

Rede de Sensores Sem Fio e Aprendizado de Máquina para Monitoramento da Qualidade de Ambientes de Estudo

Victor Guimarães Furtado*. Yan Ferreira da Silva.**
João Viana da Fonseca Neto***

**Pós-Graduação em Engenharia Elétrica, Universidade Federal do Maranhão, MA, (e-mail: victor.gf@discente.ufma.br)*

***(e-mail: yan@nca.ufma.br)*

*** *(e-mail: joao.fonseca@ufma.br)*

Abstract: Thermal comfort, luminosity, and air quality are factors that directly impact the health, well-being, and cognitive performance of occupants in an indoor environment. It is crucial that ergonomic parameters such as temperature, humidity, light levels, and carbon dioxide concentration in these spaces adhere to criteria established by Brazilian standards. Addressing this issue, this study presents a methodology for developing a Wireless Sensor Network (WSN) with the objective of intelligently monitoring and classifying the environmental quality of study spaces. The WSN nodes comprise signal acquisition sensors, a microcontroller for processing, classification, and communication, and a multiplexer serving as an analog input expander for the microcontroller. The software components encompass signal processing, communication, and classification algorithms leveraging machine learning techniques. To enable remote monitoring, the collected signals and classifications are transmitted and stored in a cloud infrastructure utilizing Internet of Things (IoT) and cloud computing techniques.

Resumo: O Conforto térmico, luminosidade e qualidade do ar são elementos que impactam diretamente a saúde, bem-estar e desempenho cognitivo dos ocupantes em um ambiente interno. É essencial que parâmetros ergonômicos, como temperatura, umidade, níveis de iluminação e concentração de dióxido de carbono nesses espaços, estejam de acordo com os critérios estabelecidos pelas normas brasileiras. Abordando essa questão, este estudo apresenta uma metodologia para o desenvolvimento de uma Rede de Sensores sem Fio (RSSF-WSN, na sigla em inglês) com o objetivo de monitorar e classificar de forma inteligente a qualidade ambiental de espaços de estudo. Os nós da WSN consistem em sensores de captação de sinais, um microcontrolador para processamento, classificação e comunicação, e um multiplexador como expensor de entrada analógica para o microcontrolador. Os componentes de software abrangem algoritmos de processamento de sinais, comunicação e classificação que utilizam técnicas de aprendizado de máquina. Para permitir o monitoramento remoto, os sinais coletados e as classificações são transmitidos e armazenados em uma infraestrutura de nuvem utilizando técnicas de Internet das Coisas (IoT) e computação em nuvem.

Keywords: WSN; Machine Learning; Sensors; IoT; Environmental quality.

Palavras-chaves: RSSF; Aprendizado de Máquina; Sensores; IoT; Qualidade do ambiente.

1. INTRODUÇÃO

O monitoramento de parâmetros de ambientes internos se tornou uma grande preocupação, pois a qualidade desses locais está diretamente ligada à saúde e qualidade de vida dos ocupantes (YE, 2009). O tempo elevado que as pessoas passam em ambientes como salas de aula, auditórios, escritórios, consultórios e laboratórios, torna a qualidade desses ambientes uma preocupação ainda maior (GONZALEZ, 2020). O conforto térmico, qualidade do ar, ruídos sonoros e visuais são fatores ambientais que têm efeitos diretos sobre a permanência dos ocupantes e o desempenho no trabalho (HUANG, 2012).

É fundamental que órgãos regulamentadores estabeleçam critérios para obtenção de um ambiente interno saudável. Normas brasileiras da ANVISA, ABNT e MTPS determinam níveis aceitáveis de parâmetros em ambientes internos de trabalho (MENDONÇA, 2019). Essas normas estabelecem

níveis para grandezas como temperatura, umidade, luz, dióxido de carbono, entre outras.

O avanço e a popularização da automação residencial e predial proporcionou a expansão da implantação de sistemas inteligentes com o intuito de oferecer conforto às residências particulares ou edifícios comerciais, através da combinação de elementos de controle, monitoramento e comunicação com ou sem fio. As tecnologias de monitoramento são essenciais nesse tipo de aplicação (TARIQ, 2012).

