

PONTIFÍCIA UNIVERSIDADE CATÓLICA DE GOIÁS
ESCOLA DE ENGENHARIA / ENGENHARIA ELÉTRICA
Trabalho Final de Curso II

Kalffman Ewan Freire Schuch

ANÁLISE PREDITIVA COM REDES NEURAS ARTIFICIAIS
PARA O PLANEJAMENTO DE SISTEMAS DE IRRIGAÇÃO

Trabalho Final de Curso II como parte dos requisitos para
obtenção do título de bacharel em Engenharia Elétrica
apresentado à Pontifícia Universidade Católica de Goiás.

BANCA EXAMINADORA:

Prof. Dr. Marcos Antônio de Sousa – Orientador. ENG-PUC Goiás.

Prof. Dr. Bruno Quirino de Oliveira – ENG-PUC Goiás.

Prof. Dr. Antônio Marcos de Melo Medeiros – ENG-PUC Goiás.

Goiânia, 9 de junho de 2021.

Análise Preditiva com Redes Neurais Artificiais para o Planejamento de Sistemas de Irrigação

KALFFMAN EWAN FREIRE SCHUCH, MARCOS A. SOUSA

Abstract— This course conclusion paper presents the development of an Artificial Neural Network (ANN) with the objective of executing predictions, in the scope of agriculture, based on input data. The system allows the analysis of inputs and results in an output value characterized by the prediction value, making it possible to predict future scenarios. A system was developed based on the techniques developed, obtained through research, to implement the forecast of the irrigation routine of a few weeks. The performance of the developed system was verified with values obtained through a hypothetical scenario. The results are presented and discussed.

Keywords – Artificial neural network, artificial intelligence, prediction, agriculture, data analysis.

Resumo – Este trabalho de conclusão de curso apresenta o desenvolvimento de uma Rede Neural Artificial (RNA) com o objetivo de executar previsões, no âmbito da agricultura, baseada em dados de entrada. O sistema permite a análise de *inputs* e resulta em um valor de saída caracterizado pelo valor da previsão, tornando possível a previsibilidade de cenários futuros. Foi desenvolvido um sistema baseado nas técnicas desenvolvidas, obtidas através de pesquisas, para implementar a previsão da rotina de irrigação de algumas semanas. O desempenho do sistema desenvolvido foi averiguado com valores obtidos por meio de um cenário hipotético. Os resultados são apresentados e discutidos.

Palavras-chave – Rede neural artificial, inteligência artificial, previsão, agricultura, análise de dados.

I. INTRODUÇÃO

O acelerado crescimento tecnológico e, conseqüente, informatização de processos, possibilitou enormes avanços operacionais nas empresas, nos mais variados setores da economia. Particularmente, no setor industrial, a produção de hardwares cada vez mais eficientes e baratos criaram um ambiente propício ao desenvolvimento de grandes sistemas baseados em IoT (*internet of things*), com a implantação de redes de comunicação mais rápidas, abrangentes e eficientes.

Internet das Coisas (IoT) de acordo com [1] está mudando e transformando tudo, desde negócio-negócio para pessoa-pessoa. IoT pode ser vista como uma tecnologia avançada que fornece a capacidade de se comunicar os dados na rede sem qualquer intervenção humana.

Com a crescente adoção da IoT, dispositivos conectados estão presentes em todos os aspectos da vida moderna, desde agricultura, saúde e fitness, passando pela automação residencial, automotiva e de logística, chegando às cidades inteligentes e à IoT industrial [2].

Em particular, a adoção de soluções IoT para a agricultura está crescendo constantemente. Segundo [3], o número de

instalações de dispositivos de IoT agrícolas deve atingir 75 milhões de unidades ainda este ano, com previsão de crescimento de 20% ao ano. Usando vários *smart gadgets*, os agricultores ganharam mais controle sobre atividades que vão desde os processos de irrigação, plantio, colheita e secagem de grãos, até o monitoramento de rebanhos.

Naturalmente, estes cenários resultam na geração de grandes volumes de dados que podem estar sendo coletados em tempo real, através de sensores, ou acessados através de bancos de dados armazenados em repositórios.

Não é difícil de se concluir que este processo gradativo de implantação de sistemas automatizados e informatizados, com infraestrutura IoT, acaba produzindo múltiplas fontes de dados, na maioria das vezes, com lógicas próprias e dificuldades de consolidação. Conseqüentemente, uma característica comum, encontrada na maioria das empresas, é a dificuldade de extração de informação relevante destas bases de dados. Como alternativa para resolver este tipo de problema, nas últimas décadas houve crescimento na pesquisa de algoritmos para automatizar os processos de tomada de decisão baseados em dados, principalmente pela aplicação de métodos relacionados ao campo da Inteligência Artificial (IA) [4].

A Inteligência Artificial (IA) consiste em uma vasta categoria de algoritmos e tecnologias utilizados para extrair, armazenar, analisar e transformar grandes volumes de dados, produzindo um ambiente de conhecimento, onde há produção sistemática de informação relevante, veloz e consistente, capaz de auxiliar as empresas a tomarem melhores decisões, baseado em fatos reais, com profundidade suficiente para descobrir as causas de uma tendência ou de um problema [5].

Na área de IA existe uma área de pesquisa chamada aprendizagem de máquina, que visa fazer uma máquina (ou algoritmo) detectar e extrapolar novos padrões, com a capacidade de adaptação às novas circunstâncias. Esta área pode ser dividida em três ramos: aprendizagem supervisionada, não supervisionada e por reforço. O problema abordado na aprendizagem supervisionada é focado em aprender uma função a partir de exemplos em suas entradas e resultados. A aprendizagem não supervisionada visa aprender padrões em suas entradas, mas com nenhuma saída especificada. Na aprendizagem por reforço, um agente deve aprender a realizar alguma tarefa de acordo com a recompensa relacionada a uma entrada [6].

A aplicabilidade das Redes Neurais Artificiais (RNA) como sistema especialista para a previsão de parâmetros produtivos e padrões de comportamento é crescente. As RNA podem ser vistas como modelos de processamento serial ou distribuídos paralelamente, procurando alcançar bom desempenho via interconexão de elementos computacionais simples. Os modelos baseados em RNA exploram

simultaneamente muitas hipóteses utilizando regras de aprendizagem que permitem adquirir poder de generalização suficiente para reconhecer padrões e realizar predição de cenários [7]. Os modelos de RNA têm aplicação potencializada quando se tem disponível uma base de dados que permite a compreensão (aprendizagem) das relações entre as variáveis que modelam o problema em estudo, com destaque para aqueles cenários em que é difícil criar modelos precisos da realidade e que estão sujeitos a frequentes mudanças de ambiente [7].

Neste sentido, tendo em vista a importância das redes neurais aplicadas na predição de cenários futuros, o presente trabalho apresenta um estudo da aplicação destas técnicas no processo de apoio à decisão para gerenciar a irrigação em um determinado campo de cultivo, com base em ambas as variáveis, climáticas e de solo, fornecidas por estações meteorológicas e sensores de solo. O processo de predição tem como objetivo principal apontar a rotina de irrigação de uma semana futura.

A complexidade deste problema e as diferentes fontes de variabilidade justificam a utilização de RNA no processo de predição. A experiência humana tem se mostrado eficaz para auxiliar na gestão da irrigação, mas não é escalável e, normalmente, não está disponível para todos os campos de cultivo. Sem dizer que é lento na análise dos dados e processamento em tempo real. Em vez disso, aplicar técnicas de aprendizado de máquina para substituir os modelos manuais e para auxiliar agrônomos especialistas permite a viabilidade de criação de um Sistema de Apoio à Decisão para o processo de Irrigação de forma automatizada.

Nas seções seguintes serão detalhadas as etapas de construção do sistema de apoio a decisão para o processo de irrigação. A seção II descreve as técnicas de inteligência artificial e os processos de aprendizagem de sistemas especialistas baseados em IA. A seção III destaca os principais elementos das Redes Neurais Artificiais, bem como as suas aplicações, vantagens e desvantagens. O protótipo do sistema desenvolvido é detalhado na seção IV, com destaque para o processo de implementação computacional. Os resultados mais relevantes das simulações computacionais, juntamente com as suas discussões, podem ser conferidos na seção V. Por fim, a seção VI descreve as conclusões gerais sobre o trabalho.

