadas e estimadas para todos os solos e metodologias simultaneamente, utilizando a rede neural artificial treinada e as respectivas fotografias digitais	40

1 INTRODUÇÃO

A demanda pelos recursos hídricos tem aumentado e, cada vez mais, percebe-se a necessidade de um manejo rigoroso e racional da água, de modo a assegurar a integridade, produtividade e diversidade dos sistemas agrícolas. Dentre as informações utilizadas no manejo da água, a umidade do solo constitui uma das mais importantes dentro do sistema solo-água-planta-atmosfera.

A umidade do solo é uma informação utilizada em projetos e estudos agrícolas, hidrológicos, meteorológicos, geotécnicos e florestais (ASSIS, 2008). A umidade influi em diversos parâmetros, tais como a resistência ao cisalhamento, a deformabilidade, a compressibilidade e a condutividade hidráulica, os quais influenciam diretamente nas práticas gerais de manejo e conservação do solo e da água.

Segundo Lopes et al. (2011), pode concluir que a umidade do solo exerceu grande influência sobre a resistência do solo em relação ao tráfego das máquinas de colheita da madeira, sendo que as maiores alterações nas propriedades físicas avaliadas ocorreram com o aumento da umidade do solo.

Existem diversos métodos para estimação da umidade do solo, dentre eles, destacam-se as técnicas que utilizam sonda de nêutrons, a reflectometria do domínio da frequência (FDR), o radar de penetração do solo (GPR) e a reflectometria do domínio do tempo - TDR (ASSIS, 2008).

A evolução da conscientização da necessidade do uso racional dos recursos naturais, principalmente da água, aliada ao avanço da eletrônica e informática, tem contribuído para o avanço tecnológico e intensificação dos estudos relacionados ao monitoramento da água no solo e automação dos processos de aquisição de dados.

Baseando-se no fato de que o solo muda de cor com a alteração de sua umidade, a partir da quantificação da cor, por meio de fotografias, pode-se estimar indiretamente o conteúdo de água no solo. Tal técnica tem sido motivo de alguns estudos no exterior, como por exemplo, os trabalhos desenvolvidos por Lihua et al. (2005) e Persson (2005). Esta técnica tem se mostrado promissora e pode ser considerada como um avanço no processo de estimação indireta da umidade do solo, pois apresenta as

vantagens de ser um método prático, rápido, relativamente de baixo custo, não destrutivo, e que permite a automação do processo em campo. O custo desse modelo é relativamente baixo quando comparado aos outros métodos, pois há necessidade de aquisição somente de uma máquina digital comum. Para diminuirmos ainda mais os custos, poderíamos fazer a secagem do solo por diferentes outros métodos. Dentre eles destacam-se: o método do forno microondas, o método do álcool, o Speed, EDABO e o método da frigideira.

1.1 Objetivos

1.1.1 Objetivo geral

O objetivo geral do presente trabalho foi desenvolver e avaliar modelos baseados em redes neurais artificiais (RNAs) para estimar a umidade do solo usando fotografias digitais do mesmo.

2 REVISÃO DE LITERATURA

2.1 Umidade do Solo

A importância da umidade no solo em sistemas agrícolas foi reconhecida há bastante tempo. O crescimento das plantas e a produtividade das culturas talvez estejam mais proximamente relacionados com a umidade no solo que qualquer outro elemento meteorológico isolado, inclusive a chuva (BAIER & ROBERTSON, 1968).

A água é extremamente importante na produção vegetal e o seu manejo racional é decisivo para o desenvolvimento das plantas, visando evitar a sua falta ou excesso. Desta maneira, o conhecimento da distribuição da umidade no solo torna-se cada vez mais necessário, uma vez que está intimamente ligado às propriedades do sistema solo-água-planta, onde o domínio desse conhecimento é, certamente, um dos fatores indispensáveis para uma agricultura sustentável e com o mínimo de prejuízos ao meio ambiente (SOUZA & MATSURA, 2002).

A umidade no solo constitui-se numa das variáveis mais importantes nos processos de troca entre o solo e a atmosfera, bem como para estudos de infiltração, de drenagem, de condutividade hidráulica, de irrigação e mecanização agrícola e florestal. Além disso, é uma variável indispensável para o entendimento de muitos processos hidrológicos que estão envolvidos em uma grande variedade de processos naturais (geomorfológicos, climáticos, ecológicos, etc.) que atuam em diferentes escalas espacial e temporal (ENTIN et al., 2000).

A prática do cultivo irrigado exige o conhecimento prévio da umidade do solo como parâmetro básico para o cálculo do momento e a quantidade certa da lâmina de irrigação a ser aplicada. O custo relativo da água destinada à irrigação é elevado. Ela deve, portanto, ser aplicada na quantidade mais próxima possível daquela que a planta necessita (CALHEIROS & ARNDT, 1991).

Outra importância que exige o conhecimento prévio da umidade do solo é na mecanização e manejo do solo. Eavis (1972) destaca que a condição de umidade no momento em que o solo está sendo compactado tem grande influência na redução e

redistribuição do espaço poroso. Solos secos são mais resistentes a mudanças na distribuição do tamanho dos poros, e essa resistência é reduzida com o aumento do conteúdo de água. Sendo assim, é interessante que se obtenha uma curva de compactação para cada tipo de solo e que se evite o trabalho com máquinas próximo a este ponto ótimo de umidade do solo (MANTOVANI, 1997).

2.1.1 Métodos para a determinação da umidade no solo

Diversos são os métodos para a determinação da umidade do solo, como o gravimétrico, considerado o método direto padrão, além dos métodos indiretos, que estimam a umidade do solo, a partir de propriedades do solo, tais como termalização de nêutrons, resistência elétrica e reflectometria no domínio do tempo (TDR) (SOUZA & MATSURA, 2002).

Hignett (2000), analisando diversos métodos utilizados em medições do conteúdo de água no solo concluiu que cada um tem suas vantagens e desvantagens, sendo que em diferentes aplicações, a vantagem em uma pode ser desvantagem em outro.

2.1.1.1 Método gravimétrico

O método gravimétrico é o mais conhecido e utilizado, o qual consiste na amostragem do solo em campo e posterior análise em laboratório, O método gravimétrico apresenta resultados precisos a um custo relativamente baixo, quando usado como técnica laboratorial, mas para medidas no campo o acondicionamento e transporte das amostras podem reduzir a precisão dos resultados e, ainda, para amostragens repetidas em uma pequena área, podem causar interferência no local em estudo (SOUZA & MATSURA, 2002).

Este método consiste na retirada de amostras do solo desejado que, após serem hermeticamente embaladas, são enviadas ao laboratório. As amostras são pesadas e

postas para secas na estufa a uma temperatura de 105 °C. Após 24 horas, as amostras são pesadas novamente e obtém-se a massa de água através da diferença de massas. O teor de umidade gravimétrico é definido como sendo a relação entre a massa de água e a massa de solo.

Segundo Assis (2008), as principais vantagens desse método são:

- Resultados acurados;
- Pode ser utilizado para calibrar outros métodos devido à sua acurácia;
- Simplicidade do processo;
- O custo do equipamento é baixo quando comparado aos outros métodos.

Por outro lado, suas principais desvantagens são:

- A repetibilidade do processo é dificultada devido à impossibilidade de se retirar amostras do mesmo local onde foram retiradas as amostras originais;
- Processo de escavar, coletar e secar as amostras demanda muito tempo;
- Possibilidade de perda de umidade na manipulação das amostras;
- Não é apropriado para turfas e solos orgânicos, pois pode ocorrer perda de massa;
- Não é automatizado, impossibilitando, por exemplo a monitoração da umidade durante um intervalo de tempo.

2.1.1.2 Método da dispersão de nêutrons

O uso da sonda de nêutrons exige um treinamento especial para seu manuseio, principalmente pela presença de fontes radioativas. (SELKER et al., 1993; COELHO & OR, 1996).

A dispersão de nêutrons é extensamente usada para estimar o conteúdo de umidade volumétrica. Com este método, nêutrons rápidos são emitidos de uma fonte radioativa, e a velocidade é reduzida por intermédio de átomos de hidrogênio dentro do solo. Desde que a maioria dos átomos de hidrogênio no solo seja componente das moléculas de água, a proporção de nêutrons termalizados está relacionada ao conteúdo de umidade do solo. Este método oferece a vantagem de medir um grande volume do

solo, a possibilidade de sondar as várias profundidades e a obtenção de uma distribuição do perfil de umidade. Porém, também possui várias desvantagens: o custo alto do instrumento, perigo de radiação, insensibilidade nas proximidades da superfície do solo, insensibilidade a pequenas variações em conteúdo de umidade a pontos diferentes num raio de 30 a 40 cm, e variação em leituras, devido a variações de densidade do solo, que podem causar uma taxa de erro de até 15 % (PHENE, 1988 apud ZAZUETA & XIN, 1994; PALTINEANU & STARR, 1997).

2.1.1.3 Método da atenuação gama

O método de atenuação por raio gama é uma técnica radioativa que pode ser usada para determinar o conteúdo de umidade do solo. Este método assume que o espalhamento e a absorção de raios gama estão diretamente relacionados à densidade de matéria no caminho deles, e que o peso específico (densidade global) de um solo permanece relativamente constante com aumentos ou diminuições na umidade. Mudanças na densidade de molhamento são medidas pela técnica de transmissão de raios gama, e o conteúdo de umidade é determinado por esta mudança de densidade (ZAZUETA & XIN, 1994)

2.1.1.4 Sensores capacitivos

Mead et al. (1994) afirmam que a medição da constante dielétrica do solo em frequências menores que 1 GHz é um método alternativo de medição da umidade do solo, e que a microeletrônica possibilita a medição da capacitância dos eletrodos e a posterior correlação com a dinâmica da umidade volumétrica do solo. As vantagens dos sensores capacitivos, em relação aos métodos nucleares tradicionais de monitoramento da umidade, são bem maiores, tais como: equipamentos mais leves, instalação permanente, rápida resposta, ausência de efeitos radioativos e pouco erro aleatório de contagem associado.

2.1.1.5 TDR

O conhecimento da umidade do solo é imprescindível a qualquer estudo que envolva as propriedades do sistema solo-água-plantas. Sua determinação, pela técnica TDR (Time Domain Reflectometry = Reflectometria no Domínio de Tempo), é bastante exata. O uso da TDR tem-se difundido na área de pesquisas principalmente por ser um método não-destrutivo, por sua exatidão e pela possibilidade de automação da coleta dos dados (COELHO et al., 2006).

Para medidas de umidade do solo em laboratório e em campo, a utilização da TDR possui algumas vantagens quanto ao uso, principalmente pela precisão, possibilidade de multiplicação de leituras, repetição sem destruição da amostra de solo e pela segurança (TOPP et al., 1980; COELHO & OR, 1996).

A TDR baseia-se no efeito da umidade do solo sobre a velocidade de propagação de pulsos de microondas em cabos condutores envoltos por solo. (SOUZA & MATSURA, 2002).

A utilização dessa técnica tem se expandido e proporcionado uma contribuição relevante para os estudos da relação solo-água-plantas-atmosfera, possibilitando, dentre outros, avaliar a condutividade elétrica do extrato de saturação do solo (PERSSON & UVO, 2003).

De acordo com Or *et al.* (2004), as principais vantagens desse método são:

- Grande exatidão de resultados entre 1 e 2% de umidade do solo;
- Fácil calibração
- Diferentemente de outros métodos, não oferece riscos radioativos;
- Resolução espacial e temporal satisfatória;
- Medidas de simples obtenção, com possibilidade de coletá-las automaticamente.

2.2 Processamento de Imagens Digitais

Por Processamento Digital de Imagens (PDI) entende-se a manipulação de uma imagem por computador de modo que a entrada e a saída do processo sejam dados digitais. O objetivo de se usar processamento digital de imagens é melhorar o aspecto visual de certas feições estruturais para o analista humano e fornecer outros subsídios para a sua interpretação, inclusive gerando produtos que possam ser posteriormente submetidos a processamentos computacionais (CAMARA et al., 1996).

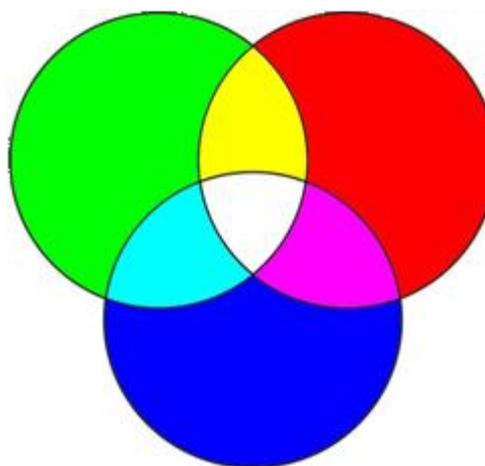
Brys (2008) afirma que a informação de interesse é caracterizada em função das propriedades dos objetos ou padrões que compõem a imagem. Portanto, extrair informação de imagens envolve o reconhecimento de objetos ou padrões. A maior parte dessa atividade requer grande capacidade de cognição por parte do intérprete, devido à complexidade dos processos envolvidos e à falta de algoritmos computacionais precisos o bastante para realizá-lo de forma automática.

O sistema visual humano possui uma notável capacidade de reconhecer padrões. Contudo, ele dificilmente é capaz de processar o enorme volume de informação presente numa imagem. Vários tipos de degradações e distorções, inerentes aos processos de aquisição, transmissão e visualização de imagens, contribuem para limitar ainda mais essa capacidade do olho humano (BRYS, 2008).