Dentre os principais sistemas de monitoramento, destacam-se as *Wireless Sensor Networks* (WSN). Essas redes são compostas por nós de sensores que monitoram fenômenos de interesse, são caracterizadas como *ad-hoc* (não necessitam de configuração prévia) e transmitem os sinais coletados à estação central de processamento, chamada de estação base ou *gateway*. Como o nome indica, estas redes utilizam canais de comunicação sem fio, que permite maior flexibilidade para a

alocação dos nós. A pesquisa em WSN foi inicialmente motivada por aplicações militares e ainda possui larga aplicação nessa área, porém o desenvolvimento dessa tecnologia proporcionou e expandiu seu uso em diversas áreas como saúde, monitoramento ambiental, entre outros (SELMIC, 2016).

Sabendo a importância de ambientes internos confortáveis e a capacidade de monitoramento das WSN, este trabalho tem como objetivo o projeto, desenvolvimento e implantação de uma WSN e um classificador inteligente baseado em aprendizado de máquina para o monitoramento remoto de temperatura, umidade, concentração de dióxido de carbono (CO₂) e luminosidade. O ambiente escolhido para os testes é o Laboratório de Controle de Processos (LCP) da Universidade Federal do Maranhão (UFMA), além de uma proposta de método inteligente de classificação inteligente para qualidade de ambientes. A WSN envia os sinais para uma nuvem chamada *ThingSpeak*® via técnicas de *Internet of Things* (IoT) e os sinais/dados coletados são usados para classificar o ambiente segundo as normas brasileiras.

O artigo é organizado em Seções, na Seção 2 tem-se a descrição de conceitos, da metodologia desenvolvida e etapas necessárias para o desenvolvimento do trabalho. Na Seção 3 tem-se descrições de *hardware* e *software* utilizados para implementação do sistema. As conclusões do trabalho são apresentadas na Seção 4.

2. PROJETO DA WSN

O desenvolvimento da WSN inteligente requer inicialmente uma análise do ambiente de implementação: o LCP.



Fig. 1 Diagrama de blocos das etapas do sistema.

Tendo conhecimento das atividades desenvolvidas, rotina dos ocupantes e das características físicas do local é proposto um sistema de monitoramento online baseado em WSN e classificação da qualidade do ambiente, com critérios de temperatura, umidade, luminosidade e taxa de concentração de gás carbônico adotados segundo normas brasileiras para ambientes internos. A Figura 1 apresenta o diagrama de bloco com as etapas funcionais do sistema.

Na análise das características do LCP é verificado que a área é dividida fisicamente em três regiões, com objetivo metodológico, as zonas foram chamadas de s1, s2 e s3 como a Figura 2 apresenta.



Fig. 2 Divisão do laboratório em zonas. (MENDONÇA, 2019)).

As regiões s1, s2, e s3 possuem, respectivamente, áreas de 30,8m², 10,9m² e 7,2m² totalizando uma área aproximada de 49m² para o LCP.

2.1 Arquitetura do sistema embarcado do nó de sensor

O nó de sensor desenvolvido possui o DHT11 da AOSONG® como sensor de temperatura e umidade, um LDR (*Light Dependent Resistor*) de 5mm para luminosidade e o MQ-135 da HANWEI para dióxido de carbono. O microcontrolador utilizado é o ESP8266 presente na plataforma de desenvolvimento de código aberto ESP8266 NodeMCU ESP-12 da *Espressif Systems*. A NodeMCU possui capacidade computacional e compatibilidade para uso dos sensores, baixo custo, baixo consumo energético e suporte de comunicação que engloba rádio transceptor e antena para comunicação via protocolo IEEE 802.11 b/g/n (*Wi-Fi*).