II. INTELIGÊNCIA ARTIFICIAL

A Inteligência Artificial representa uma área do conhecimento utilizada com o propósito de sistematizar e automatizar tarefas que são realizadas pelos seres humanos e que exigem algum nível de intelectualidade, ou inteligência [8].

A Inteligência Artificial não é uma tecnologia recente, apesar da sua crescente notoriedade nos diversos tipos de mídia. Sua concepção tem origem através da junção de várias áreas de conhecimento ao longo da história, que contribuíram de maneira significativa para o seu desenvolvimento, tais como: filosofia, matemática, economia, neurociência, psicologia, engenharia e computação [8].

Os projetos desenvolvidos com IA objetivam fazer com que computadores apresentem inteligência a partir de algoritmos complexos e métodos que funcionam de maneira semelhante à forma dos seres humanos pensarem e resolverem problemas. Nota-se, portanto, que o desenvolvimento de aplicações IA tem como inspiração a

capacidade humana de percepção, resolução de problemas, comunicação, aprendizagem e adaptação.

As técnicas de Inteligência Artificial podem ser divididas em dois grandes grupos: Inteligência Artificial Clássica, que envolve basicamente os sistemas especialistas e sistemas baseados em raciocínio ou inferência lógica; e a Inteligência Computacional ou Aprendizagem de Máquina, que tem como meta desenvolver programas computacionais capazes de automaticamente melhorar seu desempenho por meio da experiência.

A. Sistemas Especialistas

Sistema Especialista (SE) pode ser visto como uma técnica de Inteligência Artificial desenvolvida para processar informações não numéricas [9], com o objetivo de auxiliar na resolução de problemas que não possuem regras ou processos claramente definidos, ou cuja solução exige grande esforço computacional.

Através de Sistemas Especialistas é possível habilitar um sistema computacional a trabalhar de forma semelhante a um especialista humano. O SE captura a *expertise* humana em um domínio específico do conhecimento e a transforma em um conjunto de regras para um sistema de software que pode ser usado por outras pessoas da organização. Este processo é realizado através de inferências computacionais, apontando soluções, mesmo que os dados fornecidos inicialmente não sejam totalmente completos.

Entre as características mais relevantes para a interação do sistema especialista com o seu usuário podem ser destacadas [10]:

- Raciocínio operacional: para convencer o usuário de que a solução apresentada é adequada ao problema, é necessário que o SE descreva de forma clara e precisa o raciocínio utilizado que o levou àqueles resultados.
- Atualização de conhecimento: um especialista humano está sempre atento a novas informações que o levem a modificar seu conhecimento ou mesmo complementá-lo. Igualmente, um SE deve manter sempre atualizadas suas bases de conhecimento.
- Interação contínua: processo de submissão dos mesmos dados brutos utilizados pelo especialista humano para o Sistema Especialista, e permitir que o SE aprenda com ele.

Uma das grandes vertentes para o desenvolvimento de sistemas especialistas são para os processos de predição de parâmetros de qualidade. Nestes ambientes, o SE recebe informações (coletadas em tempo real e/ou de um banco de dados de registro) sobre as características do problema e, com base em algumas premissas, aponta cenários futuros mais prováveis para atingir aquelas soluções com os melhores índices de qualidade.

O objetivo é auxiliar gestores na tomada de decisão, verificar possíveis situações que podem ocorrer, de modo particular, em algumas etapas do processo. Assim, esses modelos de SE de predição também podem ser utilizados como importantes ferramentas de planejamento, operação e manutenção, bem como na necessidade de ampliação, reparo e/ou modificações para atendimento de alguns requisitos específicos. Além de possibilitar a crescente automatização que já vem ocorrendo em diversos setores da economia.

Estrutura de um Sistema especialista

A estrutura de um Sistema Especialista pode variar de desenvolvedor para desenvolvedor dentro das organizações. Porém, três componentes são considerados essenciais na arquitetura de um Sistema Especialista (Figura 1):

- *Base de Conhecimento*: é o componente que armazena todo o conhecimento do especialista humano e que deve ser formalizado pelo Engenheiro do Conhecimento. O conhecimento pode estar na forma de fatos, heurísticas (por exemplo: experiências, opiniões, julgamentos, previsões, algoritmos) [11]. A função da Base de conhecimento é aprender conceitos de uma determinada área e produzir uma representação dos seus objetos e suas relações. Quando utilizado, o Mecanismo de Aprendizagem favorece a atualização da Base de Conhecimento com novas regras e/ou fatos.
- *Máquina de Inferência*: tem a função de processar o conhecimento, por meio da busca repetitiva de dados na Base de Conhecimento, além de analisá-lo conforme as regras estabelecidas pela Base de Regras. As informações dos processos de resolução alcançados pela Máquina de Inferência podem ser registradas e/ou atualizadas (na Memória Operacional) e encaminhadas para o Sistema de Justificação (responsável por detalhar o raciocínio utilizado pelo sistema para a obtenção do resultado) e para o Mecanismo de Aprendizagem (para este último somente quando o sistema utiliza técnicas de aprendizagem).
- *Memória Operacional*: armazena os principais fatos dos problemas e os valores das variáveis informadas pelo usuário que podem, posteriormente, gerar um relatório descrevendo todo o processo de execução realizado pelo SE. Todas as informações processadas devem ser encaminhadas ao usuário por meio de uma interface de usuário flexível e amigável.

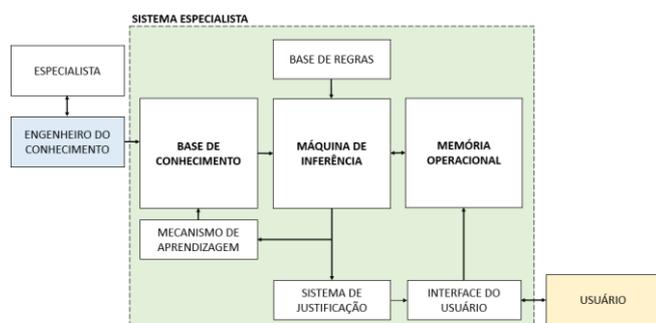


Figura 1. Estrutura de um Sistema Especialista adaptado de [10][12][13].

B. Técnicas de Aprendizagem

Sistemas que sofrem aprendizagem são aqueles capazes de adaptar ou mudar seu comportamento com base em exemplos. A maioria dos processos de aprendizagem é gradativa, requerendo um processo iterativo e de adaptação com o ambiente ao qual pretende retratar. As técnicas de aprendizagem mais comuns e que são utilizadas pelos algoritmos de treinamento são:

- *Aprendizagem supervisionada*: o sistema especialista recebe, sucessivamente, conjuntos de padrões de entrada e seus correspondentes padrões de saída. O SE ajusta os pesos das relações entre os elementos de processamento, até que o erro entre os padrões de saída gerados pelo SE alcance um valor mínimo definido previamente.

- *Aprendizagem não supervisionada*: o sistema especialista analisa os conjuntos de dados de entrada, determina algumas propriedades desse conjunto de dados e aprende a refletir estas propriedades na sua saída.

- *Aprendizagem por reforço*: ao invés de fornecer as saídas corretas para o sistema especialista, relativas ao treinamento individual, o SE recebe um valor que informa se a saída está correta ou não.

- *Aprendizagem híbrida*: os sistemas especialistas utilizam uma combinação das técnicas anteriores. Dependendo da aplicação e das informações disponíveis, a combinação de um treinamento supervisionado com um não supervisionado agrega valor para a base de conhecimento do sistema especialista utilizado no processo de tomada de decisão.

C. Machine Learning

As diversas técnicas de aplicação da Inteligência Artificial variam no funcionamento, na lógica aplicada e, principalmente, na saída que se espera dos algoritmos desenvolvidos. Neste contexto, a aprendizagem de máquina (*machine learning*) apresenta-se como um conjunto de técnicas de inteligência artificial que visam reconhecer padrões em base de dados. A aprendizagem de máquina agrega qualidade na geração de informação e conhecimento, auxiliando os gestores, e melhorando os processos de tomadas de decisão das empresas.

