

Simulação da irrigação por aspersão utilizando redes neurais artificiais treinadas com e sem termo momentum

RESUMO

Joice Wolfrann

joice.sezm@gmail.com

Universidade Tecnológica Federal
do Paraná, Medianeira, Paraná,
Brasil

Paulo Lopes De Menezes

plopes@utfpr.edu.br

Universidade Tecnológica Federal
do Paraná, Medianeira, Paraná,
Brasil

Silvana Ligia Vincenzi

sligie@globo.com

Universidade Federal de Santa
Catarina, Florianópolis, Santa
Catarina, Brasil

Fabiana Costa De Araujo Schutz

fabianaschutz@gmail.com

Universidade Tecnológica Federal
do Paraná, Medianeira, Paraná,
Brasil

O desenvolvimento da produção agrícola só é possível quando os aspectos de clima, solo e água se encontram em condições favoráveis. Condições desfavoráveis devido à escassez dos recursos prejudicam o crescimento e o desenvolvimento de plantas, podendo inviabilizar uma produção sustentável. O objetivo da pesquisa foi simular o ensaio radial da irrigação por aspersão através de modelo baseado nas redes neurais artificiais, treinadas com o algoritmo backpropagation com e sem o termo momentum, devido a sua capacidade de se retro propagar na rede para gerar a saída adequada. O estudo comparou o desempenho das redes neurais na simulação dos valores de precipitação de ensaios realizados em uma malha de 16x16 pluviômetros com espaçamentos regulares de 1,50 m. A melhor rede foi treinada com 6x459x1 neurônios no algoritmo backpropagation momentum. Conclui-se que o algoritmo backpropagation com o termo momentum apresentou melhor capacidade de generalização, com seu menor erro quadrático médio igual a 0,0040812 com a taxa de aprendizagem igual a 0,7.

PALAVRAS-CHAVE: Ensaio em malha. Inteligência artificial. Modelo radial. Simulação da irrigação.

INTRODUÇÃO

A produtividade rural é prejudicada quando o ambiente e a interação entre solo, clima e água são desfavoráveis. A irrigação é uma prática essencial para regiões áridas e semiáridas, pois garante segurança na produtividade onde ocorre a escassez contínua. Em conjunto com outras práticas agrícolas e melhorias, pode ser adotada como um pacote tecnológico a favor do produtor rural.

Estatisticamente, quando os valores das precipitações se encontram fora da variabilidade climatológica e o índice de chuva está acima ou abaixo é importante que haja esse tipo de intervenção, que contribui para obter benefícios ao meio agrícola (SANTOS; GALVANI, 2014) e com toda a cadeia de produção relacionada (plantio, colheita, transporte, armazenagem e comercialização) (PEREIRA; ANGELOCCI; SENTELHAS, 2007).

Os métodos de irrigação podem ser agrupados de acordo com a forma de aplicação da água, destacando-se quatro métodos principais: irrigação por superfície, subterrânea, por aspersão e localizada.

No primeiro método a água é disposta na superfície do solo e seu nível é controlado para aproveitamento das plantas. No método subterrâneo (ou subsuperficial), a água é aplicada abaixo da superfície do solo, formando ou controlando o lençol freático, na região em que pode ser aproveitada pelas raízes das plantas. A irrigação por aspersão é um método que ajuda a corrigir a falta de recursos hídricos, no qual a água é aspergida sobre a superfície do terreno, fracionando o jato de água em gotas como se fosse uma chuva artificial.

O método localizado (ou micro irrigação) consiste na aplicação em uma área bastante limitada, utilizando pequenos volumes de água, sobre pressão, com alta frequência. Existem diferentes sistemas para cada um desses métodos, como o sistema por inundação na irrigação superficial; o sistema de pivô central na irrigação por aspersão; e o sistema de gotejamento que ocorre nos métodos subterrâneo e localizado (BERNARDO, 2009).

Segundo dados da Organização das Nações Unidas para Agricultura e Alimentação (FAO, 2017) o Brasil está entre os dez países com maior área de irrigação, o que demonstra que tem uma pequena consideração ao potencial da área agrícola estimado em comparação com outros. Mais, esse fato se deve ao conjunto de fatores climáticos favoráveis e boa disponibilidade hídrica que se encontra nas regiões do Brasil, como aborda a Agência Nacional de Águas (ANA, 2017).