2.2 Gateway

A função de *gateway* da WSN é desempenhada por um microcontrolador de mesmo tipo dos utilizados nos nós de sensores, por conta do seu suporte *Wi-Fi* e compatibilidade para comunicação com os nós e envio de dados para a *Internet*. A configuração deste dispositivo como *Access Point Station* permite que ele funcione como um cliente de uma rede e ao mesmo tempo como um ponto de acesso, configuração necessária para que ele funcione como *gateway* da WSN.

2.3 Cobertura do nó de sensor

A cobertura de sensoriamento ou alcance de detecção do nó proposto do projeto é definida com o método do disco binário, que compara o alcance radial de todos os sensores do nó e adota o menor como alcance de detecção do nó.




Fig. 3 Cobertura do nó de sensor.

O DHT11 é o sensor que tem o menor alcance radial quando capta umidade, sendo assim é adotado como cobertura do nó de sensor: 1,4m de raio da circunferência.

2.4 Definição da quantidade de nós

Adotando os critérios; maior área de sensoriamento, menor área de intersecção entre as coberturas dos nós, menor área de buracos de cobertura e menor quantidade de nós. A definição da quantidade de nós é feita dividindo a área a ser instrumentalizada pela área de cobertura do nó de sensor como apresentado em (1):

$$\frac{49m^2}{\pi \times (1,4m)^2} = 7,95 \text{ nós} \quad (1)$$

O cálculo resulta em um valor não inteiro, então é realizado uma aproximação para 8. Uma aproximação para baixo causaria uma área considerável de buracos de cobertura.

2.5 Distribuição Espacial

No modelo proposto, as características de rádio e comunicação do microcontrolador utilizado, em termos de alcance, superam a cobertura do nó e as dimensões físicas do ambiente, portanto, independente da quantidade de nós e sua distribuição, a comunicação nó-gateway e gateway-ponto de acesso (roteador) não é um empecilho para a implementação da WSN.

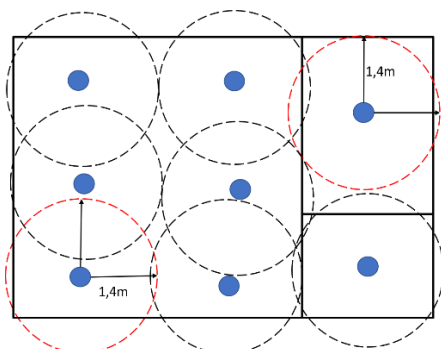


Fig. 4 Representação da distribuição espacial da WSN.

O problema da distribuição espacial da rede proposta, é limitada à cobertura de detecção. Respeitando os critérios estabelecidos, as subdivisões físicas do ambiente e o modelo do disco binário, os nós são distribuídos de forma a compreenderem as zonas de trabalho, regiões em que os ocupantes/pesquisadores do LCP mais permanecem e realizam suas atividades. Desta forma, 6 nós são alocados na zona s1, e as outras duas zonas recebem 1 nó cada, de forma centralizada, como a Figura 4 apresenta.

2.6 Topologia da WSN

As dimensões físicas do ambiente monitorado e o alcance de comunicação entre nós de sensores e gateway, tornam a escolha da topologia independente da distribuição espacial, desta forma, a topologia estrela é a mais adequada para o objetivo proposto, pois apresenta o menor consumo dentre as topologias. Na Figura 5 pode ser visto uma representação da rede quanto a topologia.




Fig. 5 Representação da Arquitetura de comunicação da WSN: (1) nós de sensores; (2) gateway.

A Figura 5 também apresenta uma representação do fluxo de sinais entre nós e gateway, que consiste na etapa de comunicação interna da rede.

2.7 Etapas de comunicação da WSN

A comunicação é dividida em etapa interna e externa. A etapa de interna é a comunicação entre nós e o gateway, já a etapa externa é o envio dos sinais, pelo gateway, para serem armazenados em uma nuvem, onde podem ser acessados e monitorados de forma remota.




Fig. 6 Etapas de comunicação interna e externa da WSN: (1) nós de sensores; (2) gateway e seu alcance de comunicação; (3) nuvem de armazenamento de dados; (4) dispositivo para monitoramento.