Entre as principais tarefas que se podem ser executadas com a aplicação de técnicas de aprendizagem de máquina se destacam: análise descritiva de dados, previsão (classificação e estimação), análise de grupos, associação e detecção de anomalias [14]. Neste trabalho pretende-se abordar o estudo de problemas de previsão. Entre os principais métodos investigados em aprendizagem de máquina podem ser destacados: Árvore de Decisão, Algoritmos Genéticos, Lógica Fuzzy, Redes Bayesianas e Redes Neurais Artificiais.

Algoritmos Genéticos

Os Algoritmos Genéticos (AG) são uma família de modelos computacionais inspirados na evolução, que incorporam uma solução potencial para um problema específico numa estrutura semelhante à de um cromossomo e aplicam operadores de seleção, cruzamento e mutação a essas estruturas de forma a preservar informações críticas relativas à solução do problema.

Deve ser observado que cada cromossomo, chamado de indivíduo no AG, corresponde a um ponto no espaço de soluções do problema de otimização [15]. O processo de solução adotado nos algoritmos genéticos promove uma varredura tão extensa quanto necessária do espaço de soluções. Nesse processo de evolução da solução, cada nova população gerada, através de regras específicas, em conformidade com o problema abordado, é composta por aqueles indivíduos que melhor se adaptam ao seu meio ambiente. O grau de adaptação dos indivíduos de uma população, em cada geração do processo de evolução, é averiguado com a aplicação de funções de aptidão que capturam os objetivos que se pretende alcançar de forma otimizada.

Árvore de Decisão

Árvore de decisão é uma técnica de aprendizado de máquina para classificação, em que os dados são particionados de acordo com uma condição de teste, normalmente executado por meio de uma expressão lógica, até alcançar uma classe. Existem várias formas de se implementar uma árvore de decisão. Para cada uma delas existe um algoritmo apropriado.

Uma vez construída a árvore de decisão, ela pode ser usada para classificar um objeto de classe conhecida. Para isso, basta testar os valores dos atributos na árvore e percorrê-la desde o nó raiz até se atingir um nó folha, que corresponde à classe predita para aquele objeto [14].

Rede Bayesina

A Rede Bayesiana é uma técnica de aprendizagem de máquina cuja lógica se baseia em probabilidades. Sua estrutura consiste em um grafo onde as variáveis são representadas por nós e os arcos que os unem simbolizam suas dependências. Cada nó da rede possui uma função que determina qual caminho é o mais provável de ser utilizado. As decisões estão baseadas na suposição de que as quantidades de interesse são reguladas por distribuições de probabilidade [16].

Os classificadores bayesianos assumem que o efeito do valor de um atributo em uma dada classe é independente dos valores dos outros atributos. Essa premissa tem como objetivo simplificar os cálculos, e por causa dela o algoritmo de treinamento utilizado pela rede é comumente denominado de Naive Bayes.

Lógica Fuzzy

A Lógica *Fuzzy* não só analisa os estados de um atributo (variável) e age em resposta a eles, como também determina quão preciso ou quão verdadeiro é o estado daquele atributo. Em problemas de classificação, por exemplo, diferentemente da lógica booleana clássica, na lógica *fuzzy*, um objeto pode pertencer a mais de uma classe (conjunto), porém com variados graus de pertinência. O objetivo desta técnica de aprendizagem de máquina é permitir o desenvolvimento de um ferramental matemático com capacidade de representação de incertezas e de tratamento de informações de caráter impreciso ou vago.

O resultado é um sistema de inferência baseado em regras que possibilite o estudo de sistemas que são muito complexos para serem analisados através de termos matemáticos convencionais. Neste sentido, o desenvolvimento de um sistema baseado em lógica *fuzzy* contempla duas atividades fundamentais [17]:

- *O processo de modelagem de dados imprecisos*: tanto o número quanto o formato das funções de pertinência devem ser escolhidos de acordo com o conhecimento sobre o processo que se pretende estudar.
- *A representação da inteligência*: a base de regras de controle que deve ser criada está baseada no conhecimento e expectativa do profissional especialista/projetista.

Redes Neurais

Redes Neurais Artificiais é uma área de estudo que busca reproduzir a forma de funcionamento do cérebro de seres vivos, que tem ampla capacidade de aprender. Neurônios

artificiais operam em uma rede em camadas, normalmente uma camada de entrada, uma camada oculta e uma de saída. A comunicação é unidirecional: começa na camada de entrada e segue sentido camada de saída. Neurônios de uma mesma camada não se comunicam, porém devem se comunicar com todos os neurônios artificiais da camada subsequente. Cada neurônio recebe um dado alterado através de um peso, produzem uma resposta que é avaliada quanto ao erro encontrado. Este erro é então utilizado para ajustar o peso de entradas. O processo é repetido uma série de vezes durante o processo de aprendizagem (treinamento) da RNA.

Uma característica importante das RNA está no processo de armazenamento do conhecimento. Nas RNAs de estrutura mais simples, esse conhecimento é armazenado nos pesos das conexões entre os neurônios artificiais (sinapses). A capacidade de processamento e aprendizagem da RNA é enormemente influenciada pelo algoritmo de aprendizagem utilizado para ajustar estes pesos das sinapses [18].

Neste trabalho, a Rede Neural Artificial é a técnica de Inteligência Artificial adotada para auxiliar no processo de tomada de decisão, em particular para problemas que exigem estudos de predição, que é o caso do planejamento semanal da rotina de irrigação de uma lavoura.

III. REDES NEURAIS ARTIFICIAIS

Redes neurais artificiais são sistemas inspirados na neurociência em que um modelo preditivo é formado, baseado em como o cérebro funciona [4]. Inegavelmente, o fator mais importante presente nas redes neurais artificiais, é a habilidade de aprender e, dessa forma, melhorar gradativamente o seu desempenho, assim como ocorre com alguns animais e suas adaptações em situações específicas [19][20].

A. Funcionamento de uma RNA

O funcionamento de uma RNA é determinado de forma simplificada na Figura 2:

- São inseridos sinais na entrada;
- Nas camadas centrais ocorre o processamento, onde cada sinal é multiplicado por um “peso”, ou número, que altera a influência desse sinal na saída;
- Obtendo o resultado dessa multiplicação, é feito uma comparação para determinar se ele é suficiente para “disparar” uma resposta, ou saída.

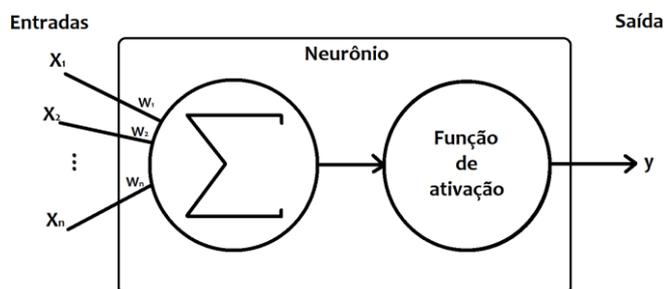


Figura 2. Modelo de um neurônio [7][20].

Por meio do treinamento da RNA, melhora-se os pesos e consequentemente diminui-se as perdas.

B. Treinamento de uma RNA

O treinamento de uma RNA é uma tarefa deveras importante pois ao efetuar essa etapa, melhora-se os valores dos pesos e conseqüentemente diminui-se as perdas. A escolha da técnica de treinamento de uma RNA depende dos dados disponíveis e do tipo de problema a ser avaliado.

No Aprendizado Supervisionado (Figura 3), rotula-se os dados e “alimenta” a RNA. Conseqüentemente, os dados são conhecidos e as saídas também. Assim, a rede procura espelhar o comportamento do padrão estipulado [7].

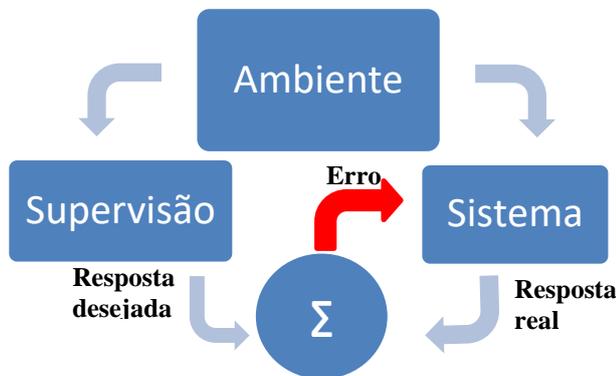


Figura 3. Treinamento supervisionado adaptado de [7].