As características climáticas como precipitação, temperatura, radiação solar e ventos, podem exercer influência sobre todos os estágios da produção agrícola, determinando quais atividades serão desempenhadas até a seleção de regiões ou lugares para a instalação de culturas e experimentos agrícolas, além de servir como planejamento a longo ou curto prazo das referidas atividades. As mudanças climáticas podem afetar os sistemas agrícolas regionais com sérias consequências, dependendo de como as mudanças acontecem, determina-se a viabilidade e a utilização dessas áreas (SILVA, 2013).

De acordo com o manual da Agência Nacional de Águas (ANA, 2017) as culturas irrigadas têm maior participação e indicadores de produtividade para as safras de feijão, arroz e trigo. O método também está fortemente ligado à irrigação

de pastagens, hortaliças, café, legumes, flores, ou seja, uma forma convencional associada à micro aspersão.

Os aspersores constituem-se nas peças principais no método de aspersão. Podem ser tanto estacionários ou rotativos. Quando rotativos, podem se apresentar com giro completo (360°) ou do tipo setorial, permitindo uma regulagem da amplitude de giro. O ângulo mais comum de inclinação do jato com a horizontal é o de 30°; contudo, o ângulo de 20 a 22° é o que melhor se adapta a condições de vento forte. No sistema pivô central, têm-se utilizado difusores estacionários, em que o jato de água é finamente pulverizado pelo choque com anteparo cheio de ranhuras (BERNARDO, 2009).

Para Seginer et al. (1992), conhecer o perfil radial de distribuição de água de um aspersor é fundamental para a pesquisa, desenvolvimento, controle da qualidade de fabricação e avaliação de aspersores. Como o ensaio em malha decorre de gastos financeiros e mobilização de pessoal em campo, a pesquisa usou a simulação de ensaio radial para averiguar se podem chegar à conclusão similares as do campo.

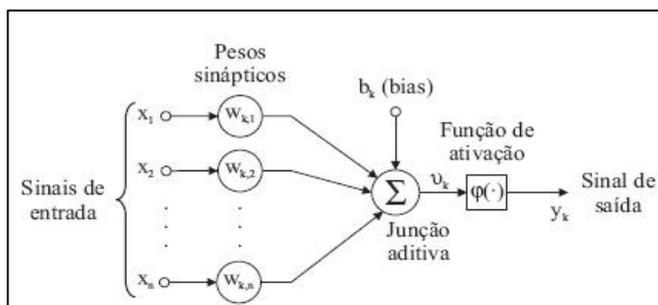
A Inteligência Artificial (IA) está ligada na capacidade de como um aparelho computadorizado pode ser controlado a cumprir tarefas com características desde humanas até mecânicas. Dentro deste contexto a aplicação dessas técnicas vem sendo esboço na construção de várias teorias e pesquisas (DWYER, 2001).

Com o emprego de técnicas computacionais auxiliadas pelos recursos da IA, o produtor rural pode basear-se para verificar se seria viável estabelecer o critério da simulação radial no emprego em campo.

No campo da IA, as Redes Neurais Artificiais (RNAs) são estruturas computacionais que tentam simular o funcionamento das estruturas neurológicas do cérebro humano. A arquitetura de uma RNA restringe o tipo de problema no qual ela pode ser utilizada, e é definida pela quantidade de camadas, neurônios, tipo de conexão e topologia da rede, como demonstra a Figura 1 (HAYKIN, 2001).

Nos pesos sinápticos ($w_{k,j}$) o k refere a um neurônio, enquanto o j se refere ao sinal de entrada no qual o peso tem relação. A função de ativação tem a função de somar todos os sinais de entrada, do qual são ponderados pelos pesos sinápticos de cada neurônio. O bias aumenta ou diminui a influência para a ativação de cada neurônio.

Figura 1 – Modelo da estrutura de uma RNA



Fonte: Retirado de Zanetti et al. (2008)

Uma importante característica usada nas RNAs está na sua capacidade de aprender com casos reais, com que faz que proporcione maior confiabilidade na

habilidade e capacidade de aprender. Exemplos conhecidos são encontrados no processamento de imagens, automação, previsão da bolsa de valores entre outros (ROCHA; MATOS; FREI, 2011).