O microcontrolador usado como gateway é configurado como estação e ponto de acesso ao mesmo tempo. Ele gera uma rede wireless e se conecta à Internet pela rede Wi-Fi do roteador presente no LCP. O microcontrolador dos nós de sensores é configurado como estação e conectado como cliente da rede sem fio gerada pelo gateway.

2.8 Protocolo de comunicação

As duas etapas de comunicação utilizam o protocolo TCP/IP com algumas diferenças. A primeira etapa tem como camada de enlace o protocolo IEEE802.11b (Wi-Fi), camada de rede o protocolo IPv4 e camada de transporte o protocolo UDP. O envio de dados através do protocolo UDP garante uma baixa latência para o envio de dados. A segunda etapa diverge da anterior, pois tem como camada de transporte o protocolo TCP e como camada de aplicação o protocolo MQTT.

O protocolo MQTT (*Message Queue Telemetry Transport*) é um protocolo de comunicação entre máquinas (*Machine to Machine – M2M*) baseado no protocolo TCP/IP, com modelo

publish/subscribe e muito utilizado em IoT. O MQTT possui armazenamento em *Broker* (Nuvem) que possibilita o monitoramento *online* e evita perda de dados quando houver perda de conexão ou algum outro tipo de falha. Para esta aplicação, os sinais coletados e pré-processados nos nós de sensores são transformados em dados e enviados para o *gateway*, onde são convertidos em JSON (*JavaScript Object Notation*) e enviados para um *Broker*, uma plataforma IoT, para serem armazenados e monitorados através da *Internet*.

2.9 Normas Brasileiras de Qualidade Ambiental

A NR17-Ergonomia estabelece que locais de trabalho em ambientes internos onde são executadas atividades que necessitam de solicitação intelectual e concentração constante, devem ter a temperatura efetiva entre 18°C e 25°C (MTPS, 2021). A Resolução 09 de 2003 da ANVISA estabelece que em ambientes climatizados artificialmente de uso público e coletivo, o valor máximo recomendado para não haver contaminação química é de 1000 ppm de dióxido de Carbono (CO₂), esse valor é um indicador de renovação do ar externo. Essa resolução também estabelece como faixa de operação da umidade relativa entre 40% e 65% (ANVISA, 2003). A NBR ISSO/CIE 8995-1:2013 determina que o critério de nível mínimo de iluminação de ambientes internos de trabalho do tipo construções educacionais – salas de aplicação e laboratórios deve ser 500 lux (ABNT, 2013). A NBR 5413:1992 estabelece que o limite máximo de iluminação de ambientes internos de trabalho que possuem atividades com requisitos visuais normais, trabalho médio de maquinaria ou escritórios é 1000 lux.

2.10 Classificador Inteligente

A primeira etapa do classificador inteligente é desenvolvida no sistema embarcado do nó de sensor e utiliza o princípio da árvore de decisão. Um algoritmo baseado em árvore de decisão é um modelo de aprendizado de máquina que representa decisões e suas possíveis consequências em uma estrutura em forma de árvore (BISHOP, 2006). Cada nó interno da árvore representa um teste em um atributo, enquanto os nós-folha representam as classes ou os resultados previstos. O objetivo é dividir os dados em subconjuntos cada vez mais homogêneos, tomando decisões com base nas características dos sinais (RUSSEL, 2010). Tendo em vista a estrutura de uma árvore de decisão, como critérios dos parâmetros, os valores estabelecidos (SUGIARTO, 2016) nas normas brasileiras de qualidade ambiental, apresentadas no tópico anterior. Tem como objetivo analisar se a região coberta pelo nó está dentro dos critérios no instante da coleta. A Figura 7 apresenta a estrutura do algoritmo inteligente baseado em árvore de decisão que representa esta etapa.