No Aprendizado Não Supervisionado (Figura 4), a RNA não possui “professor”, não se conhece as saídas desejadas e não se conhece qual a qualidade dela. Em geral, utilizada para classificar os padrões de entrada [7].



Figura 4. Treinamento não supervisionado adaptado de [7].

Já o Aprendizado por Reforço (Figura 5) funciona por meio de tentativa e erro por parte da máquina. Assim, para que o programa siga para a solução do problema, são dadas recompensas ou penalidades pelas ações executadas [7].

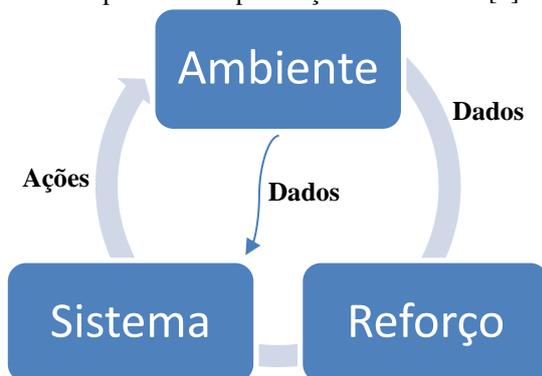


Figura 5. Treinamento por reforço adaptado de [4].

C. Vantagens e desvantagens de uma RNA

Dentre as qualidades tem-se [7]:

- Capacidade de adquirir conhecimento empiricamente a partir de uma base de dados e extrapolar para maiores fontes;

- Altamente intuitiva uma vez que se entende o princípio de funcionamento;
- Muito flexível, permitindo a solução de variados problemas;
- Deveras eficaz em sua tarefa, obtendo resultados extremamente positivos.

Porém, tem-se também as desvantagens:

- Há a possibilidade de haver *overfitting* (sobre ajuste) por ser demasiadamente eficaz;
- Demandam alto poder computacional (dependendo da aplicação);
- O treinamento de uma RNA pode ser extremamente difícil.

IV. METODOLOGIA

Objetivando a resolução de problemas sem a intervenção, e com performance tão boa ou melhor, que a humana, foi desenvolvido um estudo para a criação de uma IA baseada na técnica de RNA. O projeto dividiu-se em duas etapas: Estudo sobre técnicas de IA, definição dos requisitos desejados para cumprimento da IA, seleção da técnica que melhor se enquadra nas especificações, escolha de uma situação problema e, por fim, desenvolvimento do código. A rede neural artificial é desenvolvida para auxiliar no processo de tomada de decisão em cenário de planejamento da rotina semanal de irrigação de uma lavoura. A partir de informações meteorológicas e de condições do solo, coletadas de bases históricas e/ou atuais em tempo real, o sistema deve ser capaz de executar a predição da quantidade de água necessária no processo de irrigação de uma semana futura.

A. RNA - Desenvolvimento

Conforme explicitado anteriormente, a RNA serve como uma grande ferramenta na solução de problemas. Porém, o seu desenvolvimento é, de certa forma, simples, mas trabalhoso.

O desenvolvimento de uma RNA resume-se, simplificada, na definição de sua estrutura. Ou seja, afunila-se a decisão do número de camadas e da quantidade de neurônios em cada camada. Porém, ainda que pareça simples, existe mais um fator determinante: a arquitetura da RNA depende da complexidade do problema trabalhado [21].

Estrutura e ajuste da RNA

A estrutura da RNA a ser desenvolvida (Figura 6) depende da complexidade do problema. Tal motivo se dá pelo fato de que existem inúmeras aplicações e, conseqüentemente, inúmeras respostas desejadas. Existem divergências na literatura quanto a definição da quantidade de neurônios e camadas a serem utilizados. Porém, por meio do treinamento, é possível adequar a quantidade correta necessária para obter os resultados esperados [21].

Inicialmente, na camada de entrada, deve-se especificar as variáveis que são necessárias para compor a fonte de dados da estrutura lógica da rede. Para o problema de predição da irrigação, estas informações referem-se aos dados que podem ser coletados de registros históricos, estações meteorológicas ou de sensores.

É de interesse, também, estabelecer a taxa de aprendizado (valor aplicado sobre o erro para determinar a variação da diminuição) e um número máximo de *Epoch* (um ciclo completo de treinamento). Em relação aos parâmetros de

peso, são ajustados de forma independente pelo próprio modelo enquanto acontece a aprendizagem, objetivando sempre a minimização do erro [7][22].

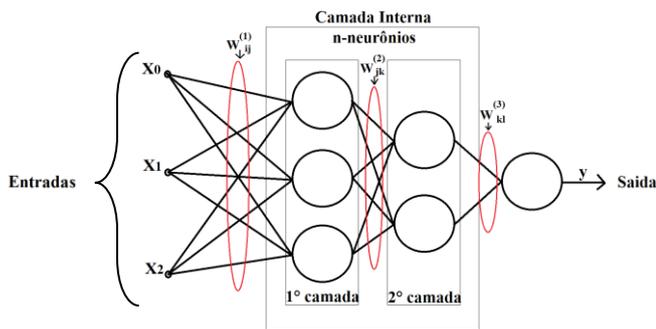


Figura 6 – Exemplo de uma estrutura RNA multicamadas.

Treinamento da RNA

Ao efetuar o treinamento da RNA, é necessário que seja feita a escolha do método de aprendizagem, como citado na secção III.B, e basear tal decisão para convergir em direção ao objetivo da criação da rede [23].

De forma simplificada, são executados algoritmos que aplicam pesos em cima dos dados de entrada e a partir da análise da saída, faz a correção dos pesos utilizando uma função erro. Para que o modelo não alcance um *overfitting*, é coerente a procura por pelo menos dois dos principais critérios de parada do processo de treinamento: número máximo de iterações (*epoch*) e erro mínimo alcançado [23]. Para a minimização do erro, utiliza-se uma técnica chamada *Backpropagation*. Em um treinamento supervisionado, que é o caso do cenário de aplicação deste trabalho, este algoritmo analisa a discrepância entre o sinal de saída oferecido pela RNA, e o valor esperado, para recalculer o valor dos pesos da última camada até atingir a camada de entrada [7].

B. RNA – Implementação computacional

A utilização da linguagem Python se tornou significativamente mais ativa desde os anos 2000. Dentre as linguagens utilizadas na comunidade de computação científica, o Python se destaca por ter uma das maiores comunidades ativas [24].

Os fatores que tornaram decisiva a escolha de tal linguagem para o projeto foram:

- A facilidade de aprendizagem;
- Variedade de bibliotecas voltadas para análise de dados.

Plataforma de desenvolvimento da RNA

Nesse projeto, utilizou-se o pacote de distribuição *open-source* chamado Anaconda [25], que possui diversas bibliotecas integradas voltadas para Ciência de Dados.

A biblioteca principal que foi utilizada é a API Keras É simples, de fácil uso, e fornece resultados consistentes, além de possuir vastas documentações e tutoriais [26].

Fluxograma e pseudocódigo da RNA

O modelo genérico de utilização e aplicação da RNA está exemplificado no fluxograma da Figura 7 e no pseudocódigo.

especificidade do problema abordado, com destaque para as seguintes atividades:

- Para a seleção de dados de treinamento, entende-se que é necessário filtrar eles possuindo em mente as variáveis de entrada do processo de tomada de decisão na predição da irrigação;
- Na correção do erro (em *Deep Neural Networks*), é comum a utilização do algoritmo de treinamento *Backpropagation* [27] para melhoria de desempenho da RNA implementada.

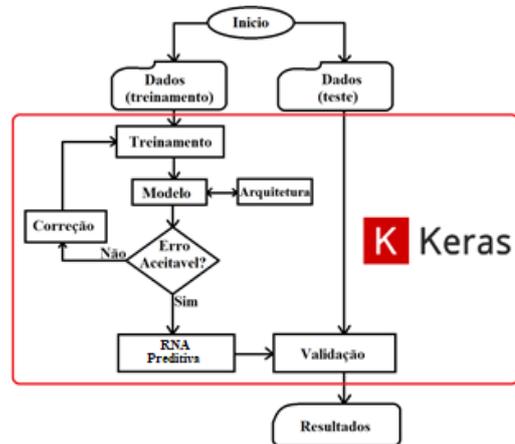


Figura 7 – Fluxograma da RNA genérica utilizando Keras, baseado em [28].

