

AUTOMAÇÃO DE SISTEMA DE IRRIGAÇÃO UTILIZANDO REDES NEURAS ARTIFICIAIS EMBARCADA EM APLICAÇÃO DE INTERNET DAS COISAS

Enzo Contieri¹; Alessandra Dutra Coelho² ;
Wânderson de Oliveira Assis²; Rogério Cassares Pires³

¹ Aluno de Iniciação Científica da Escola de Engenharia Mauá (EEM-CEUN-IMT);

² Professor da Escola de Engenharia Mauá (EEM-CEUN-IMT);

³ Engenheiro do Centro de Pesquisas (CP-CEUN-IMT).

Resumo. *O trabalho em pauta aborda um estudo dos dados coletados através dos sensores de umidade da horta do Centro de Pesquisa do Instituto Mauá de Tecnologia, estando estes dispostos em posições estratégicas. O objetivo deste estudo é consolidar a integração do hardware e dos softwares do sistema através da plataforma desenvolvida a partir da interface implementada por meio de algoritmos e ferramentas de Internet das Coisas. Desta forma, no futuro, pode-se implementar no sistema algoritmos de redes neurais artificiais tornando-o autônomo e aumentando o valor de mercado da solução trabalhada. Esta plataforma permitirá a realização do controle automatizado do acionamento das válvulas, possibilitando a coleta de dados em tempo real para que posteriormente uma rede neural efetue a previsão do nível de umidade ideal para a irrigação do plantio, visando minimizar o consumo de água a partir da interpretação dos dados coletados. A coleta de dados, o envio destes para os dashboards construídos e o acionamento à distância das válvulas do sistema de irrigação foram bem-sucedidos e se mostraram viáveis e replicáveis, portanto pode-se considerar o sistema apto a receber a rede neural para que se torne autônomo.*

Introdução

Segundo o Banco Mundial, a proporção de terras aráveis em 1960 era de 38 hectares por pessoa, com uma população de 3 bilhões. Em 2019, com uma população de 7,6 bilhões, a proporção caiu para 19,6 hectares por pessoa. Além disso, há fortes indícios que o mundo está perdendo biodiversidade alimentícia. De acordo com um estudo conduzido recentemente pelo grupo varejista Carrefour (Coraccini, 2019), nos anos 1960 havia mais de mil tipos de feijão no Brasil, enquanto que, atualmente, apenas o feijão “carioquinha” corresponde a 70% das variedades.

Tendo em mente que a FAO (Organização para alimentação e agricultura das Nações Unidas) afirma que a humanidade precisará de 60% mais alimentos do que precisa hoje (além dos 40% a mais de produção extra e 50% a mais de energia e água necessários), urge que surjam tecnologias que otimizem e potencializem os métodos de plantio já empregados e a forma como utilizamos os recursos envolvidos nesses processos (Coraccini, 2019).

Ao mesmo tempo, veio à tona a Quarta Revolução Industrial e com ela surgiu um novo setor, o da agricultura de precisão. Este tem recebido um grande impulso de atividade, criatividade e capital de empresas, fruto do robusto investimento em tecnologias de conectividade. Nessas aplicações há múltiplos microcontroladores que monitoram processos na agricultura, sendo responsáveis pelo controle e comunicação entre as operações da rede. As suas transmissões são realizadas por protocolos de comunicação, os quais coletam e armazenam os dados do plantio. A

maioria destes está relacionada com tecnologias conectadas à rede de “*Internet*”, tais como Wi-Fi, Sigfox e LoRaWanTM (Boyadjian et al., 2019) (IEEE et.al, 2019).

Talvez a tarefa mais importante que temos em comum dentre essas tecnologias seja a condução de análises preditivas em processos produtivos, já que estas podem reduzir consideravelmente riscos, ocorrência de falhas e o gasto excessivo de recursos valiosos como dinheiro, matéria-prima, mão-de-obra, tempo e água. No estudo aqui apresentado, pode-se ver que o processamento e exploração dos dados da agricultura podem ser realizados por redes neurais, que, por sua vez, detectam padrões e efetuam previsões. Desse modo, aplicações em pequenos e grandes plantios podem otimizar significativamente o uso de diversos recursos, como a água por exemplo, com mínima interferência do ser humano (WIRED, 2019).