Os valores de precipitação observados no ensaio de irrigação por aspersão podem ser utilizados como entrada da RNA, e criar uma representação interna que abstraí e representa as variáveis externas do ensaio, cujos valores de entrada são ponderados e podem aumentar ou diminuir os valores dos sinais de saída que representam as precipitações. As constantes alterações que ocorrem no decorrer do treinamento pelo peso adicionado aos neurônios e ao bias (bk) tem o efeito de realizar a ponderação dos sinais de entrada (GOLDSCHMIDT, 2010).

O algoritmo de backpropagation tem a complexidade em se retro propagar ajustando os seus pesos. Caracteriza-se por ser construída de unidades interconectadas, com uma ou mais camadas ocultas. Os elementos são interconectados por pesos. Cada unidade deve enviar sua saída para camadas de ordem maior que a sua e devem receber suas entradas de camadas abaixo da sua. Não existem interconexões entre os elementos dentro de uma mesma camada, que consiste em duas fases: feedforward e feedbackward.

Na fase feedforward os valores são processados na RNA e comparados com o valor real, caso haja diferença entre o valor predito e o real é determinado um erro, e a rede utiliza a fase feedbackward, que consiste no recálculo do processo mediante a alteração da ponderação para cada variável e cada neurônio. Esse procedimento, chamado treinamento, é feito até que se obtenha um número dentro do previamente estabelecido (COSTA JUNIOR; CRUZ, 1998).

Cada neurônio é caracterizado pelo peso, bias e função de ativação, dessa forma os valores na rede são ponderados com os pesos da entrada, especificado o tipo da função de ativação como sigmoide e o treinamento como supervisionado. As amostras são treinadas e se obtém uma respectiva saída, que caso não for a desejada os pesos se corrijam e ajustados conforme o algoritmo definido na aprendizagem.

A utilização do termo momentum consiste em aplicar uma constante μ sobre a mudança no peso do vetor na última iteração, somando-se a esta a correção de direção da iteração corrente. Se a última mudança de pesos foi em uma direção particular, o termo momentum faz com que a próxima mudança de peso seja mais ou menos na mesma direção que a anterior. Conforme a situação, o pequeno desvio pode ser suficiente para evitar que a rede caia e resulte em um resultado mínimo ao peso adaptado a saída (COSTA JUNIOR; CRUZ, 1998).

A RNA pode ser capaz de produzir resultados satisfatórios na simulação do ensaio radial de irrigação por aspersão, devido à sua boa capacidade de generalização, tomando o cuidado e evitando a ocorrência de overfitting (excesso de treinamento) ou underfitting (parada mais cedo) (FRANCO; JEREZ; ALIZONDO, 2009). A capacidade de generalização reflete em qual valor da taxa de aprendizagem a rede obteve o menor erro MSE (Média de erro quadrático). O menor erro MSE pode ser usado como parâmetro para verificar se a convergência das RNA é satisfatória (REYES; VELLASCO; TANSCHIT, 2012).

O presente trabalho comparou o uso do algoritmo de treinamento *backPropagation* com e sem o termo momentum, devido a capacidade de retro propagação de erros na rede. A simulação é um importante fator para averiguar se

os dados obtiveram satisfação a partir dos colhidos em campo e a partir disso torná-la satisfatória para averiguar testes antes de serem aplicados em campo e evitar gastos excessivos.

MATERIAL E MÉTODOS

Os dados usados na pesquisa foram coletados na fazenda Ouro Verde, área localizada no município de Medianeira, Brasil com as coordenadas geográficas (25° 12 '19,26 "S; 54° 3 '27,93" W; 360 m) localizado na região Oeste do Estado do Paraná.

Os ensaios caracterizam a distribuição de água de um aspersor usando diferentes combinações de bocal (mm), quebra jato, pressão (Kgf/cm²), velocidade do vento (m/s), direção do vento (graus) e precipitação (mm h⁻¹).