Pseudocódigo – RNA genérica

-
- Passo01. Inicializar os parâmetros
 Dados de treinamento (*T1Data*)
 Dados de teste (*T2Data*)
 Erro mínimo (*SetError*)
 Taxa de aprendizado (*Lr*)
 Número de *Epochs* (*nEpoch*)
- Passo02. Função de ativação $f(x) = \frac{1}{1+e^{-x}}$
- Passo03. Configurar a RNA
- Passo04. Executa o treinamento
 Enquanto (*erro > SetError* ou *epochs < nEpoch*)
 Executa o cálculo do erro levando em conta *Lr*
 Atualiza o valor dos pesos
 Fim do Enquanto
- Passo05. Executa validação com *T2Data*
-

Primeiramente, são declarados os parâmetros iniciais (Passo01) e logo após, é definida a função de ativação (Passo02), sendo a função de ativação Sigmoide que é especificadamente utilizada para modelos onde é necessário prever um valor como uma saída [29].

Para configurar a RNA (Passo03), é necessário estabelecer a estrutura da RNA (entradas, saídas e camadas internas) e a função de ativação, além de estabelecer o algoritmo de otimização com uma taxa de aprendizado *lr*.

Nessa etapa (Passo04), ocorre o treinamento utilizando os dados “*T1Data*” aplicados na função de ativação (Passo02) e, logo em seguida, calcula-se o erro. Após o cálculo, subtrai-se dos pesos o valor encontrado e atualiza os mesmos. O treinamento deve continuar ocorrendo caso não se extrapole a condição de parada.

Por fim (Passo05), utiliza-se o modelo obtido para validação utilizando os dados de teste “*T2Data*”.

Procedimentos de utilização da RNA

Como proposto no fluxograma da Figura 7 e no pseudocódigo, inicialmente deve ser feita a separação dos dados para treinamento e para validação do modelo. Após essa etapa, introduzir os dados na rede (nesse modelo genérico se utilizou a API Keras para facilidade).

Após o término das *Epochs* o modelo fica disponível para ser utilizado na predição da rotina de irrigação e/ou qualquer outro problema de predição similar.

V. CENÁRIO DE APLICAÇÃO

Um sistema de recomendação de irrigação inteligente deve ser desenvolvido com o propósito de estimar as necessidades hídricas para irrigar a lavoura adequadamente, garantindo as necessidades da plantação com responsabilidade ambiental, minimizando os desperdícios. Tradicionalmente, esta decisão é realizada por um experiente agricultor ou técnico agrícola especializado. A Figura 8 descreve um possível fluxograma do processo de tomada de decisão no planejamento da irrigação [30]. Um agrônomo especialista é responsável por analisar as informações de diferentes fontes, entre elas: estações meteorológicas localizadas próximo às plantações e registros de características da cultura e do solo (tipo, idade, tamanho, ciclo, entre outros). O processo de tomada de decisão pode ser realimentado com informações que podem ser coletadas em tempo real de sensores de solo instalados nos campos de cultivo. Neste processo todo, uma decisão gerenciável bastante relevante é aquela em que o especialista analisa as informações disponíveis em uma determinada semana, para fornecer um relatório de irrigação, que seja capaz de indicar a quantidade de água necessária para irrigar adequadamente a lavoura na semana seguinte.

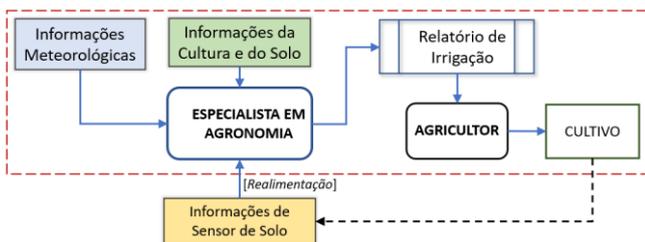


Figura 8 – Fluxograma do processo de planejamento da irrigação (adaptado de [30]).

O sistema de predição desenvolvido neste trabalho pode ser inserido neste cenário como ferramenta de apoio no processo de tomada de decisão em conjunto com o especialista. A proposta é avaliar o desempenho e a validade do sistema de predição em estimar as necessidades de água para a rotina de irrigação de uma semana futura, com base em informações de uma semana atual.

O sistema de predição deve ser tão preciso quanto possível no processo de recomendação da rotina de irrigação da lavoura. Para conferir essa validade do sistema, é necessário que sejam utilizadas as mesmas informações disponíveis para o especialista durante todo o processo de tomada de decisão. Os relatórios gerenciais com a descrição das decisões adotadas também são fundamentais. Portanto, o sistema de predição deve ser submetido a um processo de treinamento supervisionado com registros históricos. O planejamento da rotina de irrigação, realizado pelo especialista, para o período de cultivo de uma determinada lavoura, pode ser utilizado como sendo a verdade

fundamental do sistema. A Figura 9 apresenta o processo de treinamento supervisionado para o sistema de predição proposto neste trabalho, com aplicação no problema de planejamento da irrigação.

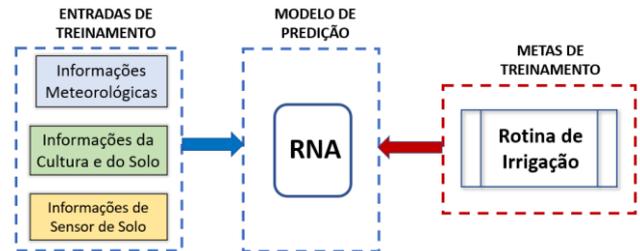


Figura 9 – Treinamento do sistema de predição para o planejamento da irrigação.

O Sistema de predição da irrigação pode receber informações de estações meteorológicas, da cultura e do solo, e de sensores de solo, e se for treinado adequadamente, é capaz de prever a rotina de irrigação da lavoura para a semana seguinte. A Tabela 1 lista o conjunto de possíveis variáveis de entrada do sistema de predição da irrigação, onde a variável “Evapotranspiração da Cultura (ETc)” descreve o perfil da plantação avaliada. O seu valor depende de vários fatores, entre eles podem ser destacados: o tipo de cultura, clima, o nível de evapotranspiração da cultura e o estágio de crescimento da planta no solo.

Tabela 1– Conjunto de possíveis variáveis de entrada do sistema de predição da irrigação (adaptado de [30]).

Variável de entrada	Símbolo	Categoria
Volume Água – Profundidade 1	VAP1	Sensor de solo
Volume Água – Profundidade 2	VAP2	
Volume Água – Profundidade 3	VAP3	
Potencial de Água no Solo	PAS	Estação meteorológica
Temperatura do Solo	TS	
Chuva	CV	
Velocidade do Vento	VV	
Temperatura	T	
Humidade Relativa	HR	
Radiação Global	RG	
Ponto de Orvalho	PO	Registro
Deficit de Pressão de Vapor	DPV	
Evapotranspiração da Cultura	ETc	

O conjunto de dados de treinamento $\mathbf{D} = \{\mathbf{X}, \mathbf{T}\}$, com N amostras, é modelado por uma matriz preditora $\mathbf{X} = [x_{11}, \dots, x_{1i}, \dots, x_{1K}, \dots, x_{N1}, \dots, x_{Ni}, \dots, x_{NK}]^T$ e uma matriz de resposta $\mathbf{Y} = [y_{11}, \dots, y_{1i}, \dots, y_{1M}, \dots, y_{N1}, \dots, y_{Ni}, \dots, y_{NM}]^T$. x_i é um vetor coluna de K elementos, que pode conter todas as medidas dos sensores e das variáveis meteorológicas indicadas na Tabela 1 em uma determinada semana i . y_i é outro vetor coluna de M elementos, contendo o valor das variáveis a serem estimadas naquela semana i .

VI. RESULTADOS E DISCUSSÕES

Nesta seção são descritos alguns resultados preliminares para as técnicas de configuração, treinamento e aplicação da Rede Neural Artificial no processo de planejamento da irrigação. Pretende-se prever com sucesso a necessidade de irrigação de uma lavoura, com base nas informações fornecidas pelos dispositivos de coleta e pelo conhecimento aprendido com registros de relatórios de irrigação.