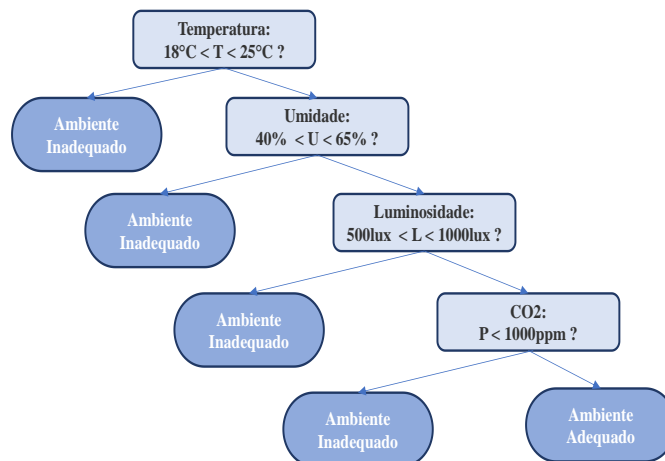


Fig. 7 Estrutura algoritmo de aprendizado de máquina (árvore de decisão) da primeira etapa do classificador.

O classificador inteligente verifica, respectivamente, se a temperatura, umidade, luminosidade e concentração de dióxido de carbono estão dentro dos critérios estabelecidos. O ambiente é classificado como inadequado se pelo menos uma das grandezas está fora dos critérios estabelecidos.

A estrutura do algoritmo baseado em aprendizado de máquina proposto, possui uma variável correspondente a cada parâmetro. Se o parâmetro está dentro dos critérios, sua variável recebe '1', se não estiver recebe '0'. Ao final da coleta é feita uma média entre as variáveis como apresentado em (2).

$$Cl = \frac{A + B + C + D}{4} \quad (2)$$

Cl é o valor do classificador, A é a variável correspondente à temperatura, B a umidade, C a luminosidade e D a dióxido de carbono. Os valores calculados em cada nó de sensor são enviados para a nuvem para serem monitorados e armazenados. A segunda etapa do classificador inteligente consiste em uma média global de todos os nós independente da região, neste caso, os nós possuem peso igual, calculada no MATLAB®, dos valores da primeira etapa do classificador por faixa de horário, o dia é dividido em 5 faixas de 4 horas. A faixa aceitável para trabalho no ambiente é entre 0,8 e 1, apesar do ambiente ser considerado inadequado quando pelo menos uma das variáveis está fora da faixa, na média final é considerado 20% de tolerância.

3. RESULTADOS EXPERIMENTAIS

3.1 Implementação dos nós de sensores

A Figura 8 A) apresenta a estrutura do nó, desenvolvido no software CAD Fritzing®. O microcontrolador utilizado apresenta um empecilho no desenvolvimento do circuito pois possui apenas uma GPIO que funciona como entrada analógica, e o LDR e o MQ-135 fornecem sinal analógico. O problema foi solucionado com um multiplexador 4052, sua função é expandir momentaneamente a quantidade de entradas analógicas do microcontrolador para 2 entradas. Utilizando dois canais de saída, o multiplexador comuta entre os dois canais, interligando o pino analógico da NodeMCU de modo alternado a esses dois sensores em intervalos de 1 segundo.




Fig. 8 A) Projeto do sistema embarcado do nó de sensor no Fritzing, B) Sistema físico embarcado.

A Figura 8 B) apresenta a prototipagem do nó de sensor seguindo o modelo apresentado na Figura 8 A). A calibração dos sensores é feita através do método de aferição utilizando equipamentos de medição específicos. O mesmo modelo de montagem foi adotado para os demais nós, como apresenta a Figura 9.




Fig. 9 Oito nós de sensores da WSN montados.

Os nós de sensores exibidos na Figura 9 estão em ordem crescente da direita para a esquerda. Os nós 1 e 2 foram montados utilizando uma NodeMCU V2 enquanto os demais a NodeMCU LolinV3, os nós 4 e 5 foram montados utilizando uma *shield* de expansão para a NodeMCU V3, para aplicações deste trabalho nenhuma dessas divergências apresentam implicações relevantes no circuito de montagem dos nós de sensores.