2.2.1 Modelo de Cores – RGB

Existem diversos modelos de cores, dentro dos quais podemos citar: CMY, o qual é baseado nas cores primárias subtrativas: azul (Cyan), magenta (Magenta) e amarelo (Yellow); YIQ, o qual é empregado no sistema NTSC (*National Television Standards Committee*), sendo um dos modelos criados para permitir que as emissões dos sistemas de televisão em cores fossem compatíveis com os receptores em preto e branco, e por fim, o modelo RGB.

O modelo de espaço de cores RGB é provavelmente o mais usado entre os modelos de cores, especialmente para dados de 8 bits. A teoria do espaço de RGB (vermelho-verde-azul), de Thomas Young (1773-1829), é baseada no princípio de que diversos efeitos cromáticos são obtidos pela projeção da luz branca através dos filtros vermelho, verde e azul e pela superposição de círculos nas cores projetadas (Figura 1).



Cores Aditivas

Figura 1 – Círculo de cores aditivas

Conforme Souto (2000), a luz branca é produzida se os três círculos coincidirem, sendo uma composição entre as cores primárias. As cores primárias não podem ser produzidas pela mistura de duas delas, por isso são definidas como cores primárias aditivas (Figura 1). Outras cores são produzidas quando duas cores se misturam:

- vermelho + azul = magenta
- vermelho + verde = amarelo
- verde + azul = ciano

Com a variação da quantidade relativa das cores primárias, uma enorme gama de cores pode ser produzida, se incluir diversos tons a cada uma delas. O espaço de cores RGB é tradicionalmente representado através de uma figura geométrica denominada de “cubo das cores”, apresentado na Figura 2.

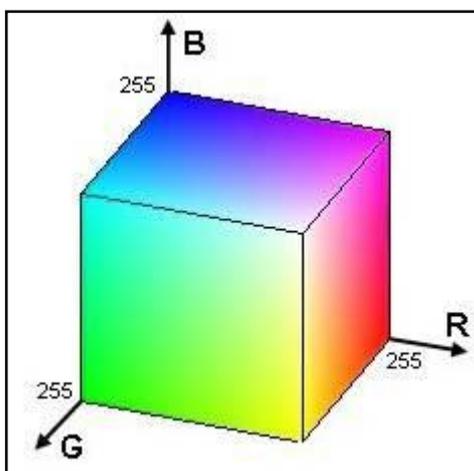


Figura 2 – Cubo representando o espaço de cores RGB.

Na Figura 2, os valores sobre os eixos R, G e B variam de 0 a 255. Note que os vértices do cubo representam as cores aditivas primárias e secundárias. Sobre as arestas do cubo, diz-se localizarem as cores saturadas neste espaço.

2.3 Redes Neurais Artificiais (RNA)

Rede neural artificial (RNA) é uma técnica de inteligência artificial que tenta simular, de uma maneira simplificada, o funcionamento do cérebro humano. Ela é capaz de reconhecer padrões, extrair regularidades e detectar relações subjacentes em um conjunto de dados aparentemente desconexo. Além disso, ela apresenta habilidade de lidar com dados difíceis de serem analisados e de prever sistemas não lineares (MELLO, 2004).

Braga et. al (2000) define RNA como técnicas computacionais que apresentam um modelo inspirado na estrutura neural natural de organismos inteligentes e que adquirem conhecimento através da experiência. São compostas por unidades de processamento simples, que calculam determinadas funções matemáticas, denominadas neurônios ou nós. O neurônio é uma unidade de processamento de informação fundamental para operação de uma rede neural artificial. Pode-se dizer que redes neurais artificiais consistem em um modo de abordar a solução de problemas de inteligência artificial.

A RNA é formada a partir da combinação de diversos neurônios organizados em camadas: de entrada, intermediária (oculta) e de saída. As entradas simulam uma área de captação de estímulos, que podem ser conectadas em muitos neurônios, e resultarem em uma série de saídas. Na camada intermediária é feita a maior parte do processamento da rede por meio de conexões ponderadas. Estas conexões comparadas com o sistema biológico representam o contato dos dendritos com outros neurônios, formando assim as sinapses. A função da conexão em si é transformar o sinal de saída de um neurônio em um sinal de entrada do outro, ou ainda, orientar o sinal de saída para o mundo externo ou real. As diferentes possibilidades de conexões entre as camadas dos neurônios podem gerar muitas estruturas diferentes (TAFNER, 2008).

As redes neurais artificiais possuem como características a tolerância a falhas, adaptabilidade a novas condições, resolução de problemas com base no conhecimento passado e reconhecimento de padrões (HAYKIN, 2001).

Segundo Galvão et al. (1999), em função de sua estrutura não-linear, as redes neurais artificiais conseguem captar características mais complexas dos dados, o que

nem sempre é possível com a utilização das técnicas estatísticas tradicionais. Para Sudheer et al. (2003), a maior vantagem das redes neurais artificiais sobre os métodos convencionais é que elas não requerem informação detalhada sobre os processos físicos do sistema a ser modelado.

A solução de problemas através de redes neurais artificiais é bastante atrativa, já que a forma como estes são apresentados internamente pela rede cria a possibilidade de um desempenho superior ao dos modelos estatísticos convencionais (BRAGA et al., 2000).

Não se pode negar a utilidade dos modelos tradicionais, porém os mesmos apresentam características que geram dificuldades operacionais para sua efetiva aplicação, como o problema inerente em se trabalhar com modelos estatísticos complexos, suas hipóteses restritivas a serem satisfeitas e a dificuldade em se alcançarem conclusões e resultados por não especialistas (BENITE, 2003).

Existem diversos tipos de redes neurais e diferentes maneiras de classificá-las. Talvez a mais importante seja quanto à forma de aprendizado, que pode ser: supervisionado e não supervisionado. No aprendizado supervisionado, são sucessivamente apresentados à rede conjuntos de padrões de entrada e seus correspondentes padrões de saída. Durante este processo, a rede realiza um ajustamento dos pesos das conexões entre os elementos de processamento, segundo uma determinada lei de aprendizagem, até que o erro entre os padrões de saída gerados pela rede alcance um valor mínimo possível (BRAGA et al., 2000). Por exemplo, Perceptrons, Adaline e Madaline, Redes de Função de Base Radial, são algumas dentre as dezenas de redes com métodos de aprendizado supervisionado.

No aprendizado não supervisionado, a rede “analisa” os conjuntos de dados apresentados, determina algumas propriedades dos conjuntos de dados e “aprende” a refletir estas propriedades na sua saída. A rede utiliza padrões, regularidades e correlações para agrupar os conjuntos de dados em classes. As propriedades que a rede vai “aprender” sobre os dados podem variar em função do tipo de arquitetura utilizada e da lei de aprendizagem (BRAGA et al., 2000). Por exemplo, Mapa Auto-Organizável de Kohonen, Redes de Hopfield e Memória Associativa Bidirecional são redes com métodos de aprendizado não supervisionado.

A principal desvantagem das RNAs é a de não ter capacidade de explicação (DANDOLINI, 1997). Os dados entram nas redes e uma previsão sai, mas o tipo de relacionamento entre as variáveis não é revelado, assim como os detalhes de como elas se relacionam com os dados para se chegar às conclusões (FRANCIS, 2001). Por este motivo, as RNAs são recomendadas para serem aplicadas em áreas de conhecimento que não necessitam de modelos precisos da realidade física do problema ou onde os resultados do modelo são mais importantes que a compreensão de seu funcionamento.

3 MATERIAL E MÉTODOS

O presente trabalho consistiu no desenvolvimento de modelos matemáticos baseados RNAs para estimar a umidade do solo a partir de fotografias digitais. Para obtenção dos dados necessários, foram utilizadas amostras de solo com diferentes teores de água, as quais foram fotografadas usando uma câmera digital comum. As umidades das amostras de solo foram determinadas pelo método gravimétrico, que é considerado padrão.

Os modelos desenvolvidos foram utilizados para estimar a umidade das amostras dos solos. Para comparar os resultados, os dados de umidade obtidos pelos modelos foram comparados com os teores de água das mesmas amostras obtidas pelo método gravimétrico. A escolha do melhor modelo foi efetuado com base em métodos estatísticos quantitativos.

A câmera digital utilizada foi do tipo Canon PowerShot A710 IS, com resolução de 7.1 megapixels, sendo as fotos foram obtidas com regulagem automática e uso do flash.

3.1 Obtenção dos Dados

As amostras de solo utilizadas no presente estudo foram coletadas num Latossolo Vermelho-Amarelo e num Cambissolo. As amostras do Latossolo Vermelho-Amarelo foram coletadas ambas localizadas no município de Alegre-ES. As amostras do Cambissolo foram coletadas no município de Guaçuí-ES. Na tabela 1 são apresentadas as coordenadas geográficas onde os solos foram coletados. As análises de solo necessárias foram realizadas no Laboratório de Recursos Hídricos do Departamento de Ciências Florestais e da Madeira da UFES.

A cobertura vegetal encontrada nas amostras coletadas do Latossolo Vermelho-Amarelo (Solo 1 e Solo 3) era *Brachiaria brizantha*, com relevo inclinado, e a coleta próximo ao barranco. A cobertura vegetal encontrada nas amostras coletadas do Cambissolo (Solo 2) era *Coffea arabica*, com relevo inclinado e a coleta próximo ao barranco.

Tabela 1 – Coordenadas geográficas dos pontos de amostragem dos solos utilizados no estudo.

Descrição	Latitude	Longitude
Solo 1	20° 45' 40" S	41° 29' 40" O
Solo 2	20° 49' 57" S	41° 37' 03" O
Solo 3	20° 44' 57" S	41° 29' 20" O

As amostragens e análises dos solos foram realizadas na camada de 0 a 10 cm de profundidade. Foram coletadas três amostras de cada tipo de solo, em condições de umidade natural, representando três repetições. Dois tipos de amostras foram retirados em campo: amostras deformadas e amostras indeformadas.

Com as amostras deformadas, visando caracterizar o solo estudado, foram determinadas a sua composição granulométrica (textura) e o seu teor de matéria orgânica, em laboratório, seguindo-se os métodos padrão descritos por EMBRAPA (1997). As amostras indeformadas foram utilizadas para determinação da densidade do solo, utilizando-se o método do anel volumétrico, conforme mostrado na Tabela 2. A fim de aumentar a praticidade do método, as redes foram treinadas com umidades entre os pontos de murcha permanente (PMP), e capacidade de campo (CC), que seriam as umidades de interesse encontradas no dia a dia do campo.

Tabela 2 – Características físicas dos solos Latossolo Vermelho-Amarelo e Cambissolo utilizados no experimento.

Descrição	Areia [%]	Silte [%]	Argila [%]	Matéria orgânica [g/kg]	Densidade do solo [g/cm ³]	CC	PMP
						(-10 kPa) [kg/kg]	(-1.500 kPa) [kg/kg]
Solo 1 [*]	35	7	58	15,4	0,91	0,275	0,180
Solo 2 ^{**}	42	11	47	17,9	1,41	0,203	0,127
Solo 3 ^{***}	56	7	37	16,2	1,59	0,240	0,163

* Latossolo Vermelho-Amarelo coletado em Alegre-ES.

** Cambissolo coletado em Guaçuí-ES.

*** Latossolo Vermelho-Amarelo coletado na área experimental do CCA-UFES.

Os teores obtidos para areia, silte e argila permitem classificar os solos utilizados no estudo como argilosos, de acordo com o triângulo de agrupamento textural proposto por Lemos e Santos (1996).

Foram coletados e treinadas redes do mesmo solo (Latosolo Vermelho-Amarelo), pois eles foram coletados em locais diferentes e apresentaram diferenças em sua granulometria.

No experimento, foram utilizadas três metodologias distintas de obtenção de dados, sendo que os diferentes solos passaram pelas diferentes formas de obtenção de dados, para comparação dos resultados e seleção do modelo de RNA com melhor desempenho para estimar a umidade de cada tipo de solo. As metodologias foram comparadas visando identificar a que apresentasse uma RNA's melhor treinada no ajuste de umidade do solo através das fotografias digitais.

Foram necessárias diferentes metodologias visando prevenir sobre possíveis erros que poderiam estar acontecendo no processo de obtenção de dados, para a metodologia A, como por exemplo: diferenças de umidade na superfície e interior, onde a superfície do solo poderia se encontrar mais seca do que o restante do recipiente, influenciando na cor do solo antes da retirada da fotografia.

3.1.1 Metodologia A

No experimento foram utilizados três recipientes plásticos, de massa conhecida, com dimensões aproximadas de 30 cm de comprimento, 15 cm de largura e 7 cm profundidade (volume de três litros, aproximadamente). As superfícies inferiores dos recipientes foram previamente perfuradas, a fim possibilitar o escoamento da água, e fechadas com tela de malha fina, visando evitar a perda de solo.

Em seguida, as amostras deformadas de solo foram destorroadas e acondicionadas nos recipientes de plástico, de forma que ficasse o mais adensável possível, aproximando da densidade observada em campo. A superfície do solo foi previamente nivelada para reduzir as sombras causadas pela sua rugosidade no momento de obtenção das fotografias. Na sequência, os recipientes foram imersos em

bandejas com água a uma altura de aproximadamente $3/4$ da altura do solo, por um período de 48 horas, para saturar totalmente as amostras de solo por meio de ação capilar.

Desta forma, após a saturação em laboratório, os recipientes foram deixados em repouso por alguns instantes para que a água livre presente nos poros fosse drenada e, assim, fosse possível realizar a primeira coleta de dados. Os recipientes foram mantidos com a superfície superior do solo exposta para permitir a perda de água por evaporação, sendo deixadas em repouso por algumas horas para evaporar parte da água do solo. Periodicamente, após cada período de repouso, foram coletados os seguintes dados: massa dos conjuntos recipiente-solo e fotografia da superfície do solo, obtidos com balança de precisão e câmera digital, respectivamente. Este processo foi realizado diariamente até que o solo atingisse a umidade de equilíbrio higroscópico com o ar atmosférico.