Devido as dificuldades de se obter dados reais para simulação da ferramenta computacional implementada, foi

criado um cenário hipotético capaz de representar com alto grau de fidelidade um possível ciclo completo de desenvolvimento de uma lavoura na vida real.

Treinamento e validação do sistema de predição:

Entre todos os conjuntos possíveis de recursos (Tabela 1), apenas algumas combinações com sentido lógico, que podem ser identificadas por um engenheiro agrônomo especialista, é que devem ser consideradas durante o processo de tomada de decisão. O tipo de ciclo da lavoura, o estágio de desenvolvimento da planta, o sistema de irrigação adotado, registros históricos disponíveis, são alguns dos fatores determinantes na escolha de quais variáveis de entrada são mais relevantes para o processo de tomada de decisão.

A nível de demonstração, neste trabalho o conjunto de dados de treinamento é composto por informações que simulam 52 semanas de planejamento:

- O vetor de dados de entrada é composto por informações de três variáveis, de forma a reproduzir informações de registro que podem ter sido obtidas de sensor de solo (VAP1, PAS) e de perfil de lavoura (ETc), respectivamente.

- O vetor da variável resposta contém a rotina de irrigação estipulada pelo especialista. A informação utilizada é o tempo de irrigação (em minutos) adotado em cada uma das 52 semanas de planejamento.

Para uma melhor escolha dos parâmetros de configuração da RNA, foi realizado um treinamento variando a quantidade de neurônios que compõem a rede. A Tabela 2 lista o resultado deste treinamento com o ranqueamento das RNAs com base nas métricas de desempenho: Erro Absoluto Médio, Erro Quadrático Médio e Raiz quadrada do Erro Quadrático Médio.

Tabela 2 – Treinamento da RNA x Número de neurônios.

Escolha de número de neurônios baseado nas métricas de desempenho			
Neurônios	Erro absoluto médio	Erro Quadrático Médio	Raiz quadrada do Erro Quadrático Médio
10	84,8	10600,9	103,0
20	78,7	8896,2	94,3
30	63,1	5709,1	75,6
40	28,8	1228,9	35,1
50	29,6	1280,7	35,8
60	2,2	6,7	2,6
70	3,2	18,9	4,3
80	2,7	8,8	3,0
90	3,1	19,8	4,4
100	3,0	10,0	3,2

Após treinar a rede com a variância dos valores de neurônios de 10 a 100, chegou-se no melhor resultado que é uma RNA com 60 neurônios. Este valor foi escolhido pois as suas métricas de desempenho se encontram abaixo dos demais (quanto menor os valores, melhor o desempenho da RNA).

Com a RNA ajustada com 60 neurônios efetuou-se mais um treinamento. Dessa vez, variando os valores de *epoch*. O objetivo foi identificar a melhor configuração da RNA para o processo de predição, após o seu treinamento com a base dados do problema de planejamento da irrigação.

Tabela 3 – Treinamento da RNA x Número de *epoch*.

Escolha de número de <i>Epochs</i> baseado nas métricas de desempenho			
Epochs	Erro absoluto médio	Erro Quadrático Médio	Raiz quadrada do Erro Quadrático Médio
50	140,0	34462,5	185,6
100	129,5	29878,5	172,9
150	82,0	11588,6	107,7
200	27,6	1064,9	32,6
250	2,9	14,8	3,8
300	2,9	17,1	4,1

Como pode-se perceber, após o treinamento da RNA com número de *epochs* entre 50 e 300, o melhor resultado alcançado foi aquele com 250 *epochs*.

O Gráfico 1 descreve a evolução do processo de treinamento e validação da RNA com 60 neurônios e 250 *epochs*. A Perda diminui consideravelmente até que os valores de Treino e Validação sejam relativamente os mesmos em 250 *Epochs*. Vale observar que o ajuste dos parâmetros da RNA durante esta etapa de treinamento e validação é um processo empírico. Outros resultados podem ser alcançados com diferentes métodos de análise.

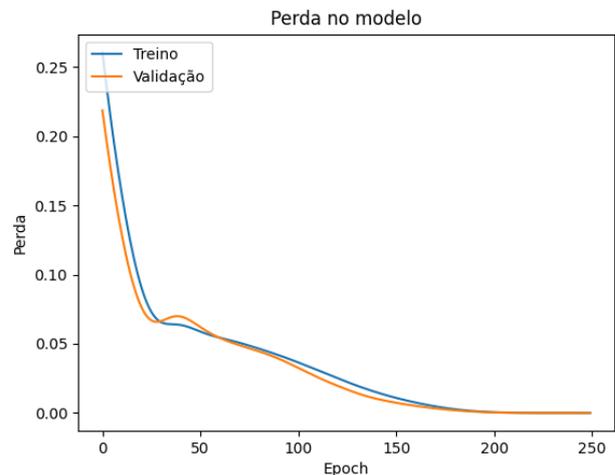


Gráfico 1 – Perdas por *Epoch*.

Teste do sistema de predição:

A RNA configurada e treinada pode, então, ser utilizada na predição para auxiliar no processo de tomada de decisão do planejamento da rotina de irrigação. O cenário de aplicação contempla uma base de dados com registros de 20 semanas. A RNA recebe os dados das três variáveis de entrada (VAP1, PAS e ETc) e executa o processo de predição da variável de saída, indicando a quantidade de minutos semanal que o sistema de irrigação deve operar.

O Gráfico 2 apresenta os resultados da predição da RNA para as 20 semanas (semana 0 até semana 19). A recomendação de irrigação semanal apontada pelo agrônomo especialista é considerada como sendo a verdadeira. Neste sentido, quanto mais próxima a predição estiver destes valores, melhor é o processo de tomada de decisão do sistema proposto com a RNA.

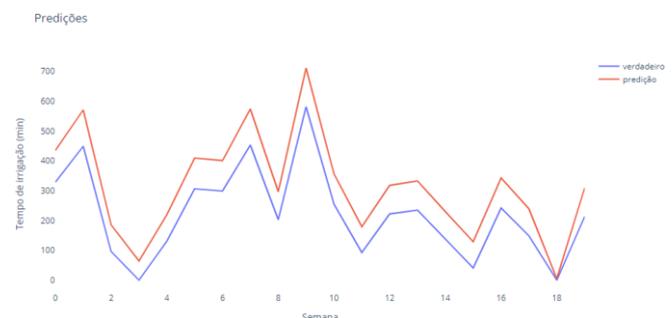


Gráfico 2 – Comparativo de valores verdadeiros em relação a predição.

É possível perceber pelos resultados do Gráfico 2 que a RNA compreendeu com exímio rigor o padrão de irrigação adotado pelo especialista. Neste cenário, a predição realizada pela RNA apresenta um comportamento conservador no planejamento semanal da irrigação. Isto pode ser interessante para o agricultor no planejamento da capacidade do

reservatório para atender todo o ciclo do cultivo, garantindo uma margem de segurança na quantidade de água necessária. Porém, deve-se destacar que uma previsão de irrigação pontual acima do necessário naquele instante pode prejudicar o desenvolvimento da planta.

Com o objetivo de melhorar o processo de tomada de decisão do sistema proposto, foi realizado um ajuste na previsão da RNA, utilizando o valor do Erro Quadrático Médio alcançado nas cinco primeiras semanas de teste do ciclo de 20 semanas. O Gráfico 3 e a Tabela 5 apresentam um comparativo entre a rotina de irrigação apontada pelo especialista (verdadeiro, real), a previsão realizada pela RNA (predição) e a previsão alcançada com a RNA ajustada (predição ajustada).

O processo de predição ajustada melhora o resultado do planejamento da irrigação ao aproximar o valor da predição do valor verdadeiro (real), em cada semana, a partir da semana 6. Com mais dados coletados, no decorrer das semanas, o erro entre os dois planejamentos diminui consideravelmente. A predição ajustada mostrou-se mais eficiente tanto na indicação da rotina semanal de irrigação, quanto na previsão de necessidade hídrica total do ciclo da lavoura, com apenas 12% a mais que o considerado verdadeiro pelo especialista.