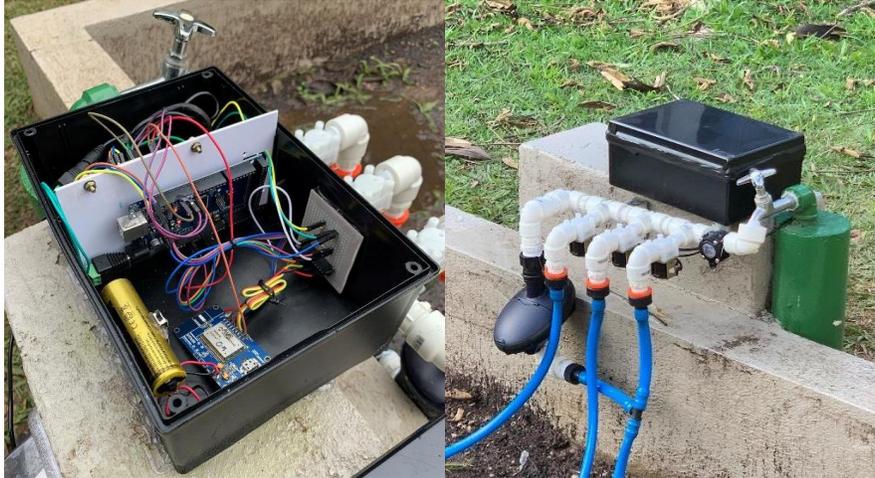
Objetivos

O projeto tem por objetivo realizar o estudo da implementação e testes de um sistema de irrigação inteligente. A partir da coleta de dados e do envio destes para exibição em *dashboards*, a solução trabalhada estará apta a futuramente determinar o tempo de acionamento dos aspersores por intermédio de redes neurais artificiais. Dessa forma, monitoram-se os dados de umidade do solo adquiridos das diferentes alturas de três sensores, coletando-se dados pertinentes que contribuam com a obtenção de um nível ótimo de gasto de recursos hídricos no plantio.

Materiais e Métodos

O projeto trabalhado utiliza dispositivos que já foram testados, melhorados e instalados pela equipe do Centro de Pesquisa (CP-CEUN-IMT) e por alunos de iniciações científicas anteriores (Boyadjian, 2019) (Kuke, 2020):

- a) Arduino Mega 2560 – Microcontrolador de plataforma eletrônica *open-source*. Ele capta e transmite os sinais vindos do PIC;
- b) Componentes eletrônicos diversos que serão destacados posteriormente;
- c) Galcon 9001BT – Temporizador de irrigação programável com opção de controle por aplicativo via *bluetooth*;
- d) Módulo LoRa RN2903 – Módulo de transmissão por radiofrequência desenvolvido pela LoRa Alliance. Ele possui baixo consumo de energia e pode alcançar longas distâncias dependendo do local;
- e) Microcontrolador PIC 24FJ128GA306 – Microcontrolador responsável por captar sinais de sensores e transmitir para atuadores os dados provenientes do módulo LoRa;
- f) Sensor de fluxo de água YF-S201b – Medidor de fluxo de água que envia os dados de vazão através de pulsos PWM;
- g) Válvula de vazão solenoide 12VDC – Válvula normalmente fechada e de 2 vias que controla a passagem de água;



Figuras 1 - Caixa contendo o circuito responsável pelo controle da irrigação da horta

Os seguintes *softwares* de programação foram utilizados durante o projeto:

- a) Node-RED – Ferramenta de programação em blocos (*nodes*) que estabelece conexão com *hardwares* e serviços *online*, com destaque para a fácil visualização da interação entre os algoritmos de programação e implementação dos mesmos (Smart Campus Mauá, 2020);
- b) ThingSpeak – Serviço analítico de coleta de dados em tempo real que permite agregar, visualizar e analisar fluxos de dados ao vivo na nuvem. Deste foi utilizada sua ferramenta de construção gráfica.

Com o intuito de ilustrar as funções exercidas pelos *softwares* e *hardwares* descritos acima, Kuke (2020) desenvolveu a explicação da solução desenvolvida a partir de uma divisão em quatro etapas. Contudo, no relatório vigente é proposto o acréscimo de uma etapa a mais nesse processo, uma vez que se obteve êxito na coleta e visualização dos dados do sistema.