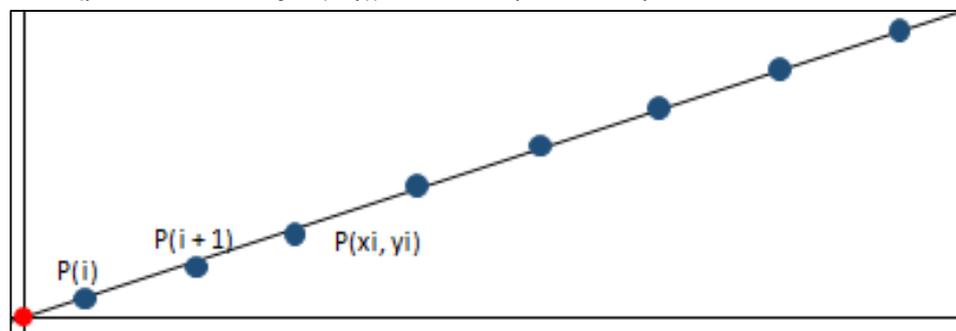
O aspersor operou em uma malha de 16x16 pluviômetros, usando nove diferentes combinações de bocais (2,6 x 2,4; 2,8 x 2,4; 3,0 x 2,6; 3,2 x 2,6; 3,4 x 2,6; 3,6 x 2,8; 3,8 x 2,8; 4,0 x 2,8 e 4,0 x 3,2 mm), com uma distância de 1,5 m entre os pluviômetros, com a base do aspersor a uma distância vertical de 1,25 m em relação à superfície do solo.

No total foram realizados 108 ensaios em campo. Disponibilizados em uma planilha de cálculo matemático, os dados tiveram de ser adaptados e configurados para o uso na RNA. Os parâmetros que constituíram a entrada de dados na RNA foram: o bocal, o quebra jato, a pressão, velocidade do vento, direção do vento e precipitações.

O modelo observado foi composto de um aspersor central e em malha composta de 256 pluviômetros, que visava captar a água aspergida a fim de verificar o quanto em milímetros é aspergido e se fornecerá hidratação suficiente às plantas. Já o modelo radial simulado foi construído por uma única linha inclinada (Figura 2), com um aspersor inicial e há uma distância de 1,5 metros na distribuição dos oito pluviômetros como demonstra a Figura 3.

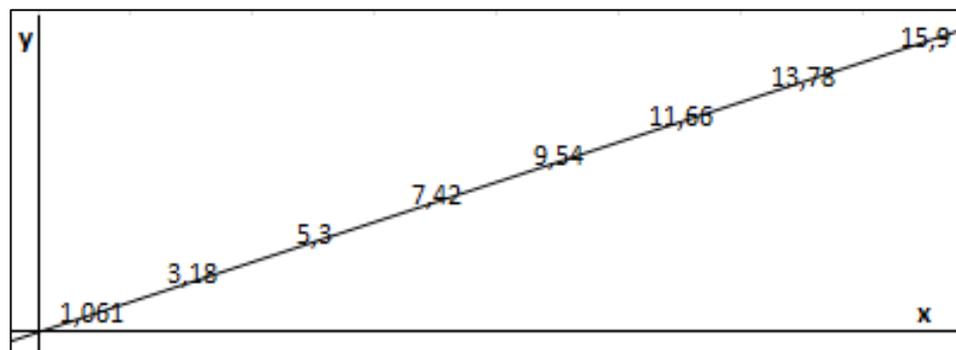
Para a simulação das distribuições observadas foram utilizados cálculos matemáticos da geometria analítica.

Figura 2 – Distribuição da distância dos pontos no ensaio radial em relação do aspersor inicial (ponto na intersecção (x, y)) aos demais pontos dos pluviômetros



Fonte: Autoria própria

Figura 3 – Representação das distâncias dos pontos calculadas para o ensaio radial dos pluviômetros



Fonte: Autoria própria

Para minimizar o problema com os dados devido ao uso de unidades e variáveis com diferentes magnitudes é importante realizar um pré-processamento dos dados chamado de normalização, na qual os dados são transformados em um padrão coerente para que facilite o processamento pela função de ativação da RNA. A função sigmoide, usada na pesquisa, opera no intervalo no intervalo de [0, 1]. Normalização ainda é útil, mas não é por conta da ativação sigmoide.

A Equação 1 é utilizada para realizar a normalização dos dados (SILVA; SCHIMIDT, 2016).

$$X_N = X_o - X_{min} / X_{max} - X_{min} \quad (1)$$

em que:

X_o : x original; X_N : x normalizado; X_{max} : maior valor do parâmetro;

X_{min} : menor valor do parâmetro.

As RNAs foram treinadas utilizando valores aleatorizados, para mostrar que não houve forçamento dos resultados. Os parâmetros de aprendizado e os padrões de treinamento são inicializados e ao longo do progresso são realizados os ajustes e conexões entre os pesos.