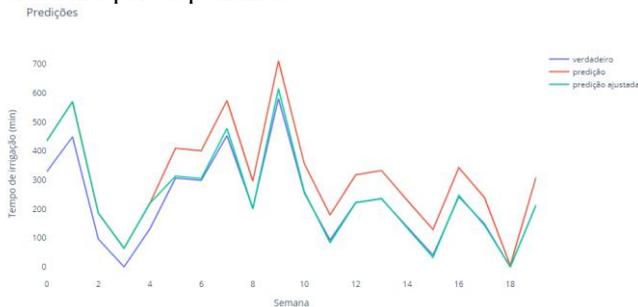


Gráfico 3 – Comparativo entre as rotinas de planejamento da irrigação.

Tabela 5 – Comparativo da predição de 20 semanas de irrigação.

Valores ajustados com base nos 5 primeiros valores reais			
Semana	Real	Predição	Predição ajustada
1	328,6	434,4	434,4
2	449,0	557,3	557,3
3	96,4	184,8	184,8
4	0,0	66,6	66,6
5	130,6	228,0	228,0
6	306,3	415,5	321,0
7	298,9	404,1	309,6
8	452,8	561,3	466,7
9	202,7	303,6	209,1
10	581,1	692,1	597,5
11	254,8	352,7	258,2
12	92,7	185,1	90,5
13	222,4	324,7	230,2
14	234,5	332,5	238,0
15	137,8	231,8	137,3
16	40,7	127,6	33,1
17	242,2	337,7	243,2
18	148,6	241,3	146,8
19	0,0	0,0	0,0
20	213,4	313,5	219,0
Total	4433,5	6294,7	4971,3

Interface gráfica de execução do sistema de predição:

Com o objetivo de facilitar o manuseio do sistema de tomada de decisão proposto neste trabalho, foi desenvolvido um *software* de interface gráfica, também em Python, tornando o processo de utilização da IA bem mais

intuitivo pelo usuário do sistema. A Figura 10 apresenta o fluxograma de utilização dessa interface gráfica.

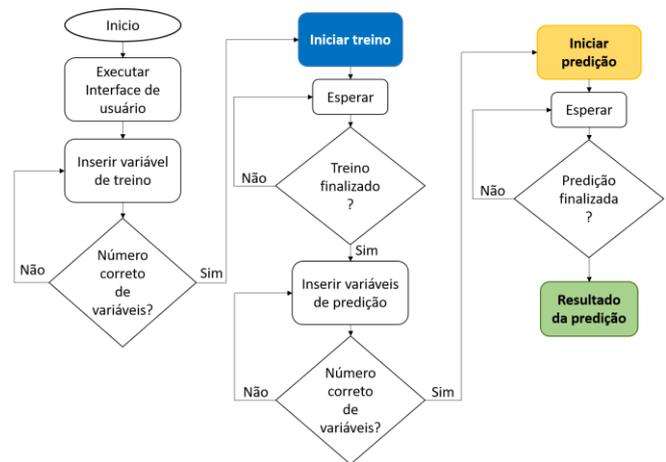


Figura 10 – Fluxograma de utilização da Interface Gráfica.

Conforme descrito no fluxograma da Figura 10, os passos para execução prática da RNA são os seguintes:

- O usuário inicializa o programa (Figura 11)

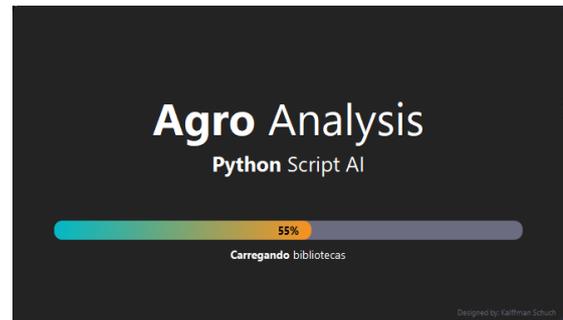


Figura 11 – Inicializando o *software*.

- O usuário “clica” na “engrenagem” (configurações).
- Na tela de treinamento (Figura 12), o usuário insere os dados das variáveis de entrada “SWC1-m”, “SWP-r” e “ETC-r” e da variável de saída “Irrigação”. As variáveis utilizadas no sistema são customizáveis, podendo ser alteradas na estrutura da IA, tanto na quantidade quanto na fonte de coleta utilizada. Por exemplo, no cenário avaliado neste trabalho, tem-se que: “SWC1-m” representa os dados da variável “VAP1-medida”, “SWP-r” representa os dados da variável “PAS-registro” e “ETC-r” representa os dados da variável “ETC-registro”.

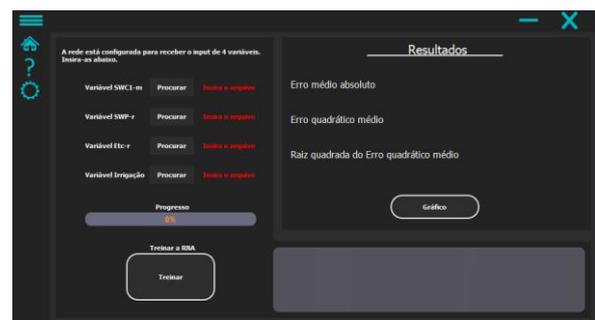


Figura 12 – Tela de inserção de variáveis de treinamento.

- Após inseridas as variáveis, o usuário pode inicializar o treinamento da RNA (Figura 13).



Figura 13 – Tela com variáveis incluídas e treinamento concluído.

- Com a finalização do treinamento (Figura 13), sinalizado pela aparição dos resultados e mensagem indicativa na parte inferior da tela, o usuário deve “clique” no “símbolo da casa”.
- Na tela de predição (Figura 14), o usuário insere os dados das variáveis “SWC1-m”, “SWP-r”, “Etc-r” e “Irrigação”, do cenário de teste de predição.

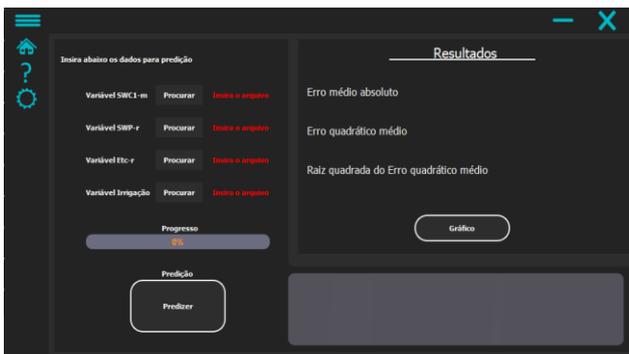


Figura 14 – Tela de inserção de dados das variáveis de teste predição.

- A etapa de teste de predição é então finalizada (Figura 15). A conclusão do processo é sinalizada com a visualização dos resultados da predição.

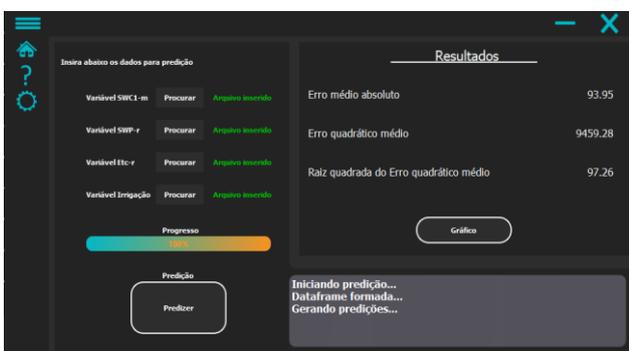


Figura 15 – Tela com variáveis incluídas e teste de predição concluído.

VII. CONCLUSÃO

Com o avanço tecnológico atual, o volume de produção de dados aumenta constantemente, tornando difícil a extração de informações relevantes. Nesse âmbito, a IA entra como uma alternativa para resolver esse problema,

automatizando os processos de aplicação e tomada de decisões.

A relevância da RNA nesse quesito é irrefutável, podendo ser utilizada na predição de futuros cenários. Dessa forma, este trabalho apresenta um estudo da aplicação destas técnicas no processo de apoio à decisão para o planejamento da rotina de irrigação de uma lavoura.