3.1.2 Metodologia B

No experimento foram utilizados três recipientes plásticos, de massa conhecida, com dimensões aproximadas de 10 cm de comprimento, 8 cm de largura e 8,5 cm de profundidade (volume de 0,7 litros, aproximadamente). As superfícies inferiores dos recipientes foram previamente perfuradas, a fim possibilitar o escoamento da água, e fechadas com tela de malha fina, visando evitar a perda de solo.

Em seguida, as amostras deformadas de solo foram destorroadas e acondicionadas até aproximadamente a metade dos recipientes de plástico, de forma que ficasse o mais adensável possível, aproximando da densidade observada em campo. A superfície do solo foi previamente nivelada para reduzir as sombras causadas pela sua rugosidade no momento de obtenção das fotografias.

A parte superior restante dos recipientes foi preenchida com solo acondicionado em sacos de tecido de algodão, de forma a permitir a troca de umidade entre as partes do solo e, assim, as umidades de ambas as partes estarem sempre em equilíbrio. Esse saco tecido de algodão localizado na parte superior dos recipientes tem como objetivo

de evitar que a superfície do solo ressecasse mais rapidamente que o centro da amostra, apresentando assim diferença de umidade entre a superfície e o centro da amostra, o que influenciaria na cor do solo. Na sequência, os recipientes foram parcialmente imersos em bandejas com água a uma altura de 3/4 da altura total da coluna do solo, por um período de 48 horas, saturando as amostras de solo por meio de ações capilares.

Desta forma, após a saturação em laboratório, os recipientes foram deixados em repouso por alguns instantes para que a água livre presente nos poros fosse drenada e, assim, realizar a primeira coleta de dados. Os recipientes foram mantidos com a superfície superior exposta, coberta apenas pelo tecido de algodão, permitindo a perda de água por evaporação. As amostras foram deixadas em repouso por algumas horas para evaporar parte da água do solo. Periodicamente, após cada período de repouso, eram coletados os seguintes dados: as massas dos recipiente-solo e as fotografias digitais da superfície do solo, sendo obtidos com balança de precisão e câmera digital, respectivamente. Esse processo foi realizado diariamente até que o solo atingisse a umidade de equilíbrio higroscópico com o ar atmosférico.

Como se pode constatar, os recipientes com solo foram submetidos a ciclos de umedecimento (saturação) e secagem (metodologia A e B), fazendo com que as amostras de solo tivessem diferentes teores de água, a fim de possibilitar a coleta de dados sob diferentes condições de umidade, visando obter um maior número de dados observados, a serem utilizados no processo de treinamento (ajuste) das RNAs.

Procedimento semelhante foi realizado na Metodologia C, onde se iniciou as medições com solo seco ao ar, sendo adicionadas periodicamente porções de água para variar (aumentar) a umidade das amostras de solo e realizar as leituras, conforme descrito na sequência.

3.1.3 Metodologia C

No experimento foram utilizados três recipientes plásticos, de massa conhecida, com dimensões aproximadas de 11 cm de comprimento, 11 cm de largura e 10 cm de profundidade (volume de 1,2 litros, aproximadamente).

As amostras deformadas de solo foram deixadas em repouso até que atingisse o equilíbrio higroscópico com o ar atmosférico. Em seguida, essas amostras secas ao ar foram acondicionadas em recipientes de plástico até aproximadamente meio litro de solo, sendo compactada o máximo possível, a fim de aproximar com as condições de densidade observadas em campo.

Desta forma, após o acondicionamento do solo, os recipientes foram tampados a fim de evitar que o solo tivesse trocas higroscópicas com o meio em que se encontrava. Periodicamente, as amostras recebiam uma pequena quantidade de água na camada superior, e por capilaridade juntamente com a gravidade, a água era distribuída por todo o solo entrando em equilíbrio higroscópico entre as partes do solo, juntamente com a parte aérea do recipiente tampado. O processo sendo feito desta forma, evitaria uma possível diferença de umidade e cor do solo, que poderia existir entre a superfície da amostra e o seu centro. Após a adição da água, o solo do recipiente foi readensável, a fim de homogeneizar a quantidade de água no solo, aumentando assim a uniformidade da umidade e diminuindo o tempo de repouso para que o equilíbrio higroscópico fosse estabelecido. A superfície do solo foi nivelada após o revolvimento do solo para reduzir as sombras causadas pela rugosidade no momento de obtenção das fotografias.

Após a homogeneização, os recipientes foram deixados de repouso por vinte e quatro horas, sendo então coletados os seguintes dados: massa dos conjuntos recipientes-solo e fotografia da superfície do solo, obtidos com balança de precisão e câmera digital, respectivamente. Esse processo foi feito diariamente até que o solo atingisse a umidade de saturação do solo.

Para todas as metodologias (A, B e C), após a última medição, foi retirada uma amostra do solo de cada recipiente para obtenção da umidade final, por meio do método padrão de estufa (gravimétrico), que consiste na secagem do solo por 24 horas sob temperatura de 105°C. A partir da massa seca do solo contido nos recipientes, os teores de água do solo no momento de cada medição foram determinados por diferença, em relação à massa úmida existente.

Visando padronizar o processo de obtenção das fotografias, para que a única fonte de luz incidente sobre as amostras fosse proveniente do flash da câmera

fotográfica, foi utilizado um tubo de papelão com 30 cm de comprimento, 20 cm de largura e 20 cm de altura para a metodologia A, e outro tubo de papelão, com 7 cm de comprimento, 7 cm de largura e 18 cm de altura, para as metodologias B e C. Cada amostra a ser fotografada foi centralizada na extremidade inferior do tubo, instalado verticalmente sobre a superfície do solo, sendo a câmera fotográfica posicionada em sua extremidade superior.

De posse das fotografias digitais das amostras de solo, foi utilizado o programa computacional ImageJ para recortar amostras representativas das mesmas e obter os dados quantitativos de cada pixel, referentes às suas cores elementares (vermelho, verde e azul – RGB), do modelo RGB de cores descrito por Gonzales & Woods (2000), os quais foram correlacionados com a umidade do solo usando redes neurais. Foram recortadas, das fotografias, amostras quadradas de 100 por 100 pixels, totalizando 10 mil pixels. Após o recorte das fotografias, foram analisados e eliminados 50% dos pixels com cores mais claras e mais escuras, consideradas como discrepantes, que podem ocorrer por reflexão da luz ou presença de sombra, algum graveto, raiz, torrão ou grão de areia, que eventualmente poderia existir no solo, influenciando negativamente nos resultados. Após a eliminação dos pixels discrepantes, foram selecionados 100 pixels de cada fotografia para análise e obtenção dos modelos matemáticos.

Para identificar e eliminar possíveis pixels discrepantes (*outliers*) utilizou-se uma adaptação do método Box Plot (NIST/SEMATECH, 2010), o qual consiste no cálculo de um limite inferior e outro superior para cada conjunto de dados, sendo que os dados situados fora deste intervalo são considerados discrepantes e, portanto, eliminados da análise. Os limites inferior (LI) e superior (LS) foram definidos por:

$$LI = Q1 \quad \text{e} \quad LS = Q3$$

em que Q1 e Q3 são os valores correspondentes ao primeiro e terceiro quartil do somatório das cores elementares de cada pixel (R + G + B), respectivamente.

3.2 Treinamento das redes neurais artificiais

As RNAs utilizadas foram do tipo perceptron de múltiplas camadas (MLP, multilayer perceptron), com treinamento supervisionado, conforme utilizado por Zanetti et al. (2008). Nesse tipo de rede o sinal de entrada se propaga para frente (*feedforward*), camada por camada, sendo em seguida retro propagado para a correção do erro (ajuste dos parâmetros da rede); este procedimento é repetido por várias iterações até a finalização do treinamento.

As redes *feedforward* têm sido muito utilizadas para soluções de problemas envolvendo altos graus de não linearidade. Tais redes usam o treinamento supervisionado realizado por um algoritmo chamado de retro-propagação de erro (*error backpropagation*), o qual é baseado na regra de aprendizagem que “corrige” o erro durante o treinamento (BOCANEGRA, 2002).

Todos os neurônios presentes na RNA utilizada foram configurados com base no modelo apresentado por Haykin (2001) – Figura 3.

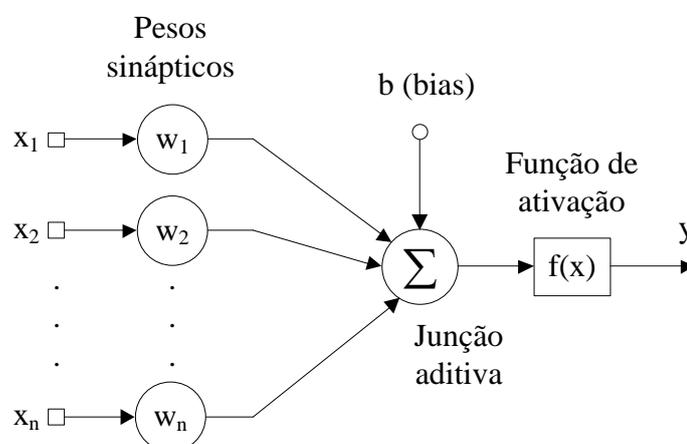


Figura 3 – Modelo de neurônio utilizado na rede neural artificial. Fonte: Adaptado de Haykin (2001).

Matematicamente, os neurônios utilizados podem ser descritos pela seguinte equação:

$$y = f\left(\sum_{i=1}^n w_i x_i + b\right) \quad (1)$$

em que y é o valor de saída do neurônio; $f(x)$ é a função de ativação; w_i são os pesos sinápticos; x_i são os dados de entrada; e b é o bias. No neurônio de saída da RNA, a umidade estimada corresponde ao seu valor de y .

Para fazer o treinamento supervisionado de uma rede neural, devem ser fornecidos exemplos de dados de entrada e de saída. No presente estudo, os dados de entrada foram obtidos das fotografias digitais das amostras de solo e os dados de saída foram os respectivos valores de umidade. Os dados disponíveis dos solos foram divididos em: repetições 1 e 2 para treinar as redes, repetição 3 para teste final da rede obtida.

A RNA foi configurada com uma camada de entrada com três variáveis (R, G e B), uma camada intermediária com número variável de neurônios (definidos em testes) e uma camada de saída com um neurônio, conforme ilustrado na Figura 4.

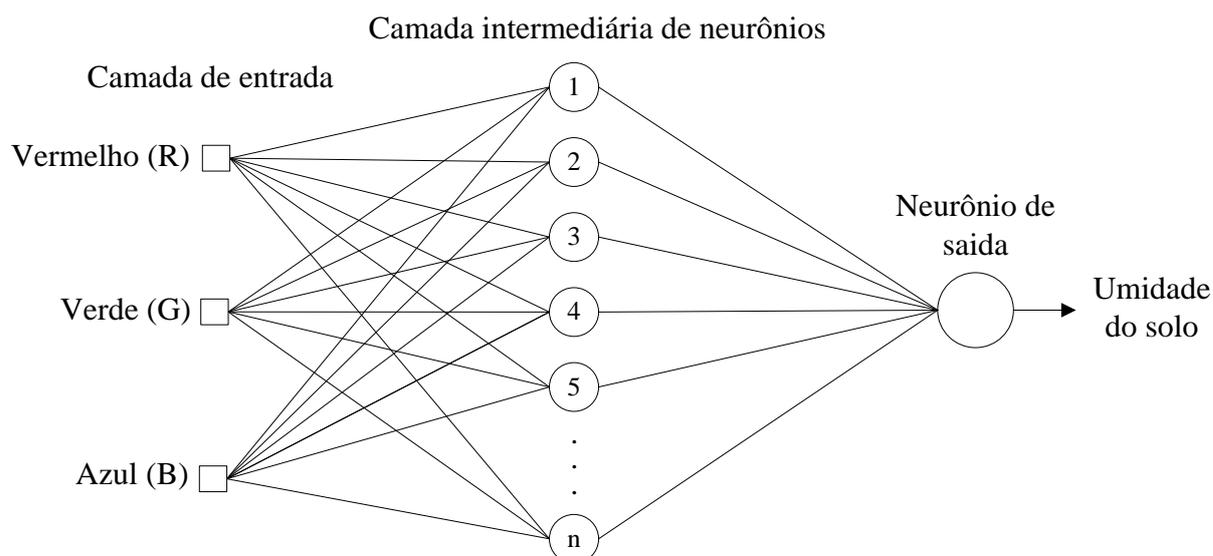


Figura 4 – Configuração da rede neural artificial utilizada no estudo.

A RNA foi treinada de forma supervisionada com o algoritmo de Levenberg-Marquardt, o qual utiliza o método de Newton para a minimização de erro e maximização do ajuste. Tal algoritmo foi adotado devido à sua superioridade em relação ao algoritmo padrão back-propagation, em termos de maior rapidez de convergência e, portanto, necessidade de menor número de iterações para treinar uma RNA, o que reduz o tempo de processamento computacional (ZANETTI et al., 2007).

Como critério para encerrar o treinamento, foi utilizado o método de treinamento com parada antecipada (HAYKIN, 2001), com o qual é possível

identificar o início do excesso de treinamento através do uso da validação cruzada. Para tanto, os dados de treinamento foram subdivididos em dois subconjuntos: um de estimação e outro de validação; o subconjunto de estimação foi utilizado para treinar a rede, sendo que, após cada iteração, a seção de treinamento era interrompida, visando realizar a validação cruzada. Enquanto o erro quadrático médio do subconjunto de validação se apresentava menor que o seu valor na iteração anterior, o treinamento da rede era continuado, caso contrário, o treinamento era finalizado, uma vez que, segundo Haykin (2001), o que a rede ajusta após esse momento é, essencialmente, o ruído contido nos dados de treinamento, ocasionando perda na capacidade de generalização (extrapolação) da rede.