A Figura 1 representa um exemplo de como foram configurados os neurônios simulados pela RNA da pesquisa. Treinada de forma supervisionada, do qual utilizou a média para o encontro do menor erro quadrático (MSE). Para o aprendizado da rede foram usados dados para o treinamento e validação. Testadas o total de 30 mil redes neurais a fim de selecionar para a etapa de avaliação do termo *momentum* aquela que obtivesse o menor erro MSE.

A melhor rede foi treinada com 6 neurônios na camada de entrada, 459 neurônios na camada oculta e 1 neurônio de saída. A taxa de aprendizado usada no treinamento das RNAs consistiu no intervalo de (0,1 a 1,0), para o algoritmo (*backPropagation* sem e com o termo *momentum*).

O termo *momentum* (μ) foi configurado para o treinamento das RNAs com o valor de 0,3. Por ter apresentado resultados propícios nos testes e melhor capacidade de generalização. As amostras foram divididas nas fases de treinamento (66%), validação (26%) e teste (8%).

O treinamento realizado para cada taxa de aprendizado se estabeleceu em três seções, em que foi promissora a procura do menor erro MSE. As RNAs foram

testadas com 10 mil épocas, usando a estratégia da parada antecipada para evitar a ocorrência indesejada de *underfitting* ou *overfitting* (MARTINS et al. 2015).

Visando selecionar uma RNA que proporcionasse o melhor desempenho, foram realizados vários testes e um estudo prévio variando-se os neurônios na camada oculta e a função de ativação nas camadas.

RESULTADOS E DISCUSSÃO

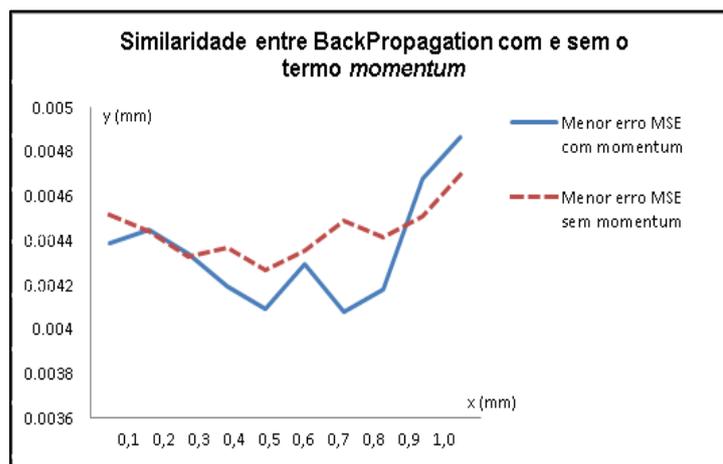
O conjunto do método utilizado para a determinação das precipitações simuladas pela RNA permitiu observar se os critérios adotados na construção da RNA para as variáveis de entrada, estrutura da rede e treinamento proposto estão de acordo com o adequado no observado.

A RNA se mostrou satisfatória com a interação de apenas uma camada oculta, no qual está variou seus neurônios até encontrar a rede de menor MSE.

O modelo simulado pela RNA obteve variações no decorrer do treinamento, apresentando diversas oscilações na rede e conforme se variava a taxa de aprendizado a sua convergência se tornava mais rápida ou lenta. No treinamento pode-se observar o quanto os valores se tornaram próximos aos observados que reflete positividade para a simulação para os testes.

A Figura 4 refere-se à comparação entre os valores do erro MSE da rede 6x459x1 com o uso do termo *momentum* e sem o uso do termo *momentum*. O algoritmo *backpropagation* sem o termo *momentum* (linha tracejada), mostra que a RNA obteve um caminho sem grandes oscilações. Já para o *backPropagation* com o termo *momentum* (linha contínua) obteve maiores oscilações para encontrar o menor erro MSE.

Figura 4 – Similaridade entre o algoritmo *backPropagation* com e sem o termo momentum