Na primeira etapa analisa-se a lógica de funcionamento do processo de transmissão de dados, como mostrado na figura 2.

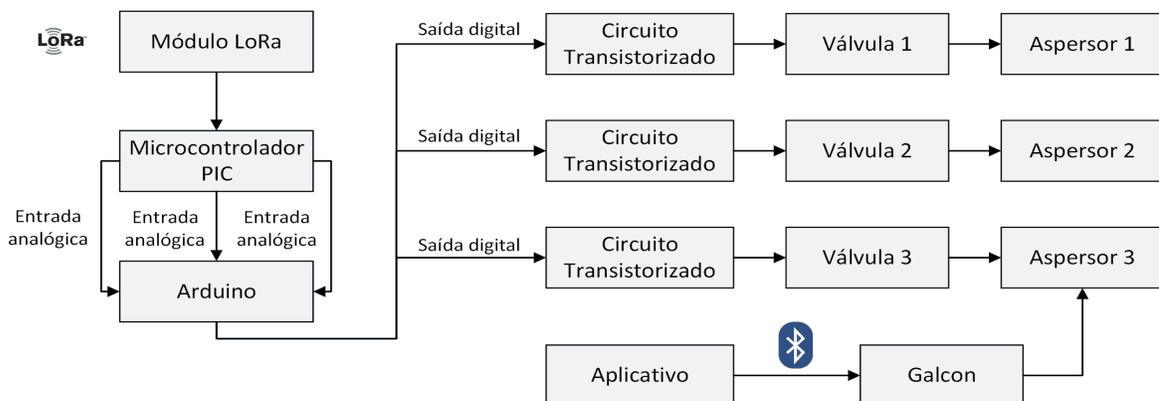


Figura 2 - Fluxograma do acionamento das válvulas

A segunda etapa consiste no acompanhamento da operação do sistema. Em seguida, a figura 3 mostra o mecanismo de coleta de dados relativos à vazão. Verifica-se o estado de cada válvula, com o intuito de se saber se o circuito está operando da maneira desejada.

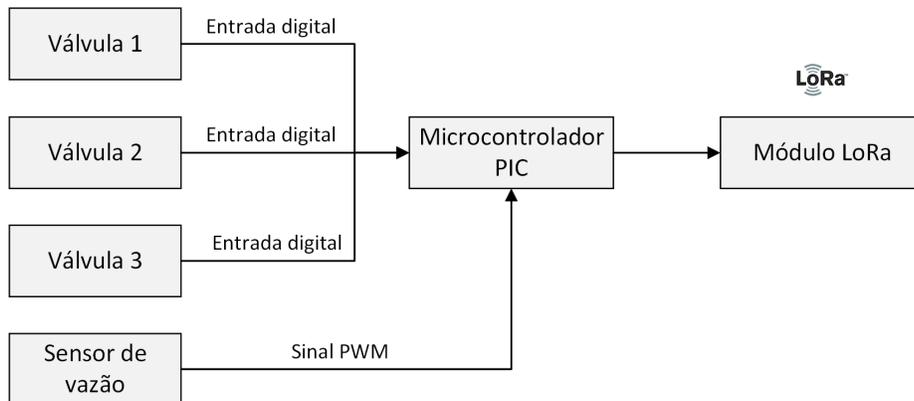


Figura 3 - Fluxograma do processo de captura de dados de vazão

Nesse processo de aquisição de informações dispõe-se ainda de um sensor de vazão, a partir do qual se pode verificar se as válvulas estão operantes ou se o controlador Galcon está liberando a passagem de água. O sensor de vazão funciona como um contador, sendo a contagem dos pulsos armazenada e enviada para o servidor a cada oito minutos, uma vez que esse é o tempo que o microcontrolador está programado para atualizar seus dados. Esta informação recebida é então convertida em valores em litros, nos fornecendo portanto o valor da vazão.

A terceira etapa é composta pela recepção dos dados relativos à vazão de água, estado das válvulas, tensão da bateria, umidade nas diferentes profundidades de medição e o tempo de última atualização dos dados na interface *web*. A metodologia do sistema é demonstrada na figura 4.