Visando identificar a configuração de RNA que proporcione o melhor desempenho, foi realizado um estudo prévio no qual foram realizados vários testes, variando-se o número de neurônios e a função de ativação da camada intermediária. Foram testadas redes com 5, 10, 15, 20, e 30 neurônios na camada intermediária, com funções de ativação sigmoidal logarítmica – logsig (Equação 2) e/ou sigmoidal simétrica – tansig (Equação 3), apresentadas por Beale et al. (2010). Juntamente, foram testadas 2 diferentes formas de padronização dos dados de entrada para o treinamento das redes (Equação 4), sendo elas: “mapminmax” e/ou “map01”, totalizando 20 combinações diferentes de arquiteturas de rede. A maneira de calcular é a mesma para esses dois tipos diferentes de padronização de dados, mudando apenas os valores das variáveis “a” e “b”. Para “maxminmax” esses valores são -1 e 1, respectivamente. Para “map01” esses valores são 0 e 1, respectivamente.

$$f(x) = \frac{1}{1 + \exp(-x)} \quad (2)$$

$$f(x) = \frac{2}{1 + \exp(-2x)} - 1 \quad (3)$$

$$X_{\text{norm}} = (b - a) \frac{X_i - X_{\text{min}}}{X_{\text{max}} - X_{\text{min}}} + a \quad (4)$$

a = valor mínimo nos dados padronizados;

b = valor máximo nos dados padronizados;

Para cada combinação dessas características, as redes foram automaticamente treinadas e testadas dez vezes, possibilitando a escolha da melhor RNA para estimar a umidade solo a partir de fotografias digitais do mesmo. O treinamento e teste das RNAs foi realizado por meio de algoritmos computacionais implementados no programa MATLAB®.

3.3 Avaliação dos resultados

Após o processo de treinamento da RNA e utilizando-se o conjunto de dados destinado para teste da mesma (dados da repetição 3), os valores da umidade foram estimados com a rede neural a partir das fotografias e comparados com os valores de umidade calculados pelo método gravimétrico. O valor de umidade de cada imagem foi obtido a partir da média da umidade calculada com a RNA para cada um de seus 100 pixels analisados.

Os ajustamentos entre dados observados e estimados de umidade foram avaliados utilizando-se o índice de desempenho (c), proposto por Camargo & Sentelhas (1997), o qual é resultante da multiplicação entre o índice de concordância proposto por Willmott (1981) e o coeficiente de correlação de Pearson (r). O índice c é um valor adimensional, variando entre 0 e 1, sendo que o valor 1 representa o completo ajustamento, enquanto o valor zero indica o oposto.

Os ajustamentos entre dados observados e estimados de umidade foram avaliados utilizando-se o Coeficiente de Eficiência (E), proposto por Nash e Sutcliffe (1970) – Equação 5.

$$E = 1 - \frac{\sum_{i=1}^n (E_i - O_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (5)$$

em que

n = número de observações;

E_i = valor estimado pelo modelo;

O_i = valor observado experimentalmente; e

\bar{O} = média dos valores observados experimentalmente.

O coeficiente E pode variar entre $-\infty$ e 1, sendo que os maiores valores indicam melhor ajuste entre dados observados e estimados. Adicionalmente, foi calculada a raiz do erro quadrático médio (REQM) (Equação 6) e, ainda, gráficos representando os pontos observados e estimados, juntamente com o ajuste de regressões lineares simples ($Y = \beta_0 + \beta_1 X$) e o coeficiente de determinação (R^2).

$$\text{REQM} = \sqrt{\frac{\sum_{i=1}^n (E_i - O_i)^2}{n}} \quad (6)$$

em que:

REQM = raiz do erro quadrático médio [g. água/g. solo]

n = número de observações;

E_i = valor estimado pelo modelo;

O_i = valor observado experimentalmente;

4 RESULTADOS E DISCUSSÕES

4.1 Metodologia A

Correlacionando-se as variáveis R-G-B das fotografias obtidas no experimento realizado com os diferentes tipos de solo e suas respectivas umidades, verificou-se a rede que mais se destacou nos treinamentos para o solo 1; solo 2; solo 3; e uma RNA para estimar a umidade com os dados dos três solos simultaneamente.

4.1.1 RNA para o Solo 1

A tabela 3 apresenta o resumo dos resultados das 20 tipos de RNA`s testadas para estimar a umidade do solo 1. Os quadros correspondentes às demais RNA`s treinadas para diferentes solos e metodologias se encontram-se no apêndice.

Para o solo 1, a RNA que apresentou melhores resultados foi a rede neural com 15 neurônios, de função de ativação “tansig”, forma de padronização “mapminmax”, pois apresentou melhores resultados no momento do teste, tendo um menor raiz do erro quadrado médio (REQM) e um maior coeficiente E.

Tabela 3 – Resumo dos resultados das 20 tipos de RNA`s testadas para estimar a umidade do solo 1.

Nº neurônios	Função de ativação	Forma de padronização	Tr		Val		Ts		
			REQM [g. água/g. solo]	E	REQM [g. água/g. solo]	E	REQM [g. água/g. solo]	E	
5	tansig	mapminmax	0,0326	0,4425	0,033	0,4364	0,0354	0,3568	
	logsig		0,0324	0,4499	0,0327	0,4463	0,0354	0,3563	
10	tansig		0,0319	0,4678	0,0322	0,4648	0,0354	0,3553	
	logsig		0,0319	0,4678	0,0322	0,4648	0,0354	0,3553	
15	tansig		0,0311	0,495	0,0313	0,4935	0,0351	0,3660	
	logsig		0,0313	0,488	0,0318	0,4771	0,0358	0,3438	
20	tansig		0,0307	0,5068	0,0313	0,4944	0,0357	0,3445	
	logsig		0,0307	0,5066	0,0311	0,5015	0,0359	0,3385	
30	tansig		0,0304	0,5171	0,0309	0,5057	0,0363	0,3245	
	logsig		0,0306	0,5102	0,0312	0,4962	0,0356	0,3488	
5	tansig		map01	0,0327	0,4417	0,0332	0,4307	0,0364	0,3214
	logsig			0,0326	0,4428	0,0331	0,433	0,0361	0,3295
10	tansig			0,0313	0,4862	0,0318	0,476	0,036	0,3353
	logsig			0,0315	0,482	0,032	0,4709	0,0359	0,3374
15	tansig			0,0311	0,4958	0,0316	0,4847	0,0359	0,3375
	logsig			0,0308	0,5026	0,0311	0,4989	0,0359	0,3395
20	tansig			0,0307	0,5076	0,0312	0,4957	0,0359	0,3397
	logsig			0,0308	0,504	0,0311	0,5005	0,0358	0,3424
30	tansig	0,0312		0,4913	0,0317	0,4819	0,0356	0,3485	
	logsig	0,0304		0,5161	0,0309	0,5067	0,0359	0,3378	

Tr = dados de treinamento; Val = dados de validação; Ts = dados de teste

No gráfico contido na Figura 5 é apresentado o ajuste entre as umidades do solo 1 observadas e estimadas por meio da rede que apresentou melhores resultados de treinamento para esse tipo de solo, utilizando-se os dados da repetição 3, destinada ao teste dos modelos. O coeficiente de determinação (R^2) apresentou valor de 0,6411.

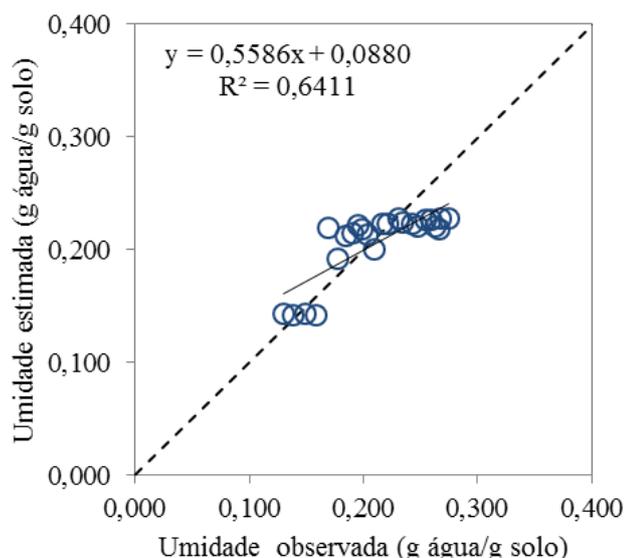


Figura 5 – Ajuste entre umidades observadas e estimadas do solo 1 utilizando a rede neural artificial treinada e as respectivas fotografias digitais.

Com os dados de umidade apresentados na Figura 5, obteve-se um índice de desempenho (c) de 0,6855. Este valor, de acordo com Camargo & Sentelhas (1997), é considerado bom, ou seja, o ajuste apresentado na Figura 5, entre umidades observadas e estimadas pela rede neural artificial, possui uma boa qualidade se for analisada apenas por esse parâmetro, porém ao analisarmos o gráfico podemos observar a existência de um espaço vago onde não temos umidade estimada, abandonando a linha de tendência ($y=x$), que seria o ideal.

4.1.2 RNA para o Solo 2

Para o solo 2, a RNA que apresentou melhores resultados foi a rede neural com 5 neurônios, de função de ativação “logsig”, forma de padronização “mapminmax”, pois apresentou melhores resultados no momento do teste, conseguindo correlacionar melhor as variáveis R-G-B com as umidades obtidas no experimento, conforme observado no apêndice (Quadro 1A).

No gráfico contido na Figura 6 é apresentado o ajuste entre as umidades do solo 2 observadas e estimadas por meio da rede que apresentou melhores resultados de

treinamento para esse tipo de solo, utilizando-se os dados da repetição 3 destinada os teste dos modelos. O coeficiente de determinação (R^2) apresentou valor de 0,4522.

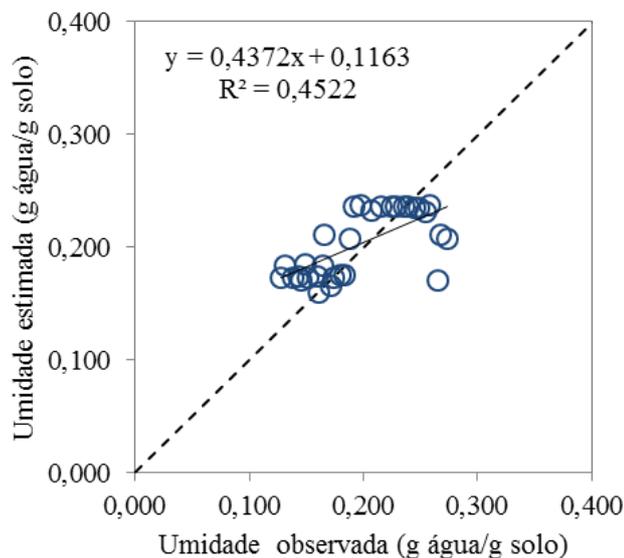


Figura 6 – Ajuste entre umidades observadas e estimadas do solo 2, utilizando a rede neural artificial treinada e as respectivas fotografias digitais.

Com os dados de umidade apresentados na Figura 6, obteve-se um índice de desempenho (c) de 0,5189. Este valor, de acordo com Camargo & Sentelhas (1997), é considerado sofrível, ou seja, o ajuste apresentado na Figura 6, entre umidades observadas e estimadas pela rede neural artificial, possui qualidade sofrível. Podemos observar no gráfico que os dados estão bastante dispersos e distantes da linha ($y=x$), que seria ideal.

4.1.3 RNA para o Solo 3

Para o solo 3, a RNA que apresentou melhores resultados foi a rede neural com 5 neurônios, de função de ativação “tansig”, forma de padronização “mapminmax”, pois apresentou melhores resultados no momento do teste, conseguindo correlacionar melhor as variáveis R-G-B com as umidades obtidas no experimento, conforme observado no apêndice (Quadro 2A)

No gráfico contido na Figura 7 é apresentado o ajuste entre as umidades do solo 3 observadas e estimadas por meio da rede que apresentou melhores resultados de treinamento para esse tipo de solo, utilizando-se os dados da repetição 3 destinada os teste dos modelos. O coeficiente de determinação (R^2) apresentou valor de 0,6160.

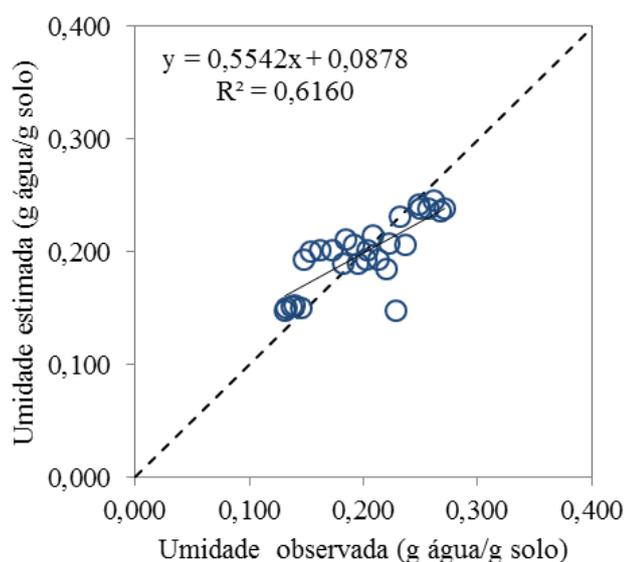


Figura 7 – Ajuste entre umidades observadas e estimadas do solo 3, utilizando a rede neural artificial treinada e as respectivas fotografias digitais.