Fonte: Autoria própria

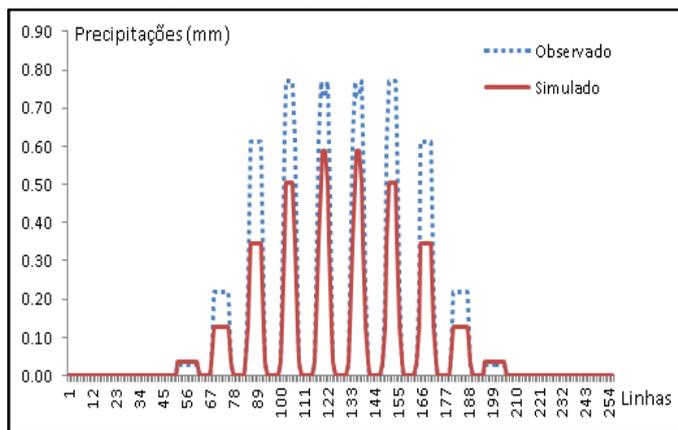
O algoritmo *backpropagation* com o uso do termo momentum permitiu resultados satisfatórios na simulação dos valores do ensaio radial do aspersor, obtendo o menor erro MSE igual a 0,0040812 com a taxa de aprendizagem em 0,7. O treinamento foi interrompido quando a rede passou a apresentar boa capacidade de generalização e taxa de erro MSE suficientemente pequena, ou seja,

menor que o erro anterior. Sem o termo *momentum* obteve-se o menor valor erro MSE igual a 0,0042659 com a taxa de aprendizagem a 0,5.

A Figura 5 mostra a comparação entre as precipitações do ensaio simulado (reta contínua) e observado (reta tracejada) com média de 0,1 a 0,079mm.

A variância apresentou resultado baixo de 0,02 até 0,5 entre as amostras, destacando proximidade em relação à média.

Figura 5 – Comparação das precipitações observadas e simuladas



Fonte: Autoria própria

A RNA treinada com o termo *momentum* obteve uma capacidade de generalização promissora ao simular as precipitações, obtendo valores próximos aos observados. O treinamento das RNAs demandou tempo e muitas modificações ao longo da pesquisa para que fosse adaptada até chegar a resultados satisfatórios.

CONCLUSÕES

Conclui-se promissora a simulação dos valores da precipitação para o ensaio radial do aspersor com o modelo baseado na RNA. A capacidade de generalização se mostrou satisfatória no algoritmo *backpropagation* com o termo *momentum*, com erro MSE igual a 0,0040812. O termo *momentum* permitiu que o aprendizado da RNA fosse mais rápido e eficiente.

As precipitações do ensaio simulado obtiveram resultados próximos aos observados, do qual concluiu verificar que a RNA foi promissora para o treinamento da rede. Os ensaios radiais simulados pelas RNAs podem contribuir na avaliação dos aspersores, diminuindo os custos de mobilização operacionais e de campo.

A pesquisa teve como meta demonstrar que é possível através da simulação prever o ensaio da irrigação por aspersão em campo, com algumas variações climáticas e interferência humana. Mas que fenômenos climáticos de grande consequência podem acarretar na destruição total da produção agrícola.

Para melhor aperfeiçoamento dos resultados em trabalhos futuros será realizado testes com outros algoritmos das RNAs, para que seja possível verificar se através de outros aprendizados se chegue a resultados mais próximos.

E também como trabalho futuro será realizado testes estatísticos para comprovar se o algoritmo *backpropagation* com o momentum é de fato superior ao sem *momentum*.

Simulation of spray irrigation using artificial neural networks trained with and without term momentum

ABSTRACT

The development of agricultural production is only possible when the climate, soil and water aspects are in favorable conditions. Unfavorable conditions due to scarce resources undermine the growth and development of plants, and may hinder sustainable production. The objective of the research was to simulate the radial spray irrigation test using a model based on artificial neural networks trained with the backpropagation algorithm with and without the term momentum due to its ability to propagate directly in the network to generate adequate output. The study compared the performance of the neural networks in the simulation of the precipitation values of the tests performed in a 16x16 pluviometer mesh with regular spacing of 1.50 m. The best network was trained with 6x459x1 neurons in the backpropagation momentum algorithm. We conclude that the backpropagation algorithm with the term momentum presented better generalization capacity, with its smallest mean square error of 0.0040812 with the learning rate equal to 0.7.

KEYWORDS: Mesh test. Artificial intelligence. Radial model. Irrigation simulation.

AGRADECIMENTOS

À Universidade Tecnológica Federal do Paraná.

REFERÊNCIAS

ANA, Agência Nacional de Águas. ATLAS IRRIGAÇÃO - Uso da Água na Agricultura Irrigada. Brasília: Ana, 2017. 86 p. ISBN 978-85-8210-051-6. Disponível em: <www.atlasirrigacao.ana.gov.br>. Acesso em: 05 abr. 2018.

BERNARDO, Salassier; SOARES, Alves Antônio; MANTOVANI, Everaldo. Manual de irrigação. 8. ed. Viçosa: Ufv, 2009. 625 p.