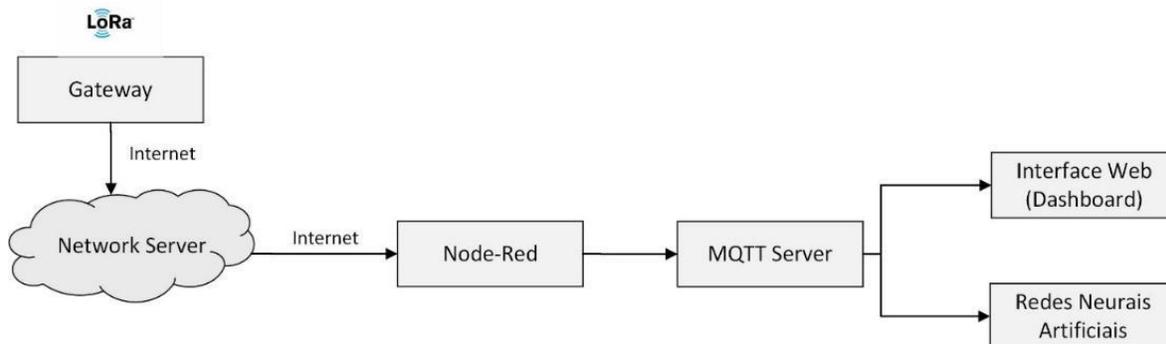


Figura 4 - Fluxograma do processo de obtenção de dados

Inicialmente, as informações captadas pelos sensores e transmitidas pelos microcontroladores chegam ao *Gateway* via LoRaWanTM. Elas são organizadas e encaminhadas ao *Network Server* pela *Internet*. Deste ponto em diante, os dados são enviados e tratados via Node-RED. Assim, a partir de blocos programáveis (*nodes*), configuramos o servidor através da interface do *MQTT Broker*, permitindo a integração em tempo real dos dados provenientes do

próprio servidor. Nesse sentido, foi realizada a divisão em dois fluxos de códigos (*flows*) para finalidades diferentes, *uplink* e *dowlink*.

No *uplink*, ocorre a recepção e tratamento dos dados da aplicação. Num primeiro momento, realiza-se a configuração do servidor, seguida pela conversão do texto no formato *string JSON* para objeto *JSON*. Após isso, coleta-se a parte do pacote com a informação de interesse. Para finalizar, a mensagem é decodificada de Base64 e codificada em hexadecimal, para ser fragmentada em informações específicas. A visualização do *flow* está representada na figura 5.