Com os dados de umidade apresentados na Figura 7, obteve-se um índice de desempenho (c) de 0,6742. Este valor, de acordo com Camargo & Sentelhas (1997), é considerado bom, ou seja, o ajuste apresentado na Figura 7, entre umidades observadas e estimadas pela rede neural artificial, possui uma boa qualidade.

Tais resultados demonstram que a rede neural artificial treinada, apresentou um bom desempenho para estimar a umidade do solo a partir das fotografias digitais do mesmo.

4.1.4 RNA para os Solos 1, 2, 3

Para os três tipos de solo treinados simultaneamente, a RNA que apresentou melhores resultados foi a rede neural com 15 neurônios, de função de ativação “tansig”, forma de padronização “mapminmax”, pois apresentou melhores resultados

no momento do teste, conseguindo correlacionar melhor as variáveis R-G-B com as umidades obtidas no experimento, conforme observado no apêndice (Quadro 3A).

No gráfico contido na Figura 8 é apresentado o ajuste entre as umidades observadas e estimadas por meio da rede que apresentou melhores resultados de treinamento para esses solos simultaneamente, utilizando-se os dados das três repetições destinados ao teste dos modelos.

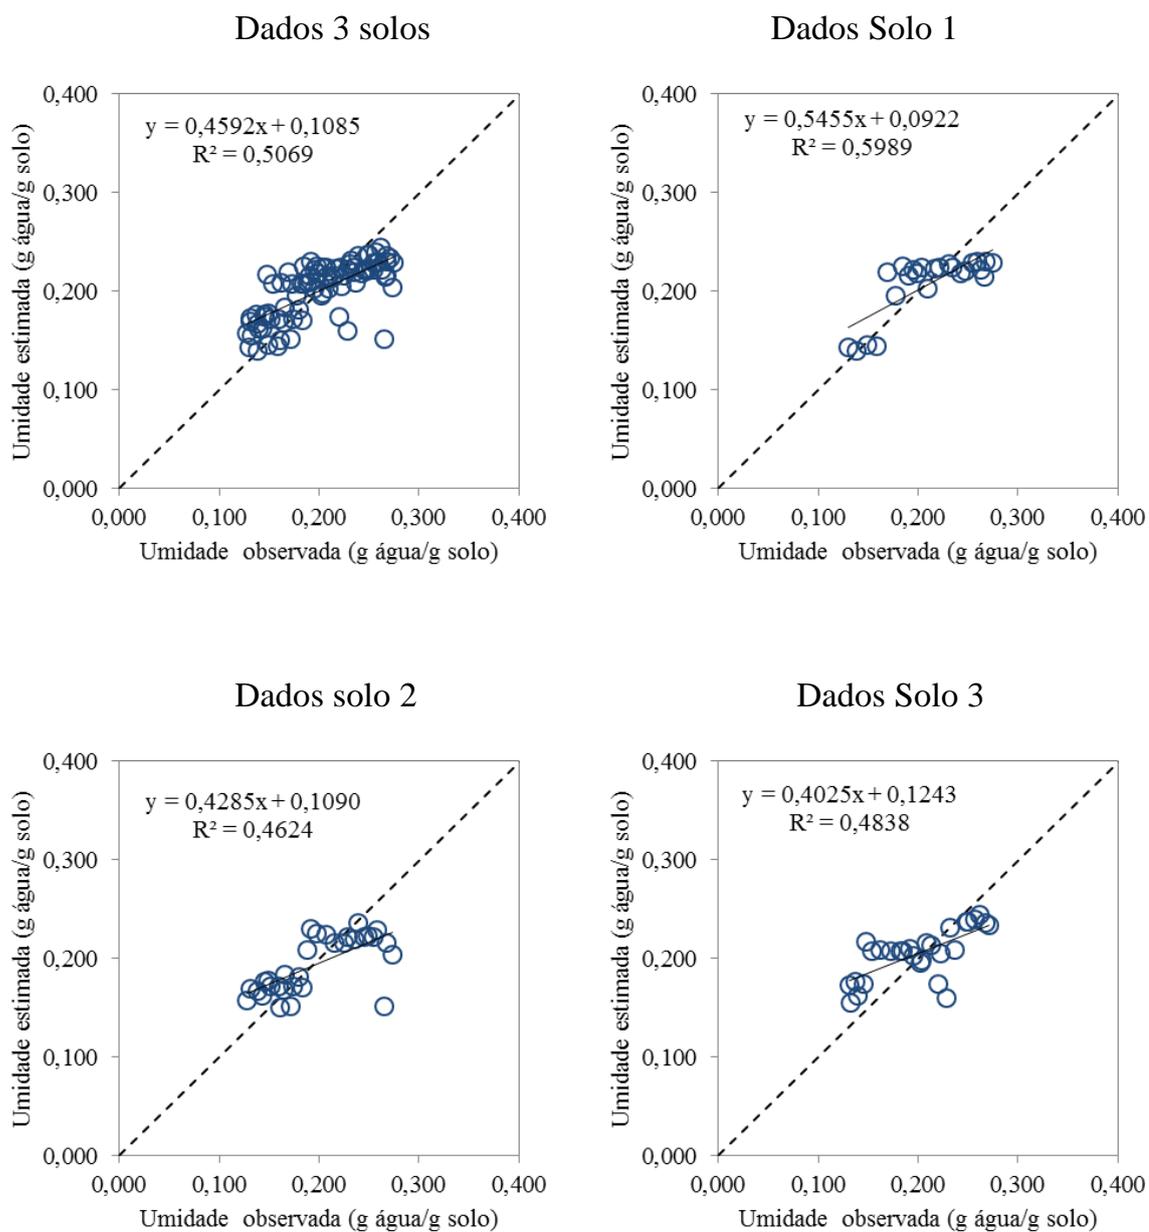


Figura 8 – Ajuste entre umidades observadas e estimadas para uma rede treinada para todos os 3 tipos de solo, simultaneamente.

O coeficiente de determinação (R^2) apresentou valores de 0,5069; 0,5989; 0,4624; 0,4838, para os dados de todos os 3 solos juntos; Solo 1; Solo 2; Solo 3, respectivamente.

Com os dados de umidade apresentados na Figura 8, obteve-se um índice de desempenho (c) de 0,5725; 0,6551; 0,5303; 0,5404, respectivamente.

Estes valor, de acordo com Camargo & Sentelhas (1997), é considerado sofrível, para o solo 2, solo 3, e o teste simultâneo para os 3 solos, e considerado mediano para o solo1, ou seja, o ajuste apresentado na Figura 8, entre umidades observadas e estimadas pela rede neural artificial, não possui uma boa qualidade.

Tais resultados demonstram que uma só rede neural artificial treinada, não apresentou um bom desempenho para estimar a umidade dos 3 tipos de solos simultaneamente a partir das fotografias digitais do mesmo.

4.2 Metodologia B

Correlacionando-se as variáveis R-G-B das fotografias obtidas no experimento realizado com os diferentes tipos de solo e suas respectivas umidades, verificou-se a rede que mais se destacou nos treinamentos para o solo 1; solo 2; solo 3; e uma rede para os três tipos de solo, respectivamente. Como nenhuma RNA treinada para o solo 1 conseguiu estimar a umidade do solo através da fotografia digital das mesmas, foi treinada uma RNA que pudesse estimar a umidade para o solo 2 e solo 3 simultaneamente.

4.2.1 RNA para o Solo 2

Para o solo 2, a RNA que apresentou melhores resultados foi a rede neural com 5 neurônios, de função de ativação “tansig”, forma de padronização “mapminmax”, pois apresentou melhores resultados no momento do teste, tendo um menor raiz do erro quadrado médio (REQM) e um maior coeficiente E, conseguindo assim

correlacionar melhor as variáveis R-G-B com as umidades obtidas no experimento, conforme observado no apêndice (Quadro 1D).

No gráfico contido na Figura 9 é apresentado o ajuste entre as umidades do solo 2 observadas e estimadas por meio da rede que apresentou melhores resultados de treinamento para esse tipo de solo, utilizando-se os dados da repetição 3 destinada os teste dos modelos. O coeficiente de determinação (R^2) apresentou valor de 0,6261.

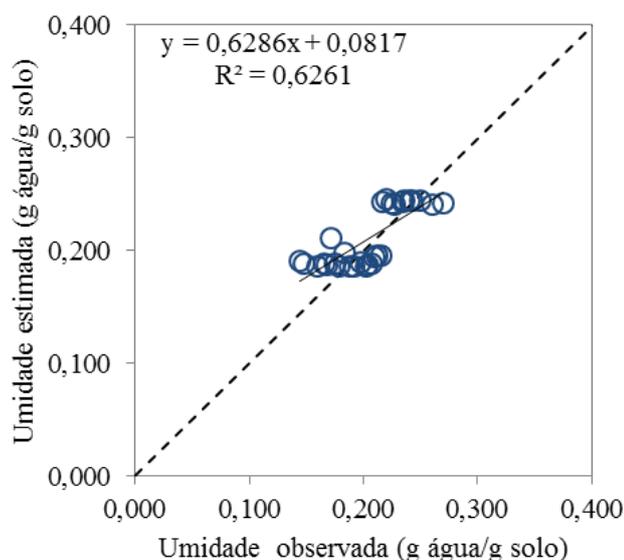


Figura 9 – Ajuste entre umidades observadas e estimadas do solo 2, utilizando a rede neural artificial treinada e as respectivas fotografias digitais.

Com os dados de umidade apresentados na Figura 9, obteve-se um índice de desempenho (c) de 0,6841. Este valor, de acordo com Camargo & Sentelhas (1997), é considerado bom, porém na análise de gráfico observa-se uma grande dispersão da linha que seria ideal ($y=x$), podendo assim concluir que essa RNA treinada apresentou péssimos resultados e baixa correlação entre as umidades.

4.2.2 RNA para o Solo 3

Para o solo 3, a RNA que apresentou melhores resultados foi a rede neural com 5 neurônios, de função de ativação “tansig”, forma de padronização “mapminmax”, pois apresentou melhores resultados no momento do teste, tendo um menor raiz do

erro quadrado médio (REQM) e um maior coeficiente E, conseguindo assim correlacionar melhor as variáveis R-G-B com as umidades obtidas no experimento, conforme observado no apêndice (Quadro 1E).

No gráfico contido na Figura 10 é apresentado o ajuste entre as umidades do solo 3 observadas e estimadas por meio da rede que apresentou melhores resultados de treinamento para esse tipo de solo, utilizando-se os dados da repetição 3 destinada os teste dos modelos. O coeficiente de determinação (R^2) apresentou valor de 0,6687.

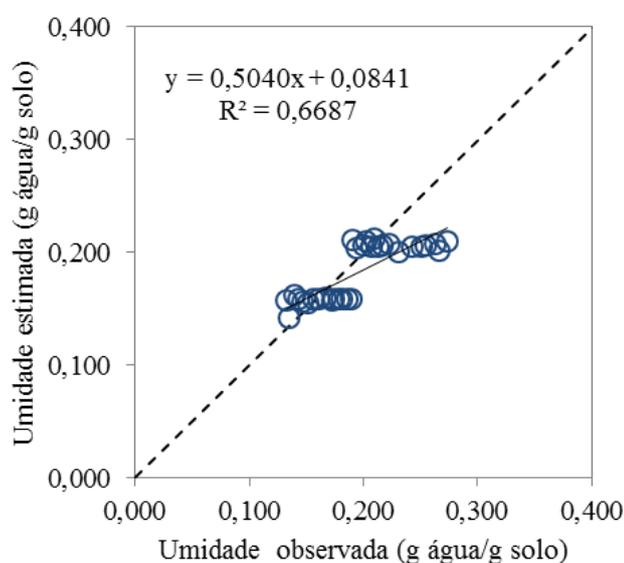


Figura 10 – Ajuste entre umidades observadas e estimadas do solo 3, utilizando a rede neural artificial treinada e as respectivas fotografias digitais.

Com os dados de umidade apresentados na Figura 10, obteve-se um índice de desempenho (c) de 0,6635. Este valor, de acordo com Camargo & Sentelhas (1997), é considerado bom, porém na análise de gráfico observamos uma grande dispersão da linha que seria ideal ($y=x$), podendo assim concluir que essa RNA treinada apresentou péssimos resultados e correlação entre as umidades baixa.

4.2.3 RNA para os Solo 2, e Solo 3

Para os dois tipos de solos treinados simultaneamente, a RNA que apresentou melhores resultados foi a rede neural com 10 neurônios, de função de ativação

“logsig”, forma de padronização “mapminmax”, pois apresentou melhores resultados no momento do teste, conseguindo correlacionar melhor as variáveis R-G-B com as umidades obtidas no experimento, conforme observado no apêndice (Quadro 1F).

No gráfico contido na Figura 11 é apresentado o ajuste entre as umidades observadas e estimadas por meio da rede que apresentou melhores resultados de treinamento para esses solos simultaneamente, utilizando-se os dados das três repetições destinados ao teste dos modelos.