Inicialmente foi realizada uma pesquisa referente a técnicas utilizadas na RNA para decidir qual aproximação seria feita em relação ao problema de predição. Durante o estudo, chegou-se na definição de utilizar o modelo Sequencial, com arquitetura *Feedforward*, diversas variáveis para a camada de entrada e uma variável para a camada de saída, caracterizada pelo valor da predição. No processo de treinamento da RNA é utilizando o algoritmo *Backpropagation*.

Como plataforma de desenvolvimento, foi utilizada a linguagem de programação Python. Os fatores determinantes para sua escolha foram: a linguagem se tornou uma das mais utilizadas na comunidade de desenvolvedores de softwares, facilidade de aprendizado e variedade de bibliotecas voltadas para análise de dados e inteligência artificial.

Os resultados finais obtidos com o modelo foram promissores, considerando a dificuldade em efetuar uma predição de um evento futuro, aproximado, com poucas variáveis. No cenário estudado, embora os valores de predição da rotina de irrigação semanal sejam um pouco mais elevados do que os valores reais, a IA desenvolvida consegue acompanhar o comportamento padrão do planejamento apontado por um especialista.

Como um método aditivo, utilizou-se a alimentação de dados de 5 semanas (simulando o *input* com a *expertise* do agricultor) para efetuar uma correção utilizando os valores previstos em comparação aos reais. Com este método aditivo o erro foi reduzido por meio da Raiz quadrada do Erro Quadrático Médio. Os resultados obtidos se aproximam consideravelmente do da predição real. Esta metodologia permitiu reduzir para 12% a diferença do tempo de irrigação total da predição ajustada para o planejamento real, para um ciclo de cultivo 20 semanas.

Para trabalhos futuros, vislumbra-se a melhoria da Interface de Usuário e avaliar o desempenho do sistema de predição desenvolvido em diversos cenários:

- Estudo de campo, com coleta de dados reais, acrescida de uma base de dados robusta de todo o ciclo de planejamento do processo de irrigação da lavoura;
- Aplicação em diferentes plantações, com diferentes ciclos, sob várias condições e regiões de cultivo;
- Avaliação do impacto de se adicionar informações de previsão do clima da região de cultivo como variável de entrada. Vislumbra-se que isto seja relevante para aquelas regiões que possuem uma rotina irregular de chuvas.

VIII. REFERÊNCIAS

- [1] Goapa, A., D. Sharmab, A.K. Shuklab and C.R. Krishnaa, 2018. An IoT based smart irrigation management system using machine learning and open source technologies. *Comput. Electron. Agric.*, 155: 41-49. DOI: 10.1016/j.compag.2018.09.040.
- [2] Aqeel-ur-Rehman, A.Z. Abbasi, N. Islam and Z.A. Shaikh, 2014. A review of wireless sensors and networks' applications in agriculture. *Comput. Standards Interfaces*, 36: 263-270. DOI: 10.1016/j.csi.2011.03.004.
- [3] Shekhar, Y., E. Dagur, S. Mishra, R.J. Tom and M. Veeramanikandan, 2017. Intelligent IoT based automated irrigation system. *Int. J. Applied Eng. Res.*, 12: 7306-7320.
- [4] W. R. da Silva, J.C. G. de Almeida, E.F. de Oliveira, E.R. Neto, C.A. Ynoguti, J.P.C. Henriques. *Manufatura Avançada para Produção Agrícola usando Inteligência Artificial e IoT*. SBA 2019, pp 1908-1913.
- [5] K. Faceli, A.C. Lorena, J. Gama, A.C.P.L.F Carvalho. *Inteligência Artificial - Uma Abordagem de Aprendizado de Máquina*. LTC, 2011.
- [6] S. RUSSELL and P. NORVIG, *Artificial Intelligence: A Modern Approach*, 4th ed. Upper Saddle River, NJ, USA: Prentice Hall, 2009
- [7] HAYKIN, S. *Redes neurais: princípios e práticas*. Tradução ENGEL, P.M. 2.ed. Porto Alegre: Bookman, 2001. 900p.
- [8] Russell S, Norvig P. *Inteligência Artificial*. 2ª ed. Rio de Janeiro: Elsevier; 2004.
- [9] Py MX. *Sistemas especialistas: uma introdução*. Instituto de Informática, Universidade Federal do Rio Grande do Sul. 2009;10(11).
- [10] F.C Santos, C.L de Carvalho. *Aplicação da Inteligência Artificial em Sistemas de Gerenciamento de Conteúdo*. Relatório Técnico RT-INF_001-08, abril, 2008
- [11] METAXIOTIS, K; ERGAZAKIS, K; SAMOULIDIS, E; PSARRAS, J. *Decision Support Through Knowledge Management: The Role of The Artificial Intelligence*. *International Journal of Computer Applications in Technology*, 19(2):101–106, 2004.
- [12] Santos HA. *Utilização de um sistema especialista para diagnóstico de patologias ortopédicas dos membros inferiores [trabalho de conclusão de curso]*. Palmas: Centro Universitário Luterano de Palmas, Universidade Luterana do Brasil; 2011.
- [13] Souza AR, Talon AF. *Inteligência Artificial Aplicada à Medicina*. *Caderno de Estudos Tecnológicos*. 2013;1(1):59-72.
- [14] De Castro, L.N; Ferrari, D.G. *Introdução à mineração de dados: conceitos básicos, algoritmos e aplicações*. São Paulo. Saraiva, 2016.
- [15] A. Ghosh and S. Tsutsui. *Advances in Evolutionary Computing: Theory and Applications*. *Springer Science & Business Media*, 2012
- [16] Miroslav Kubat. *An Introduction to Machine Learning*. 2a ed. Springer, 2017.
- [17] GEORGE, J.K.;BO, Y.. *Fuzzy Sets and Fuzzy Logic, Theory and Applications*, 2008.
- [18] Ivan Nunes da Silva; Danilo Hernane Spatti; Rogério Andrade Flauzino. *Redes neurais artificiais para engenharia e ciências aplicadas*. 2ª ed. São Paulo, 2016.
- [19] UNIVERSIDADE DE SÃO PAULO, INSTITUTO DE CIÊNCIAS MATEMÁTICAS E DE COMPUTAÇÃO. *Redes neurais artificiais*. Disponível em: <<https://sites.icmc.usp.br/andre/research/neural/>>. Acesso em: 12 nov. 2020.
- [20] MCCULLOCH, Warren S.; PITTS, Walter. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, v. 5, n. 4, p. 115-133, 1943.
- [21] HAGAN, M. T.; DEMUTH, H. B. BEALE M.,(1996)“*Neural Network Design* PWS Publishing company.
- [22] ROBERT, Hecht-Nielsen et al. Theory of the backpropagation neural network. *Proc. 1989 IEEE IJCNN*, v. 1, p. 593-605, 1989.
- [23] POMMERANZENBAUM, I. R. *Redes neurais artificiais na predição das principais séries do índice Ibovespa e suas aplicações em sistemas automatizados de negociação*. 114 p. 2014. Tese de Doutorado. Dissertação (Mestrado)-COPPE, Programa de Engenharia Elétrica, Universidade Federal do Rio de Janeiro, Rio de Janeiro.
- [24] MCKINNEY, W. *Python for Data Analysis*. [S.l.]: O’Reilly Media, 2013.
- [25] ANACONDA. *The Word’s Most Popular Data Science Platform*. Disponível em: <<https://www.anaconda.com/>>. Acesso em: 17 nov. 2020
- [26] KERAS. *Keras: the Python deep learning API*. Disponível em: <<https://keras.io/>>. Acesso em: 17 nov. 2020
- [27] HECHT-NIELSEN, Robert. *Theory of the backpropagation neural network*. In: *Neural networks for perception*. Academic Press, 1992. p. 65-93.
- [28] MARTINHO, Valquíria RC; NUNES, Clodoaldo; MINUSSI, Carlos R. *Um Novo Método para Predição da Evasão Escolar Usando Redes Neurais*.
- [29] SIBI, P.; JONES, S. Allwyn; SIDDARTH, P. *Analysis of different activation functions using back propagation neural networks*. *Journal of theoretical and applied information technology*, v. 47, n. 3, p. 1264-1268, 2013.
- [30] Hellin et al. *A decision support system for managing irrigation in agriculture*. *Computers and Electronics in Agriculture* 124 (2016) 121–131.