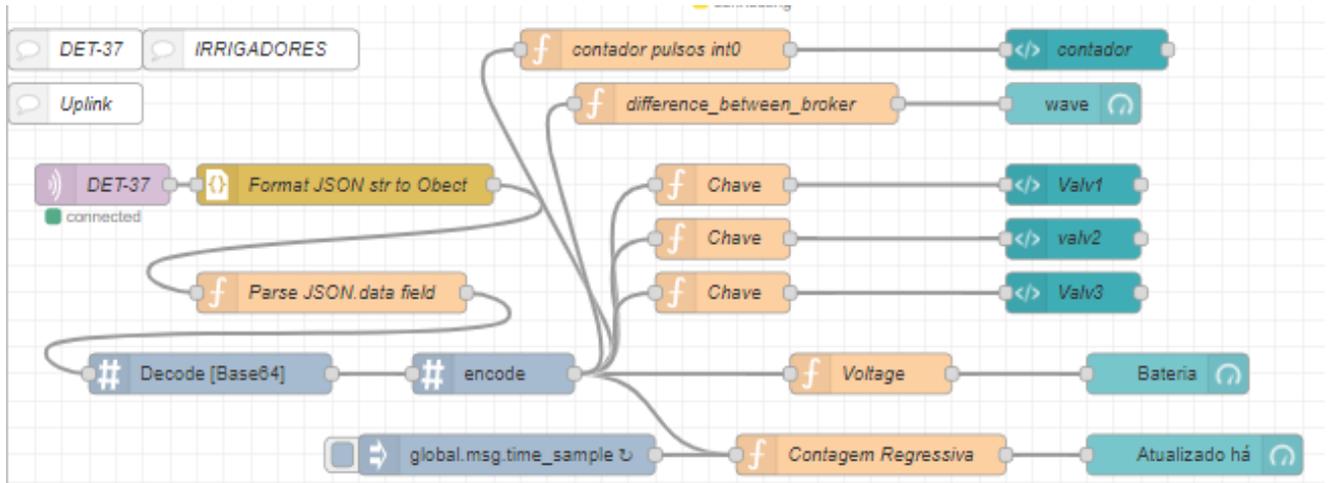


Figura 5 - Flow referente ao Uplink

Por outro lado, o *dowlink* transmite sinais para o microcontrolador PIC com módulo LoRa (*End-node*) via LoRaWan™. A princípio, é necessária uma interação de um usuário para que seja efetuada uma determinada ação. Neste caso, é preciso pressionar o botão. Após isso, envia-se uma mensagem ao dispositivo microcontrolado, a partir da configuração do servidor via *MQTT Broker*, executando uma tarefa pré-programada. Isso é observado na figura 6.

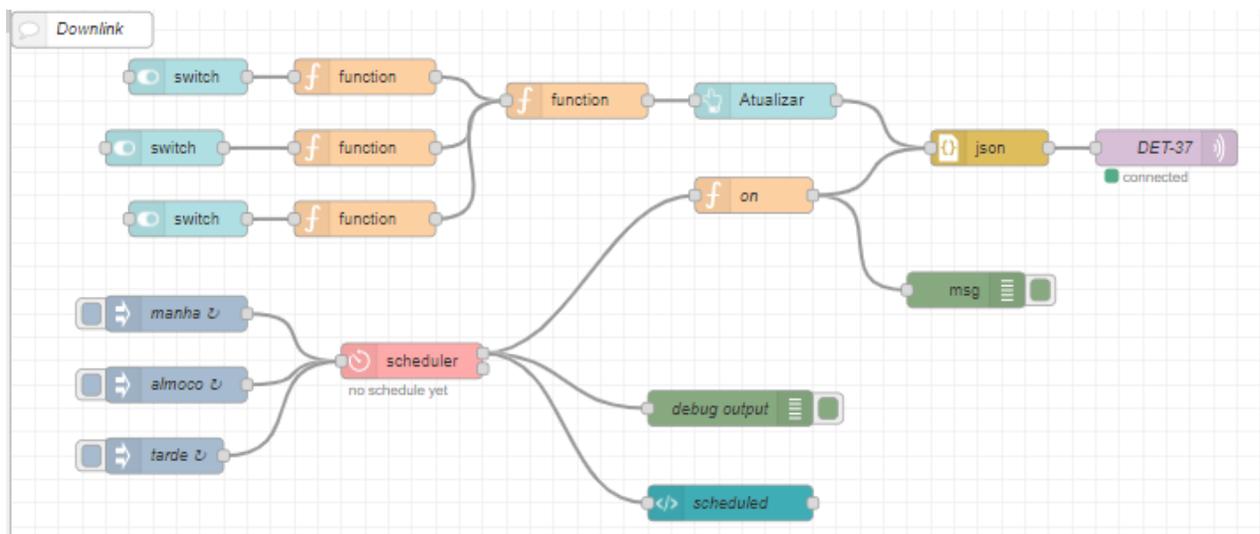


Figura 6 - Flow referente ao Downlink

Em ambos os fluxos, utilizou-se um recurso do Node-RED que permite a visualização e compreensão do que está ocorrendo no sistema (Figura 7). No *uplink* foram inseridas informações que incluem os estados das válvulas, a tensão da bateria, a vazão de água e o tempo de última atualização dos dados. Analogamente, o *downlink* também é representado no *dashboard*, entretanto a sua interação na interface acontece de forma ativa, isto é, envia informações para o *End-node*.



Figura 7 - *Dashboard* do sensor DET-37, composto pelo *uplink* e *downlink*

A quarta etapa consiste na coleta dos dados relativos à umidade e exibição destes em *dashboards*. Para análise da umidade do solo, foram definidos nove pontos de medição com diferentes profundidades (10cm, 30cm e 70 cm) e posições em espaços de 6,2m x 6,2m, como podemos ver em Boyadjian, 2019.