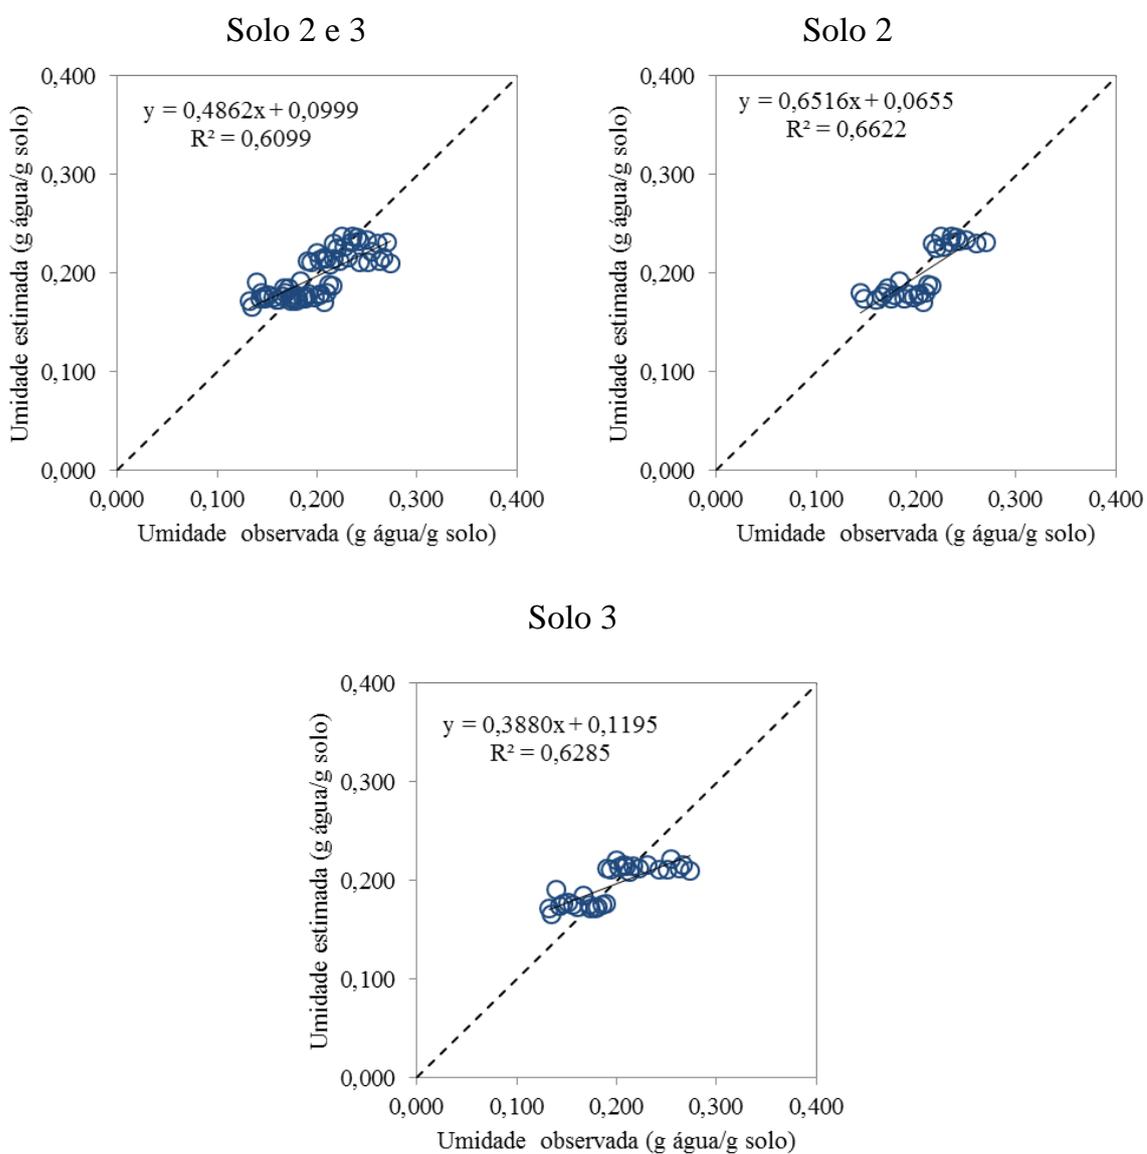


Figura 11 – Ajuste entre umidades observadas e estimadas para uma rede treinada para todos os 2 tipos de solo, simultaneamente.

O coeficiente de determinação (R^2) apresentou valores de 0,6099; 0,6622; 0,6285; e para o teste simultâneo para os 2 solos; Solo 2; Solo 3, respectivamente.

Com os dados de umidade apresentados na Figura 11, obteve-se um índice de desempenho (c) de 0,6449; 0,7147; 0,6110, respectivamente.

Este valor, de acordo com Camargo & Sentelhas (1997), é considerado mediano, bom, mediano, para o treino com os dois solos, solo 2 e solo 3 respectivamente. Porém na análise de gráfico observamos uma grande dispersão da linha que seria ideal ($y=x$), podendo assim concluir que essa RNA treinada apresentou péssimos resultados.

4.3 Metodologia C

Correlacionando-se as variáveis R-G-B das fotografias obtidas no experimento realizado com os diferentes tipos de solo e suas respectivas umidades, verificou-se a rede que mais se destacou nos treinamentos para o solo 1; solo 2; solo 3; e uma rede para os três tipos de solo, respectivamente. Como nenhuma RNA treinada para o solo 2 e solo 3 não conseguiu estimar a umidade do solo através da fotografia digital das mesmas, não foi treinada uma rede para estimar a umidade com os 3 tipos de solo simultaneamente.

4.3.1 RNA para o Solo 1

Para o solo 1, a RNA que apresentou melhores resultados foi a rede neural com 5 neurônios, de função de ativação “tansig”, forma de padronização “map01”, pois apresentou melhores resultados no momento do teste, tendo um menor raiz do erro quadrado médio (REQM) e um maior coeficiente E, conseguindo assim correlacionar melhor as variáveis R-G-B com as umidades obtidas no experimento, conforme observado no apêndice (Quadro 1G).

No gráfico contido na Figura 12 é apresentado o ajuste entre as umidades do solo 1 observadas e estimadas por meio da rede que apresentou melhores resultados de treinamento para esse tipo de solo, utilizando-se os dados da repetição 3 destinada ao teste dos modelos. O coeficiente de determinação (R^2) apresentou valor de 0,7357.

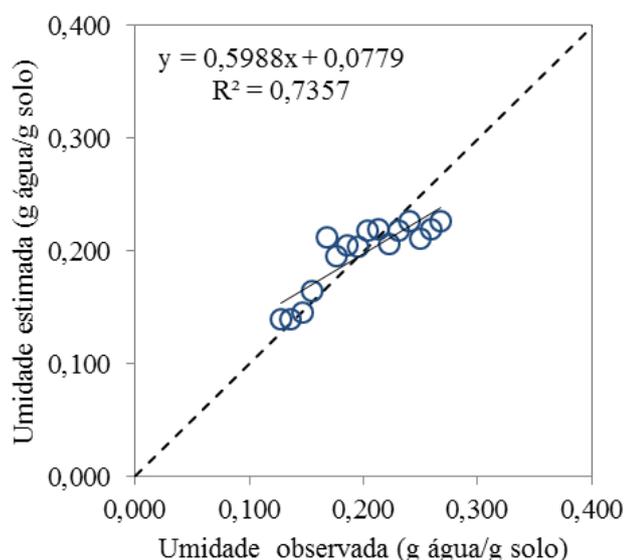


Figura 12 – Ajuste entre umidades observadas e estimadas do solo 1, utilizando a rede neural artificial treinada e as respectivas fotografias digitais.

A partir dos dados de umidade apresentados na Figura 12, obteve-se um índice de desempenho (c) de 0,7670. Este valor, de acordo com Camargo & Sentelhas (1997), é considerado muito bom, ou seja, o ajuste apresentado na Figura 12, entre umidades observadas e estimadas pela rede neural artificial, possui uma qualidade muito boa. Podemos observar no gráfico que existe um bom ajuste entre as umidades estimadas e observadas, acompanhando a linha que seria ideal ($y=x$).

4.3.2 RNA para o Solo 2

Para o solo 2, a RNA treinada não apresentou resultados satisfatórios que pudesse estimar a umidade do solo através da fotografia digital das mesmas..

4.3.3 RNA para o Solo 3

Para o solo 3, a RNA treinada não apresentou resultados satisfatórios que pudesse estimar a umidade do solo através da fotografia digital das mesmas.

Na tabela 4 é apresentados valores de REQM e coeficiente E para os diferentes tipos de solo, em suas diferentes metodologias.

Tabela 4 – REQM (raiz do erro quadrático médio) e coef. E (coeficiente de eficiência) para as melhores RNA para cada tipo de solo e metodologia testada.

	Metodologia	Solo 1	Solo 2	Solo 3
REQM [g. água/ g. solo]	A	0,026	0,034	0,027
	B	-	0,021	0,028
	C	0,023	-	-
coef. E	A	0,614	0,435	0,609
	B	-	0,596	0,530
	C	0,709	-	-

O coeficiente E pode variar entre $-\infty$ e 1, sendo que os maiores valores indicam melhor ajuste entre dados observados e estimados, já a raiz do erro quadrático médio (REQM) indicam o melhor ajuste entre os dados quando apresentados menores valores.

A RNA treinada para o Solo 1 na metodologia C se destacou, apresentando alto ajuste entre os dados observados e estimados.

- Para o Solo 1, a melhor RNA treinada foi para a metodologia C.
- Para o solo 2, a melhor RNA treinada foi para a metodologia A.
- Para o Solo 3, a melhor RNA treinada foi para a metodologia A.
- Para a metodologia A, a RNA treinada para o tiveram rendimentos semelhantes para todos os tipos de solo.
- Para a metodologia B, a RNA treinada para o Solo 2 foi melhor que o solo 3, não sendo possível o treinamento de uma rede com resultados satisfatórios para o solo 1.
- Para metodologia C, não foi possível treinar uma RNA que apresentasse resultados satisfatórios para o Solo 2 e Solo 3.

- Conforme observado para o solo 1, solo 2 e solo 3, para a metodologia A, as redes neurais artificiais treinadas para estimar a umidade do solo utilizando fotografias digitais do mesmo apresentaram desempenho “bom”, “suficiente” e “bom”, respectivamente. A rede neural artificial treinada para os dados dos três solos simultaneamente é considerada suficiente. Porém somente a análise do índice de Camargo & Sentelhas (1997), não podemos afirmar que tais redes foram boas.
- Para a metodologia B, as redes neurais artificiais treinadas para estimar a umidade do solo utilizando fotografias digitais apresentaram resultados “bom” e “suficiente”, para o solo 2, solo 3, respectivamente. Para o Solo 1 não foi possível treinar uma rede que apresentasse correlação entre a umidade estimada e observada. A rede neural artificial treinada para os dados dos três solos simultaneamente foi considerada mediana. Porém somente a análise do índice de Camargo & Sentelhas (1997), não podemos afirmar que tais redes foram boas.
- Na metodologia C, a rede neural artificial treinada apresentou correlação muito boa apenas com o solo 1.
- Usando equipamentos mais sofisticados, como radiômetros, acredita-se que seja possível obter melhores resultados. Todavia, a utilização de equipamentos mais complexos e de custos mais elevados limitaria a aplicabilidade prática do método proposto, podendo até inviabilizar sua utilização de forma geral.

4.4 RNA para todos os dados de diferentes solos e metodologia

Para todos os dados treinados simultaneamente, a RNA que apresentou melhores resultados foi a rede neural com 20 neurônios, de função de ativação “logsig”, forma de padronização “map01”, pois apresentou melhores resultados no momento do teste, tendo um menor raiz do erro quadrado médio (REQM) e um maior coeficiente E, conseguindo assim correlacionar melhor as variáveis R-G-B com as umidades obtidas no experimento, conforme observado no apêndice (Quadro 1H)

No gráfico contido na Figura 13 é apresentado o ajuste entre as umidades observadas e estimadas por meio da rede que apresentou melhores resultados de treinamento para esse tipo de solo, utilizando-se os dados das três repetições destinadas aos testes dos modelos. O coeficiente de determinação (R^2) apresentou valor de 0,2170.

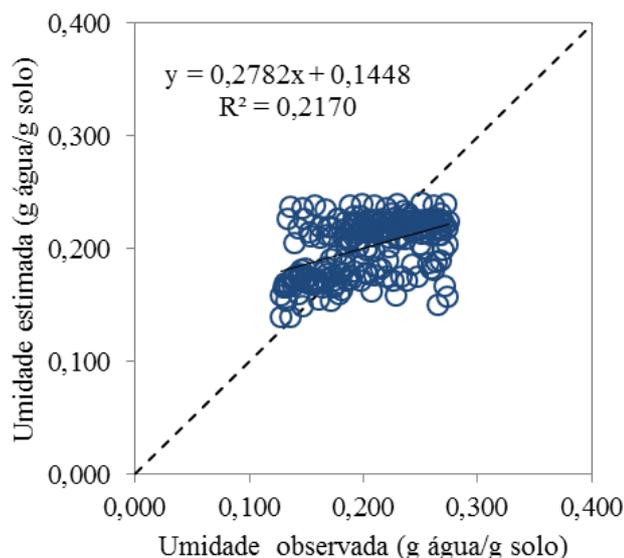


Figura 13 – Ajuste entre umidades observadas e estimadas para todos os solos e metodologias simultaneamente, utilizando a rede neural artificial treinada e as respectivas fotografias digitais.

Com os dados de umidade apresentados na Figura 13, obteve-se um índice de desempenho (c) de 0,3064. Este valor, de acordo com Camargo & Sentelhas (1997), é considerado péssimo, ou seja, o ajuste apresentado na Figura 13, entre umidades observadas e estimadas pela rede neural artificial, possui uma péssima qualidade.

Tais resultados demonstram que a rede neural artificial treinada, apresentou um péssimo desempenho para estimar a umidade do solo a partir das fotografias digitais do mesmo.

A RNA apresentou um REQM de 0,038 g. água/ g. solo. O coeficiente E apresentou valor de 0,194. Esses valores podem ser considerados alto e baixo, respectivamente, ou seja, a RNA possui um alto erro, comprovando que a rede treinada não apresentou bom ajuste entre os dados estimados e observados.