3.2 Armazenamento e monitoramento

A nuvem de armazenamento e monitoramento utilizada é o *ThingSpeak*®, uma plataforma analítica de IoT que permite agregar, visualizar, monitorar e analisar fluxos de dados em nuvem. Os dados armazenados também podem ser extraídos em formato de tabelas, por exemplo XML, formato interpretado por diversos *softwares* de análise de dados (SILVA, 2020).

3.3 Resultados dos testes em laboratório.

Após testes de funcionamento e comunicação individual e geral, os nós de sensores foram posicionados como apresentado na Figura 4 e a WSN foi habilitada para o pleno funcionamento. Para representar e analisar a coleta diária da

WSN, os gráficos apresentados são referentes a um dia completo, o dia 17 de novembro de 2022.




Fig. 10 Gráfico de temperatura da WSN

Analisando a Figura 10 é possível notar que a partir das 10:00 as temperaturas começam a cair por conta do início do funcionamento dos ar-condicionados, consequente da chegada de algum ocupante ao laboratório. Há estabilização a partir das 12:00 até as 18:00, com temperaturas entre 18°C e 23°C. Os nós 4, 5 e 6 foram os que apresentaram menor temperatura, pois estão posicionados relativamente em frente ao ar-condicionado da região s1. A partir das 18:00 é possível observar que houve uma elevação gradual da temperatura até uma estabilização, essa elevação ocorreu devido ao desligamento dos ar-condicionados, marcando o encerramento das atividades daquele dia. Durante a maior parte do tempo que houve ocupantes, a temperatura do laboratório, independente da região, esteve dentro dos critérios estabelecidos para obtenção de conforto térmico.

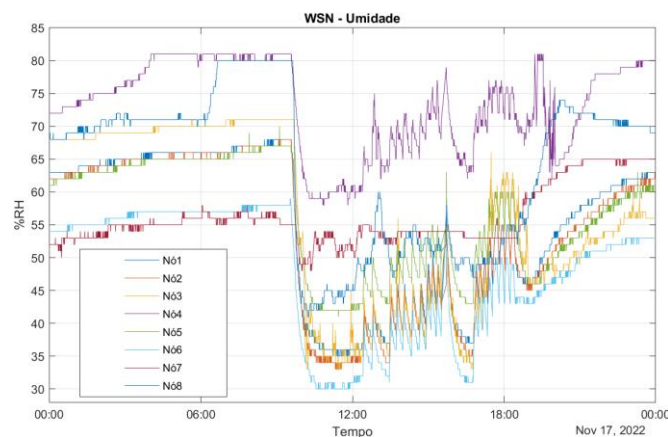


Fig. 11 Gráfico de umidade da WSN

A Figura 11 apresenta o gráfico de umidade da WSN, importante notar que até às 10:00 os valores de umidade do ambiente, possuem um comportamento em comum de subida e a partir da chegada do ocupante uma queda gradual, tendo sido causada pelo início do funcionamento dos ar-condicionados, que retiram a umidade do ar. Entre 10:00 até por volta das 18:00, somente os nós 7 e 8 estavam dentro do critério. Após às 18:00, devido ao desligamento dos ar-condicionados, houve uma crescente subida nos valores de

umidade, com exceção do nó 8 que apresentou uma oscilação para queda.

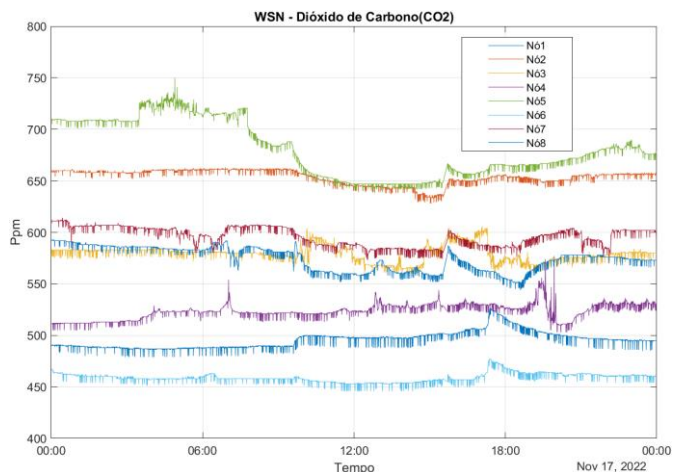


Fig. 12 Gráfico de concentração de dióxido de carbono da WSN.