COSTA JUNIOR, Rosemary Antonia Lopes Faraco Pyramo Pires da; CRUZ, Frederico Rodrigues Borges da. Minimização do erro no algoritmo back-propagation aplicado ao problema de manutenção de motores. Ufmg, Minas Gerais, v. 18, n. 1, p.1-16, jun. 1998.

DWYER, Tom. Inteligência artificial, tecnologias informacionais e seus possíveis impactos sobre as Ciências Sociais. Sociologias, [s.l.], n. 5, p.58-79, jun. 2001. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s1517-45222001000100004>.

FRANCO, Leonardo; JEREZ, José M.; ALIZONDO, David A.. Constructive Neural Networks. Spain: Springer, 2009. 281 p.

GOLDSCHMIDT Ronaldo Ribeiro, 2010. Uma Introdução à Inteligência Computacional: fundamentos, ferramentas e aplicações. 1.ed. Rio de Janeiro. 143 p.

HAYKIN, S. Redes neurais: princípios e prática. Porto Alegre: Bookman, 2001.

PEREIRA, Antônio Roberto; ANGELOCCI, Luiz Roberto; SENTELHAS, Paulo Cesar. Meteorologia agrícola. Piracicaba, SP: Lce 306, 2007. 184 p. Disponível em: <http://www.leb.esalq.usp.br/aulas/lce306/MeteorAgricola_Apostila2007.pdf>. Acesso em: 17 set. 2018.

REYES, Javier; VELLASCO, Marley; TANSCHKEIT, Ricardo. Monitoramento e diagnóstico de múltiplos sensores por redes neurais auto-associativas. Sba: Controle & Automação Sociedade Brasileira de Automática, [s.l.], v. 23, n. 2, p.121-137, abr. 2012. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s0103-17592012000200001>.

ROCHA, José Celso; MATOS, Felipe Delestro; FREI, Fernando. Utilização de redes neurais artificiais para a determinação do número de refeições diárias de um restaurante universitário. Revista de Nutrição, [s.l.], v. 24, n. 5, p.735-742, out. 2011. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s1415-52732011000500007>.

SANTOS, Denise Dias dos; GALVANI, Emerson. Distribuição sazonal e horária das precipitações em caraguatatuba-sp e a ocorrência de eventos extremos nos anos de 2007 a 2011. Ciência e Natura, Sp, v. 36, n. 2, p.214-229, 14 maio 2014. Universidad Federal de Santa Maria. <http://dx.doi.org/10.5902/2179460x11891>.

SEGINER, I.; KANTZ, D.; NIR, D.; BERNUTH, R.D. Von. Indoor measurement of single-radius sprinkler patterns. Transactions of the American society of Agricultural Engineers, St. Joseph, v.35, n.2, p.523-533, 1992.

SILVA, Saulo Rodrigues e; SCHIMIDT, Fernando. Reduction of input variables in artificial neural networks as from principal components analysis data in the modeling of dissolved oxygen. Química Nova, São Paulo, p.1-10, 2016. GN1 Genesis Network. <http://dx.doi.org/10.5935/0100-4042.20160024>.

SILVA, R. R. da. Relação entre precipitação pluviométrica e produtividade da cultura de soja no município de Ibirubá-RS. 2013.93 f. Dissertação (Mestrado) - Curso de Geografia e Geociências, UFSM. RS, 2013.

Recebido: 10 out. 2018.

Aprovado: 31 dez. 2018.

DOI: <http://dx.doi.org/10.3895/rcaa.v1n2.9501>

Como citar:

WOLFRANN, J.; MENEZES, P.L.; VINCENZI, S.L.; SCHUTZ, F.C.A. Simulação da irrigação por aspersão utilizando redes neurais artificiais treinadas com e sem termo momentum. **Revista de Computação Aplicada ao Agronegócio**, Medianeira, v. 1, n. 2, p. 44-55, ago./dez. 2018. Disponível em: <<https://periodicos.ufpr.edu.br/rcaa/article/view/9501>>. Acesso em: Dezembro, 2018.

Correspondência:

Joice Wolfrann
Rua José Grosbelli, 75, Bairro Jardimópolis.
Serranópolis do Iguaçu, Paraná, Brasil.

Direito autoral:

Este artigo está licenciado sob os termos da Licença Creative Commons-Atribuição 4.0 Internacional.