5 CONCLUSÕES

As redes neurais apresentaram melhor desempenho para o solo 1, na metodologia C, e para o solo 3, na metodologia A.

Embora o desempenho de muitas redes neurais artificiais tenha sido classificado como “bom” no índice de desempenho, na análise dos dados em gráficos, observou-se uma baixa correlação entre as umidades observadas e estimadas, não seguindo uma linha de tendência ideal ($y=x$).

As fotografias do solo foram obtidas utilizando uma câmera digital comum e com regulagem automática, com a intenção de obter um modelo simples, prático, rápido e de baixo custo. Entretanto, é possível que a simplicidade considerada no experimento não permitiu caracterizar adequadamente o padrão de variação da cor do solo em função da alteração de sua umidade, prejudicando assim os resultados.

6 REFERÊNCIAS BIBLIOGRÁFICAS

ASSIS, C. D. Avaliação de uma Sonda TDR Helicoidal para a Estimaco do Teor de Umidade dos Solos em Campo e Laboratrio. **Dissertao (Mestrado em Engenharia) – Universidade de So Paulo**, Escola de Engenharia de So Carlos, 178p., 2008.

BAIER, W.; ROBERTSON, G.W. The performance of soil moisture estimates as compared with the direct use of climatological data for estimating crop yields. **Agricultural Meteorology**, Amsterdam, v.5, p.17-31, 1968.

BEALE, M.H.; HAGAN, M.T.; DEMUTH, H.B. **Neural network toolbox: user's guide of MATLAB software**. Release 2012a, MathWorks, 2012.

BENITE, M. Aplicao de modelos de redes neurais na elaborao e anlise de cenrios macroeconmicos. So Paulo, 2003. 123p. **Dissertao (Mestrado em Engenharia) - Universidade de So Paulo**, Escola de Engenharia de So Carlos, 2003.

BOCANEGRA, C.W.R. Procedimentos para tornar mais Efetivo o Uso das Redes Neurais Artificiais em Planejamento de Transportes. 2002, 146 f. **Dissertao (Mestrado em Engenharia Civil – Transportes) – Escola de Engenharia de So Carlos**, Universidade de So Paulo, So Carlos.

BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDEMIR, T. B. Redes neurais artificiais: teoria e aplicaes. Rio de Janeiro: LTC, 2000. v. 1. 250 p.

BRYN, L. M. Pgina dinmica para aprendizado do sensoriamento remoto. **Dissertao de Mestrado pela Universidade Federal do Rio Grande do Sul**. Rio Grande do Sul, 2008.

CALHEIROS, C. B. M.; ARNDT, E. Comparao de mtodos de determinao da umidade do solo para fins de irrigao. **Cincias Agrcolas**, v. 1, n. 1, p. 7-14, 1991.

CAMARA, G.; SOUZA, R. C. M.; FREITAS, U.M.; GARRIDO, J. SPRING: Integrating remote sensing and GIS by object-oriented data modelling. **Computers & Graphics**, v. 20, n. 3, p. 395- 403, 1996.

CAMARGO, A.P.; SENTELHAS, P.C. Avaliao do desempenho de diferentes mtodos de estimativa da evapotranspirao potencial no Estado de So Paulo, Brasil. **Revista Brasileira de Agrometeorologia**, v.5, n.1, p.89-97, 1997.

COELHO, E. F.; OR, D. Flow and uptake patterns affecting soil water sensor placement for drip irrigation management. **Transactions of the ASAE**, St. Joseph, v. 39, p. 2007-2016, 1996.

COELHO, E. F.; VELLAME, L. M.; COELHO FILHO, M. A.; LEDO, C. A. S. Desempenho de modelos de calibração de guias de onda acopladas a TDR e a multiplexadores em três tipos de solo. **Revista Brasileira de Ciências de Solo**, v. 30, p. 23-30, 2006.

DANDOLINI, G.A. **Um procedimento para avaliação da saúde financeira de pequenas empresas: estudo de um caso usando redes neurais artificiais**. 1997. Dissertação (Mestrado em Engenharia de Produção), Universidade Federal de Santa Catarina, Florianópolis, 1997.

EAVIS, B. W. Soil physical conditions affecting seedling root growth: 1- mechanical impedance, aeration, and moisture availability as influenced by bulk density and moisture levels in a sandy loam soil. **Plant and Soil**, v.36, p.613-622, 1972.

EMBRAPA. **Manual e métodos de análises de solo**. 2. ed. Rio de Janeiro: CNPS, 212p., 1997.

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

FRANCIS, L. The Basics of Neural Networks Demystieild. **Contingencies**, p. 56-61, 2001.

GALVÃO, C. O.; VALENÇA, M. J. S.; VIEIRA, V. P. P. B.; DINIZ, L. S.; LACERDA, E. G. M.; CARVALHO, A. C. P. L. F.; LUDERMIR, T. B. **Sistemas inteligentes: Aplicações a recursos hídricos e ciências ambientais**. Porto Alegre: **UFRGS/ABRH**, 1999. 246p.

GONZALES, R. C. WOODS, R. E. **Processamento de imagens digitais**. São Paulo: **Edgard Blücher**, 509p. 2000.

HAYKIN, S. **Redes Neurais: Princípios e prática**. 2.ed. Porto Alegre: Bookman, 2001. 900p.

HIGNETT, C.T. Factors affecting the selecting of a soil water sensing technology. In: International Atomic Energy Agency. **Comparison of soil water measurement using the neutron scattering, time domain reflectometry and capacitance methods**, Viena: IAEA, p. 51-64, 2000.

LEMOS, R. C.; SANTOS, R. D. **Manual de descrição e coleta de solo no campo**. Sociedade Brasileira de Ciência do Solo – Centro Nacional de Pesquisa de Solos. 3. ed., p. 83, Campinas-SP, 1996.

LIHUA, Z.; MINZAN, L.; JIANYING S.; NING, T. XIJIE, Z. Estimation of soil moisture with aerial images and hyperspectral data. **Geoscience and Remote Sensing Symposium**, v. 6, p.4516- 4519, 2005.

LOPES, E. S.; SAMPIETRO, J. A.; LOMBARDI, K. C. and DIAS, A. N.. Avaliação da umidade na compactação do solo submetido ao tráfego de máquinas de colheita florestal. **Rev. Árvore [online]**. 2011, vol.35, n.3, suppl.1, pp. 659-667

MANTOVANI, E.C. Compactação do Solo. **Inf. Agropecuário**, 13:52-55, 1987.

MEAD, R. M.; PALTINEANU, I. C.; AYARS, J. E.; LIU, J. Capacitance probe use in soil moisture measurements . St. Joseph: **American Society of Agricultural Engineer**. 1994.(ASAE Paper, 94-2122).

MELLO, M.T. **Aplicação de Redes Neurais Artificiais no Processo de Precificação de Ações**. 2004. Monografia (Ciências da Computação), Universidade Federal de Pelotas, Pelotas.

NASH, J.E., SUTCLIFFE, J.V. (1970) River flow forecasting through conceptual models, I, A discussion of principles. **Journal of Hydrology**, 10:282-290.

NIST/SEMATECH. **e-Handbook of Statistical Methods**, <http://www.itl.nist.gov/div898/handbook>, 12 Jul. 2011.

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

PERSSON, M.; UVO, C.B. Estimating soil solution electrical conductivity from time domain reflectometry measurements using neural networks. **Journal of Hydrology**, v.273, p.249-256, 2003.

PERSSON, M. Estimating surface soil moisture from soil color using image analysis. **Vadose Zone Journal**; v.4, p.1119-1122, 2005b.

SELKER, J.R.; GRAFF, L.; STEENHUIS, T. Noninvasive time domain reflectometry moisture measurement probe. **Soil Science Society of America Journal**, Madison, v. 57, p. 934-936, 1993.

SOUTO, R. P. Segmentação de imagem multiespectral utilizando-se o atributo matiz .São José dos Campos: INPE, 2000. Disponível em <<http://www.obt.inpe.br/pgsere/Souto-R-P-2000/publicacao.pdf>>. Acesso em: 16 ago. 2012.

SOUZA, C.F.; MATSURA, E.E. Avaliação de sondas de TDR multi-haste segmentadas para estimativa da umidade do solo. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.6, n.1, p.63-68, 2002.

SUDHEER, K. P.; GOSAIN, A. K.; RAMASASTRI, K. S. Estimating actual evapotranspiration from limited climatic data using neural computing technique. **Journal of Irrigation and Drainage Engineering**, v. 129, n. 3, p. 214-218, 2003.

TAFNER, M.A. O Que são Redes Neurais Artificiais: <http://www.cerebromente.org.br/n05/tecnologia/rna.htm>. Acesso em: 20 de setembro de 2012.

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

WILLMOTT, C. J. On the validation of model. **Physical Geography**, v.2, n.2, p.184-194, 1981.

ZANETTI, S.S.; SOUSA, E.F.; OLIVEIRA, V.P.S.; ALMEIDA, F.T.; BERNARDO, S. Estimating evapotranspiration using artificial neural network and minimum climatological data. *Journal of Irrigation and Drainage Engineering*, Reston, v.33, n.2, p.83-89, 2007.

ZANETTI, Sidney S.; SOUSA, Elias F.; CARVALHO, Daniel F. de and BERNARDO, Salassier. **Estimação da evapotranspiração de referência no estado do Rio de Janeiro usando redes neurais artificiais**. *Rev. bras. eng. agríc. ambient.* [online]. 2008, vol.12, n.2, pp. 174-180. ISSN 1807-1929.

ZAZUETA, F. S.; XIN, J. Soil Moisture Sensors. Gainesville: **University of Florida**, 1994.12 p. (Bulletin, 292).

7 APÊNDICE

APÊNDICE A

QUADRO 1A – Resumo dos resultados das 20 tipos de RNA`s testadas para estimar a umidade do solo 2, metodologia A.

Nº neurônios	Função de ativação	Forma de padronização	Tr		Val		Ts		
			REQM [g. água/ g. solo]	E	REQM [g. água/ g. solo]	E	REQM [g. água/ g. solo]	E	
5	tansig	mapminmax	0,0241	0,6755	0,0239	0,7046	0,0384	0,2604	
	logsig		0,0260	0,6197	0,0257	0,6563	0,0368	0,3192	
10	tansig		0,0236	0,6884	0,0233	0,7173	0,0378	0,2822	
	logsig		0,0227	0,7099	0,0226	0,735	0,0373	0,3019	
15	tansig		0,0221	0,7259	0,0224	0,7407	0,0386	0,2531	
	logsig		0,0223	0,7212	0,0224	0,7389	0,0378	0,2806	
20	tansig		0,0215	0,7405	0,0219	0,7509	0,0387	0,2462	
	logsig		0,0213	0,7463	0,0219	0,7507	0,0385	0,2536	
30	tansig		0,0214	0,7436	0,0221	0,7470	0,0389	0,2417	
	logsig		0,0207	0,7594	0,0215	0,7609	0,0394	0,2196	
5	tansig		map01	0,0236	0,6877	0,0236	0,7120	0,0383	0,2620
	logsig			0,0236	0,6865	0,0236	0,7117	0,0379	0,2777
10	tansig			0,0223	0,7219	0,0226	0,7344	0,038	0,2740
	logsig			0,0222	0,7223	0,0225	0,7384	0,0384	0,2609
15	tansig			0,0213	0,7447	0,0218	0,7532	0,0390	0,2350
	logsig			0,0224	0,7186	0,0228	0,7312	0,0383	0,2631
20	tansig	0,0215		0,7406	0,0219	0,7504	0,0391	0,2322	
	logsig	0,0214		0,7432	0,0219	0,7514	0,0384	0,2581	
30	tansig	0,0209		0,7550	0,0216	0,7573	0,0386	0,2531	
	logsig	0,0208		0,7563	0,0215	0,7595	0,0392	0,2297	

Tr = dados de treinamento; Val = dados de validação; Ts = dados de teste

QUADRO 1B – Resumo dos resultados das 20 tipos de RNA`s testadas para estimar a umidade do solo 3, metodologia A.

Nº neurônios	Função de ativação	Forma de padronização	Tr		Val		Ts		
			REQM [g. água/g. solo]	E	REQM [g. água/g. solo]	E	REQM [g. água/g. solo]	E	
5	tansig	mapminmax	0,0260	0,6668	0,0244	0,7087	0,0331	0,4245	
	logsig		0,0262	0,6622	0,0245	0,7076	0,0332	0,4219	
10	tansig		0,0256	0,6779	0,0237	0,7258	0,0332	0,4235	
	logsig		0,0254	0,6831	0,0236	0,7284	0,0333	0,4181	
15	tansig		0,0252	0,6886	0,0232	0,7377	0,0338	0,4001	
	logsig		0,0248	0,6966	0,0229	0,7438	0,0336	0,4082	
20	tansig		0,0248	0,6974	0,0230	0,7421	0,0338	0,4005	
	logsig		0,0247	0,7000	0,0230	0,7416	0,0329	0,4315	
30	tansig		0,0244	0,7066	0,0231	0,7381	0,0333	0,4197	
	logsig		0,0247	0,7005	0,0228	0,7461	0,0343	0,3849	
5	tansig		map01	0,0266	0,6530	0,0249	0,6977	0,0335	0,4112
	logsig			0,0267	0,6505	0,0247	0,7023	0,0343	0,3827
10	tansig			0,0254	0,6840	0,0233	0,7336	0,0336	0,4073
	logsig			0,0249	0,6942	0,0229	0,7431	0,0335	0,4106
15	tansig			0,0246	0,7016	0,0228	0,7448	0,0338	0,3994
	logsig			0,0249	0,6960	0,0226	0,7491	0,0335	0,4121
20	tansig	0,0247		0,7003	0,0231	0,7382	0,0348	0,3635	
	logsig	0,0248		0,6986	0,0231	0,738	0,0342	0,3876	
30	tansig	0,0244		0,7084	0,0225	0,7525	0,0348	0,3642	
	logsig	0,0248		0,6982	0,0231	0,7398	0,0339	0,3961	

Tr = dados de treinamento; Val = dados de validação; Ts = dados de teste

QUADRO 1C – Resumo dos resultados das 20 tipos de RNA`s testadas para estimar a umidade do Solo 1, Solo 2 e Solo 3 simultaneamente para a metodologia A.