Na Figura 8, tem-se um dos nove gráficos de obtenção dos dados captados pelos sensores de umidade. Estes dados são transferidos do Node-Red para a plataforma do Thingspeak, para que possam assim ser analisados de forma simples e visual. Nota-se que há variação dos dados devido às interferências climáticas durante as coletas, especialmente devido à chuva.

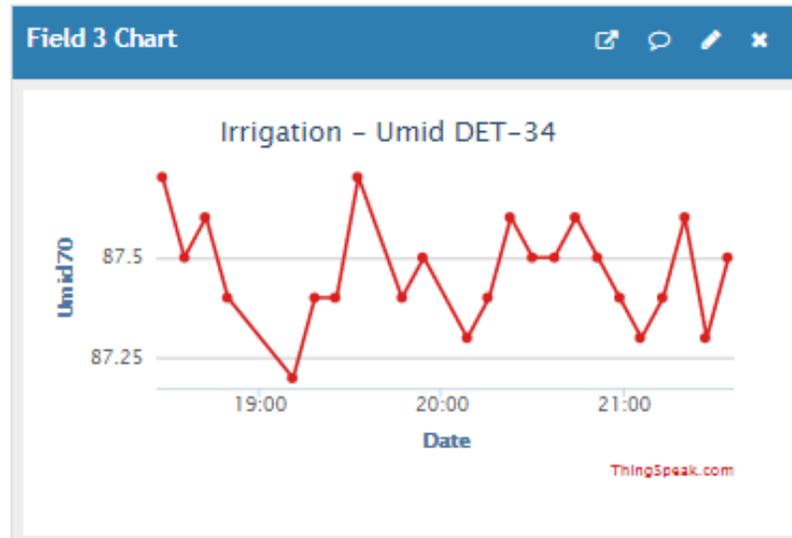


Figura 8 - Gráfico do nível de umidade à altura de 70 cm de profundidade, sensor DET-34

Uma vez que estes dados são enviados para o Thingspeak, pode-se exportá-los em formato JSON, XML ou CSV. No caso, a Figura 9 mostra como ficaria a obtenção dos dados em uma das alturas de um dos sensores de umidade no formato CSV, exibidos através de uma planilha de Excel gerada automaticamente através do *download* dos mesmos.

	A	B	C	D
1	created_at,entry_id,field1,field2,field3			
2	2021-10-28 14:44:14 UTC	634		
3	2021-10-28 14:50:50 UTC	635		
4	2021-10-28 14:57:25 UTC	636		
5	2021-10-28 15:04:01 UTC	637		
6	2021-10-28 15:10:37 UTC	638		
7	2021-10-28 15:17:12 UTC	639		
8	2021-10-28 15:30:24 UTC	640		
9	2021-10-28 15:36:59 UTC	641		
10	2021-10-28 15:43:35 UTC	642		

Figura 9 - Planilha em Excel contendo dados captados em formato CSV

Após a aquisição de dados, a quinta e última etapa consistiria no desenvolvimento da rede neural, a partir da criação de um modelo matemático que representasse a relação entre a entrada e saída do sistema. Isto é possível simplesmente a partir da obtenção de um conjunto de dados de condições do sistema. Sendo definido um ponto ótimo de umidade do solo a partir de diversas coletas de dados, pode-se prever as condições de saída de uma rede neural para o atingimento desse valor ideal. Este processo está demonstrado na figura 10 abaixo.