Quanto à concentração de dióxido de carbono, analisando a Figura 12, é possível afirmar que durante todo o dia o laboratório esteve dentro do critério. Os valores medidos estão na faixa entre 450 e 750 ppm, e possuem um comportamento característico e estável, isso se deve provavelmente por: não haver atividades de soldagem, somente 3 ocupantes no laboratório e uma boa troca de ar com o ambiente externo.

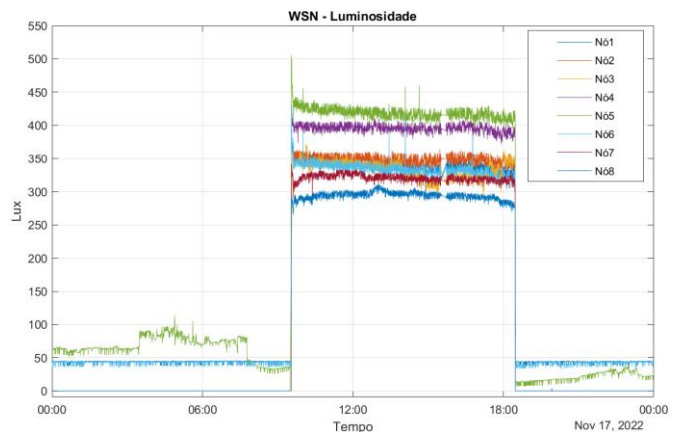


Fig. 13 Gráfico de luminosidade da WSN

Analisando o gráfico de luminosidade, apresentado na Figura 13, é possível notar que quando as luzes estavam desligadas a maioria dos nós apresentaram 0 lux, com exceção dos nós 1, 6 e 5 que tiveram valores superiores, isso se deu provavelmente por alguma pequena fonte de luz ou ruído do sensor. Por volta das 10:00, as luzes foram ligadas e é notável um pico e logo em seguida uma estabilização, esse é um comportamento característico do LDR. A partir das 10:00 até por volta das 18:30, há uma grande estabilidade da luminosidade, porém abaixo do critério. A análise indica que o laboratório não possui uma iluminação adequada. A Figura 14 apresenta os valores do classificador.

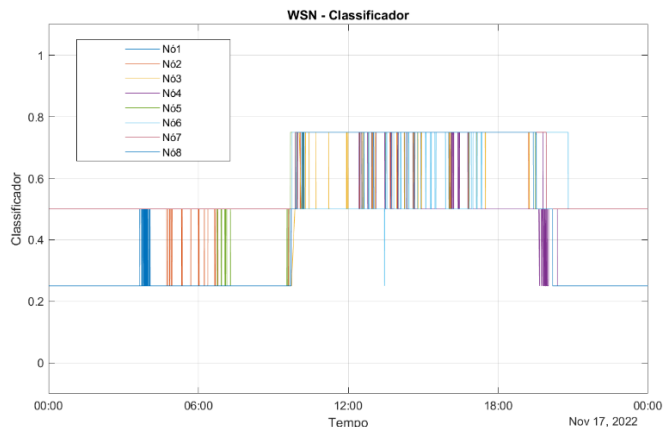


Fig. 14 Gráfico do classificador inteligente baseado em aprendizado de máquina da WSN.

O classificador inteligente não apresentou o valor máximo em nenhum dos nós de sensores, pois o critério de iluminação não foi cumprido em nenhum instante. O classificador também não obteve o valor 0, porque em nenhum momento o ambiente esteve fora do critério de dióxido de carbono. Quando havia ocupantes seu valor geralmente era de 0,75. Durante o período em que houve ocupantes, os valores dos classificadores variaram entre 0,75 e 0,5, chegando a 0,25 somente em um momento pelo nó de sensor 6. A tabela 1 apresenta os valores calculados da segunda etapa da classificação.