Nº neurônios	Função de ativação	Forma de padronização	Tr		Val		Ts		
			REQM [g. água/g. solo]	E	REQM [g. água/g. solo]	E	REQM [g. água/g. solo]	E	
5	tansig	mapminmax	0,0326	0,4425	0,033	0,4364	0,0354	0,3568	
	logsig		0,0324	0,4499	0,0327	0,4463	0,0354	0,3563	
10	tansig		0,0319	0,4678	0,0322	0,4648	0,0354	0,3553	
	logsig		0,0319	0,4678	0,0322	0,4648	0,0354	0,3553	
15	tansig		0,0311	0,4950	0,0313	0,4935	0,0351	0,3660	
	logsig		0,0313	0,4880	0,0318	0,4771	0,0358	0,3438	
20	tansig		0,0307	0,5068	0,0313	0,4944	0,0357	0,3445	
	logsig		0,0307	0,5066	0,0311	0,5015	0,0359	0,3385	
30	tansig		0,0304	0,5171	0,0309	0,5057	0,0363	0,3245	
	logsig		0,0306	0,5102	0,0312	0,4962	0,0356	0,3488	
5	tansig		map01	0,0327	0,4417	0,0332	0,4307	0,0364	0,3214
	logsig			0,0326	0,4428	0,0331	0,433	0,0361	0,3295
10	tansig			0,0313	0,4862	0,0318	0,476	0,0360	0,3353
	logsig			0,0315	0,482	0,0320	0,4709	0,0359	0,3374
15	tansig			0,0311	0,4958	0,0316	0,4847	0,0359	0,3375
	logsig			0,0308	0,5026	0,0311	0,4989	0,0359	0,3395
20	tansig	0,0307		0,5076	0,0312	0,4957	0,0359	0,3397	
	logsig	0,0308		0,504	0,0311	0,5005	0,0358	0,3424	
30	tansig	0,0312		0,4913	0,0317	0,4819	0,0356	0,3485	
	logsig	0,0304		0,5161	0,0309	0,5067	0,0359	0,3378	

Tr = dados de treinamento; Val = dados de validação; Ts = dados de teste

QUADRO 1D – Resumo dos resultados das 20 tipos de RNA`s testadas para estimar a umidade do solo 1, metodologia B.

Nº neurônios	Função de ativação	Forma de padronização	Tr		Val		Ts		
			REQM [g. água/g. solo]	E	REQM [g. água/g. solo]	E	REQM [g. água/g. solo]	E	
5	tansig	mapminmax	0,0228	0,5841	0,0222	0,5766	0,0237	0,4714	
	logsig		0,0221	0,6100	0,0216	0,6014	0,0239	0,4627	
10	tansig		0,0226	0,5910	0,0219	0,5887	0,0239	0,4641	
	logsig		0,0222	0,6038	0,0219	0,5904	0,0238	0,4693	
15	tansig		0,0219	0,6174	0,0214	0,6074	0,0247	0,4256	
	logsig		0,0215	0,6283	0,0211	0,6177	0,0247	0,4270	
20	tansig		0,0226	0,5897	0,0220	0,5865	0,0241	0,4544	
	logsig		0,0217	0,6214	0,0212	0,6128	0,0246	0,4330	
30	tansig		0,0209	0,6494	0,0207	0,6332	0,0259	0,3684	
	logsig		0,0219	0,6153	0,0217	0,5977	0,0241	0,4547	
5	tansig		map01	0,0228	0,5822	0,0224	0,5713	0,0238	0,4659
	logsig			0,0225	0,5933	0,0219	0,5885	0,0237	0,4704
10	tansig	0,0224		0,5997	0,0219	0,5880	0,0239	0,4621	
	logsig	0,0224		0,5988	0,0220	0,5853	0,0237	0,4720	
15	tansig	0,0223		0,6004	0,0216	0,5996	0,0238	0,4700	
	logsig	0,0225		0,5957	0,0220	0,5857	0,0240	0,4587	
20	tansig	0,0223		0,6023	0,0216	0,6016	0,0240	0,4600	
	logsig	0,0222		0,6061	0,0216	0,6015	0,0241	0,4536	
30	tansig	0,0222		0,6069	0,0216	0,6014	0,0238	0,4662	
	logsig	0,0222		0,6041	0,0216	0,6007	0,0238	0,4670	

Tr = dados de treinamento; Val = dados de validação; Ts = dados de teste

QUADRO 1E – Resumo dos resultados das 20 tipos de RNA`s testadas para estimar a umidade do solo 3, metodologia B.

Nº neurônios	Função de ativação	Forma de padronização	Tr		Val		Ts		
			REQM [g. água/g. solo]	E	REQM [g. água/g. solo]	E	REQM [g. água/g. solo]	E	
5	tansig	mapminmax	0,0315	0,438	0,0307	0,456	0,0301	0,4425	
	logsig		0,0311	0,451	0,0305	0,4634	0,0307	0,4208	
10	tansig		0,0318	0,428	0,0313	0,4372	0,0311	0,4071	
	logsig		0,0313	0,4462	0,0309	0,4504	0,0310	0,4123	
15	tansig		0,0307	0,4673	0,0302	0,473	0,0317	0,3829	
	logsig		0,0305	0,4726	0,0304	0,4686	0,0315	0,3895	
20	tansig		0,0307	0,4679	0,0301	0,4775	0,0318	0,3784	
	logsig		0,0303	0,4807	0,0300	0,4809	0,0315	0,3930	
30	tansig		0,0303	0,4794	0,0299	0,4842	0,0318	0,3810	
	logsig		0,0302	0,4831	0,0297	0,4906	0,0318	0,3811	
5	tansig		map01	0,0318	0,4286	0,0313	0,4351	0,0306	0,4245
	logsig			0,0315	0,438	0,031	0,4451	0,0304	0,4314
10	tansig	0,0309		0,4606	0,0304	0,4684	0,0313	0,3984	
	logsig	0,0318		0,4287	0,0314	0,4331	0,0308	0,4165	
15	tansig	0,0308		0,4615	0,0304	0,4683	0,0314	0,3951	
	logsig	0,0310		0,4558	0,0307	0,4571	0,0315	0,3925	
20	tansig	0,0306		0,4698	0,0304	0,469	0,0317	0,3848	
	logsig	0,0305		0,4734	0,0302	0,4736	0,0317	0,3836	
30	tansig	0,0304		0,4764	0,0303	0,4724	0,0317	0,3818	
	logsig	0,0308		0,4640	0,0308	0,4548	0,0317	0,3821	

Tr = dados de treinamento; Val = dados de validação; Ts = dados de teste

QUADRO 1F – Resumo dos resultados das 20 tipos de RNA`s testadas para estimar a umidade do Solo 2 e Solo 3 simultaneamente para a metodologia B.

Nº neurônios	Função de ativação	Forma de padronização	Tr		Val		Ts		
			REQM [g. água/g. solo]	E	REQM [g. água/g. solo]	E	REQM [g. água/g. solo]	E	
5	tansig	mapminmax	0,0313	0,3934	0,0312	0,3926	0,0272	0,4636	
	logsig		0,0308	0,4110	0,0308	0,4077	0,0272	0,4651	
10	tansig		0,0306	0,4191	0,0307	0,4145	0,0273	0,4620	
	logsig		0,0306	0,4172	0,0307	0,4121	0,0269	0,4778	
15	tansig		0,0304	0,4265	0,0305	0,4221	0,0272	0,4625	
	logsig		0,0306	0,4178	0,0307	0,4113	0,0270	0,4736	
20	tansig		0,0304	0,4276	0,0304	0,4248	0,0273	0,4584	
	logsig		0,0303	0,4305	0,0303	0,4286	0,0273	0,4611	
30	tansig		0,0302	0,4352	0,0304	0,4261	0,0274	0,4576	
	logsig		0,0301	0,4380	0,0303	0,4279	0,0276	0,4491	
5	tansig		map01	0,0312	0,3962	0,0312	0,3938	0,0273	0,4593
	logsig			0,0313	0,3935	0,0312	0,3951	0,0273	0,4593
10	tansig	0,0307		0,4152	0,0308	0,4104	0,0273	0,4597	
	logsig	0,0308		0,4094	0,0306	0,4157	0,0272	0,4643	
15	tansig	0,0305		0,4229	0,0306	0,4169	0,0274	0,4582	
	logsig	0,0305		0,4228	0,0305	0,4224	0,0271	0,4675	
20	tansig	0,0305		0,4238	0,0306	0,4175	0,0272	0,4646	
	logsig	0,0308		0,4117	0,0308	0,4087	0,0273	0,4596	
30	tansig	0,0301		0,4373	0,0302	0,4302	0,0277	0,4428	
	logsig	0,0307		0,4158	0,0307	0,4130	0,0274	0,4567	

Tr = dados de treinamento; Val = dados de validação; Ts = dados de teste

QUADRO 1G – Resumo dos resultados das 20 tipos de RNA`s testadas para estimar a umidade do solo 1, metodologia C.

Nº neurônios	Função de ativação	Forma de padronização	Tr		Val		Ts		
			REQM [g. água/g. solo]	E	REQM [g. água/g. solo]	E	REQM [g. água/g. solo]	E	
5	tansig	mapminmax	0,0235	0,6999	0,0263	0,6346	0,029	0,5506	
	logsig		0,0233	0,7041	0,0262	0,6395	0,0286	0,5648	
10	tansig		0,0231	0,7109	0,0258	0,6491	0,0288	0,5589	
	logsig		0,0230	0,7116	0,0260	0,6452	0,0291	0,5474	
15	tansig		0,0229	0,7143	0,0259	0,6470	0,0291	0,5488	
	logsig		0,0230	0,7124	0,0262	0,6373	0,0293	0,5407	
20	tansig		0,0228	0,7174	0,0260	0,6446	0,0292	0,5440	
	logsig		0,0234	0,7021	0,0262	0,6394	0,0290	0,5507	
30	tansig		0,0228	0,7178	0,0266	0,6275	0,0287	0,5608	
	logsig		0,0229	0,7137	0,0260	0,6442	0,0290	0,5498	
5	tansig		map01	0,0236	0,6974	0,0263	0,6346	0,0285	0,5665
	logsig			0,0239	0,6887	0,0266	0,6283	0,0287	0,5616
10	tansig	0,0233		0,7056	0,0264	0,6340	0,0289	0,5542	
	logsig	0,0230		0,7112	0,0259	0,6467	0,0289	0,5545	
15	tansig	0,0230		0,7112	0,0260	0,6438	0,0289	0,5545	
	logsig	0,0230		0,7113	0,0259	0,6482	0,0290	0,5512	
20	tansig	0,0230		0,7125	0,0259	0,6463	0,0288	0,5587	
	logsig	0,0229		0,7153	0,0255	0,6566	0,0288	0,5580	
30	tansig	0,0228		0,7161	0,0260	0,6454	0,0289	0,5539	
	logsig	0,0229		0,7152	0,0258	0,6494	0,0289	0,5539	

Tr = dados de treinamento; Val = dados de validação; Ts = dados de teste

QUADRO 1H – Resumo dos resultados das 20 tipos de RNA`s testadas para estimar a umidade de diferentes solos e metodologias.

Nº neurônios	Função de ativação	Forma de padronização	Tr		Val		Ts		
			REQM [g. água/g. solo]	E	REQM [g. água/g. solo]	E	REQM [g. água/g. solo]	E	
5	tansig	mapminmax	0,0328	0,4023	0,0329	0,3827	0,0337	0,3417	
	logsig		0,0331	0,3916	0,0333	0,368	0,0337	0,3424	
10	tansig		0,0322	0,4243	0,0322	0,4058	0,0337	0,3410	
	logsig		0,0320	0,4342	0,0320	0,4134	0,0336	0,3457	
15	tansig		0,0317	0,4423	0,0319	0,4178	0,0336	0,3463	
	logsig		0,0317	0,4417	0,0320	0,4156	0,0334	0,3536	
20	tansig		0,0316	0,4479	0,0318	0,4226	0,0335	0,3503	
	logsig		0,0316	0,4485	0,0319	0,4183	0,0334	0,3541	
30	tansig		0,0312	0,4608	0,0316	0,4305	0,0335	0,3520	
	logsig		0,0312	0,4605	0,0315	0,4325	0,0337	0,3442	
5	tansig		map01	0,0326	0,4125	0,0325	0,396	0,0342	0,3247
	logsig			0,0328	0,4027	0,0328	0,3854	0,0339	0,3366
10	tansig	0,0322		0,4266	0,0323	0,4035	0,0337	0,3434	
	logsig	0,0319		0,4359	0,0320	0,4135	0,0334	0,3542	
15	tansig	0,0317		0,4429	0,0319	0,4169	0,0336	0,3476	
	logsig	0,0315		0,4493	0,0319	0,4192	0,0335	0,3505	
20	tansig	0,0314		0,4521	0,0318	0,4207	0,0335	0,3520	
	logsig	0,0314		0,4532	0,0318	0,4227	0,0332	0,3626	
30	tansig	0,0315		0,4495	0,0318	0,4226	0,0333	0,3600	
	logsig	0,0312		0,4619	0,0316	0,4296	0,0335	0,3492	

Tr = dados de treinamento; Val = dados de validação; Ts = dados de teste