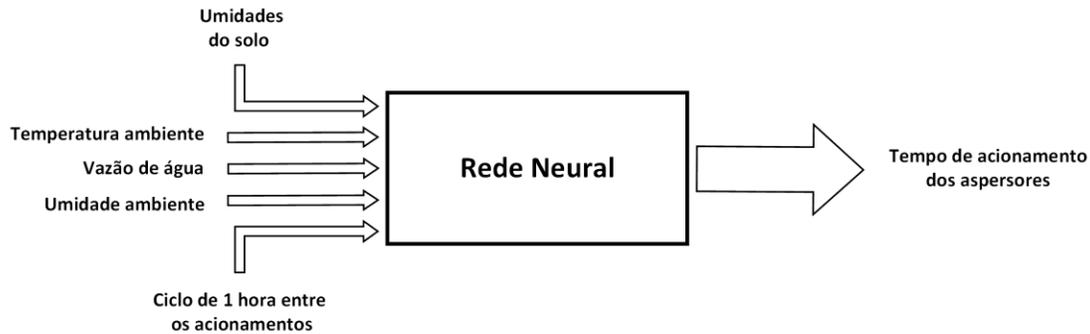


Figura 10 – Diagrama de Blocos para o Modelo da Rede Neural

O funcionamento da rede neural, que não pôde ser trabalhado ainda, consistiria em operações aritméticas, nas quais visa-se atingir o valor da umidade do solo desejada a partir do tempo de acionamento dos três atuadores. Esse processo se fundamentaria na soma ponderada de um total de doze entradas (sensores de temperatura ambiente, umidade do ar e vazão, além de nove detectores de umidade do solo), cujos pesos podem ser definidos por um *software*, como o MATLAB por exemplo, através de cálculos iterativos e algoritmos de otimização.

Resultados e Discussão

A programação em blocos no Node-Red, a visualização dos dados no ThingSpeak, o download em formato CSV e o envio destes para o *dashboard* do Smart Campus Mauá funcionam de acordo com todas as expectativas.

Em relação à rede neural, esta não foi trabalhada devido a atrasos no cronograma gerados pelo surto de COVID-19 e por condições climáticas desfavoráveis ao plantio. A implementação de algoritmos de aprendizagem no sistema agregaria um diferencial significativo na solução trabalhada, graças à autonomia que teríamos com o acionamento não só autônomo das válvulas, mas que pudesse ser otimizado a partir da análise da umidade do sistema feita pela rede neural.

Conclusão

O desenvolvimento da rede neural foi impossibilitado, devido especialmente ao atraso da atuação presencial na horta decorrente do distanciamento social ocasionado pelo surto de COVID-19 e dos danos causados aos sensores de umidade pelas fortes chuvas do segundo semestre.

Todavia, obtivemos sucesso na coleta, envio e visualização dos dados de umidade e controle das válvulas dos aspersores na plataforma do Thingspeak e no *Smart Campus* da Mauá. Isto mostra que os algoritmos e tecnologias implementados possuem um imenso potencial de replicação, o que de fato atende nossas expectativas no que diz respeito à viabilidade da solução, facilidade de monitoramento e implementação do sistema e, especialmente, que o sistema está apto a receber a implementação de uma rede neural artificial para sua automatização.

Em projetos futuros seria imprescindível o desenvolvimento da rede neural para que se possa trabalhar em uma solução autônoma para a aplicação, o que aumentaria significativamente o valor de mercado da solução desenvolvida.

Referências Bibliográficas

Boyadjian, B. P.; Assis, W. O.; Coelho, A. D.; Martins, F. A.; Peres, R. C.; “**Sistema inteligente para gestão de recursos hídricos na agricultura de precisão utilizando rede neural artificial**”, 11º Seminário Mauá de Iniciação Científica, 2019. Acesso em: 26 nov. 2021.

Coraccini, R., **Como o mundo vai alimentar 10 bilhões? (2050)**, 2020. Disponível em:<<https://www.consumidormoderno.com.br/2019/04/17/como-mundo-vai-alimentar-10-bilhoes-2050/>>. Acesso em: 26 nov. 2021.

Farooq, M. S.; Riaz, S.; Abid, A.; Abid, K.; Naeem, M. **A Survey on the Role of IoT in Agriculture for the Implementation of Smart Farming**, 2019. IEEE Xplore. Disponível em: <<https://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=8883163>>. Acesso em: 26 nov. 2021.

Kuke, A. S.; Vettorazzo, L.G.; Assis, W. O.; Coelho, A. D.; Martins, F. A.; Peres, R. C.; “**Controle de sistema de irrigação automático utilizando internet das coisas e conceitos de redes neurais artificiais**” 11º Seminário Mauá de Iniciação Científica, 2019. Acesso em: 26 nov. 2021.

Smart Campus Mauá, **Exemplo de aplicação MQTT Broker (Node-RED)**, 2020. Disponível em: <https://smartcampus.maua.br/?page_id=252>. Acesso em: 04 nov. 2021.

WIRED, **Machine Learning - living in the age of AI**, 2019. Disponível em:<<https://www.youtube.com/watch?v=ZJixNvx9BAc>>. Acesso em: 17 ago. 2021.