Tabela 1. Valores da média global do classificador

Intervalo do dia	Valor do Classificador
00:00 – 08:00	0,3782
08:00 – 12:00	0,4973
12:00 – 14:00	0,5534
14:00 – 18:00	0,6849
18:00 – 23:59	0,5172

Analisando a Tabela 1 é possível observar que o intervalo de tempo em que o laboratório possui mais variáveis dentro do critério é entre 14:00 e 18:00, porém nenhum chegou nem a 0,75. O primeiro e último intervalo, são horários em que não há ocupantes durante todo o intervalo no laboratório e no dia analisado, não havia ocupantes na maior parte do segundo intervalo.

4. CONCLUSÕES

Neste trabalho foi apresentado o desenvolvimento de uma WSN inteligente combinada com um algoritmo de aprendizado de máquina capaz de monitorar e classificar a qualidade de ambientes internos, além do envio e armazenamento dos dados em nuvem. A eficiência da WSN foi testada em diversas situações e apresentou resultados satisfatórios para os objetivos propostos. O uso do *ThingSpeak®* para aplicação foi satisfatório para as aplicações e seu tempo de resposta e o mesmo funciona como supervisor, isso permitiu a observação das variáveis de forma *online*. O modelo da WSN inteligente foi desenvolvido para um laboratório de pesquisa, porém pode ser aplicado a outros tipos de ambientes internos como hospitais, salas de aula e auditórios com suas devidas adequações.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) e Conselho Nacional de Desenvolvimento Científico e Tecnológico – Brasil (CNPq).

REFERÊNCIAS

- ABNT - Associação Brasileira de Normas Técnicas. (1992). *NBR 5413: Iluminância de interiores*. 13 p. Rio de Janeiro.
- ABNT - Associação Brasileira de Normas Técnicas. (2013). *NBR ISO/CIE 8995-1:2013: Iluminação de ambientes de trabalho parte 1: interior*. 46 p. Rio de Janeiro.
- ANVISA – Agência Nacional de Vigilância Sanitária. (2003). *RE 09: Resolução, de 16 de janeiro de 2003*. 14 p. Brasil.
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. New York: Springer.
- Gonzalez, O. B., Chilo, J. (2020). WSN IoT ambient environmental monitoring system. In *2020 IEEE 5th International Symposium on Smart and Wireless Systems within the Conferences on Intelligent data Acquisition and Advanced Computing Systems (IDAACS-SWS)*, 1-4. IEEE.
- Huang, L., et al. (2012). A study on the effects of thermal, luminous, and acoustic environments on indoor environmental comfort in offices. *Building and environment*, 49, 304-309.
- Mendonça, G. G. (2019). Monitoramento da qualidade do conforto de ambientes baseado em Lógica Fuzzy e redes de sensores.
- MTPS – Ministério do Trabalho e Previdência Social. (2021). *NR 17: Ergonomia*. 14 p. Brasília.
- Russel, S. J., Norvig, P. (2010). *Artificial Intelligence: A Modern Approach*. Third Edition. Pearson Education.
- Selmic, R. R., Phoha, V. V., Serwadda, A. (2016). *Wireless Sensor Networks*. New York, NY, USA: Springer International Publishing AG.
- Silva, Y. F. (2020). Sensor inteligente para radiação solar baseado em mini células fotovoltaicas e aprendizado de máquina.
- Sugiarto, B., Sustika, R. (2016). Data classification for air quality on wireless sensor network monitoring system using decision tree algorithm. In *2016 2nd International Conference on Science and Technology-Computer (ICST)*.
- Tariq, M., et al. (2012) Smart grid standards for home and building automation. In *2012 IEEE International Conference on Power System Technology (POWERCON)*, 1-6. IEEE.
- Ye, D., Gong, D., Wang, W. (2009). Application of wireless sensor networks in environmental monitoring. In *2009 2nd international conference on power electronics and intelligent transportation system (PEITS)*, 1, 205-208. IEEE.