



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO TECNOLÓGICO
DEPARTAMENTO DE ENGENHARIA CIVIL
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL

THAYANE LODETE BILÉSIMO

**Metodologia para seleção de algoritmo de aprendizagem de máquina para estudos de
controle centrado no usuário de edificações**

FLORIANÓPOLIS

2024

Thayane Lodete Bilésimo

Metodologia para seleção de algoritmo de aprendizagem de máquina para estudos de controle centrado no usuário de edificações

Tese submetida ao Programa de Pós-Graduação em Engenharia Civil da Universidade Federal de Santa Catarina como requisito para obtenção do título de Doutora em Engenharia.

Orientador: Prof. Enedir Ghisi, PhD.

FLORIANÓPOLIS

2024

Bilésimo, Thayane Lodete

Metodologia para seleção de algoritmo de aprendizagem de máquina para estudos de controle centrado no usuário de edificações / Thayane Lodete Bilésimo ; orientador, EneDir Ghisi, 2024.

137 p.

Tese (doutorado) - Universidade Federal de Santa Catarina, Centro Tecnológico, Programa de Pós-Graduação em Engenharia Civil, Florianópolis, 2024.

Inclui referências.

1. Engenharia Civil. 2. Eficiência energética em edificações. 3. Controle centrado no usuário. 4. Inferência de conforto. 5. Conforto visual. I. Ghisi, EneDir. II. Universidade Federal de Santa Catarina. Programa de Pós-Graduação em Engenharia Civil. III. Título.

Thayane Lodete Bilésimo

Metodologia para seleção de algoritmo de aprendizagem de máquina para estudos de controle centrado no usuário de edificações

O presente trabalho em nível de doutorado foi avaliado e aprovado por banca examinadora composta pelos seguintes membros:

Prof. Aldomar Pedrini, PhD.

Universidade Federal do Rio Grande do Norte

Prof. Arthur Santos Silva, Dr.

Universidade Federal do Mato Grosso do Sul

Prof. Devis Luis Marinoski, Dr.

Universidade Federal de Santa Catarina

Certificamos que esta é a **versão original e final** do trabalho de conclusão que foi julgado adequado para obtenção do título de doutora em Engenharia Civil no Programa de Pós-Graduação em Engenharia Civil da Universidade Federal de Santa Catarina.

Prof^ª Fernanda Fernandes Marchiori, Dr^ª
Coordenadora do Programa de Pós-
Graduação

Prof. Enedir Ghisi, PhD.
Orientador

Agradecimentos

Depois de escrever a tese, pensei que agradecer aos que fizeram parte deste processo seria uma tarefa mais simples. Após cinco anos, há muito que agradecer a cada um que esteve comigo no caminho para chegar até aqui, mas serei breve:

A Deus por, em seu infinito amor, providenciar todo o necessário para que eu pudesse concluir este trabalho.

Ao Professor Enedir, pela oportunidade e orientação, pelas correções valiosas, pela paciência e incentivo.

À banca examinadora, pelas contribuições no intuito de melhorar a qualidade desta pesquisa.

Ao meu esposo, Luiz, pelo apoio incondicional, por ser meu suporte e me fazer rir nos dias mais difíceis.

Aos meus familiares, por todo o incentivo e pela compreensão nos momentos de ausência.

A todos aqueles que foram presença e auxílio, pela motivação e pelos puxões de orelha quando eu pensava em desistir.

Aos colegas do LabEEE, pela convivência e discussão de ideias, que certamente me ajudaram a definir o rumo desta pesquisa.

Aos professores do Departamento de Energia e Sustentabilidade da UFSC Araranguá, por acolherem a proposta desta pesquisa e contribuírem para que ela acontecesse.

Ao pessoal da Quantum Team, pela disponibilidade e por aceitarem participar deste estudo.

Ao Programa de Pós-Graduação em Engenharia Civil e a todos os profissionais que contribuíram de alguma forma com a conclusão desta etapa.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

RESUMO

O atual cenário do setor de edificações requer novas estratégias de eficiência energética, que sejam capazes de identificar e proporcionar aos usuários um ambiente confortável segundo sua percepção. A aprendizagem de máquina – método de análise de dados capaz de identificar padrões e realizar inferências é uma alternativa para identificação das preferências dos usuários e controle dos sistemas das edificações, especialmente os de climatização e iluminação. A aprendizagem supervisionada é a abordagem mais usada, pois permite classificar condições ambientais em termos de conforto. No entanto, é importante identificar o algoritmo capaz de realizar inferências mais assertivas e de se adaptar às variações de preferências dos usuários das edificações ao longo do tempo. Neste sentido, o objetivo deste trabalho é propor um método para comparar o desempenho de diferentes algoritmos de aprendizagem supervisionada. O método deve permitir a identificação do algoritmo mais adequado para ser usado em estudos de sistemas de controle centrados no usuário. Para avaliar o desempenho dos algoritmos em cenários realistas, dados de ocupação, iluminância, temperatura, estado das aberturas e do sistema de iluminação artificial foram coletados durante oito meses, entre junho de 2022 e fevereiro de 2023, em um laboratório da Universidade Federal de Santa Catarina. Os dados foram pré-processados e agrupados em subconjuntos de 1, 7, 15 e 30 dias. Cada subconjunto foi utilizado no treinamento e teste dos algoritmos *Decision Tree*, *k-Nearest Neighbors*, *Multilayer Perceptron*, *Random Forest* e *Support Vector Machine*, visando prever o estado do sistema de iluminação. Os resultados foram comparados estatisticamente e os algoritmos foram avaliados a partir do cálculo da acurácia, precisão e sensibilidade. Inicialmente, identificou-se o subconjunto ideal (em quantidade de dias) para o funcionamento adequado de cada algoritmo. Em seguida, os algoritmos foram comparados. A melhor configuração (algoritmo e quantidade de dias) foi submetida a um processo de otimização. Posteriormente, simulou-se a atualização diária do conjunto de dados, a fim de avaliar o desempenho da configuração otimizada em um cenário realístico. Para o cenário estudado, o melhor resultado foi obtido utilizando o *k-Nearest Neighbors* e subconjuntos de 7 dias para treino. O algoritmo foi capaz de se adaptar às variações observadas após cada atualização, mesmo com a substituição completa do conjunto inicial de dados. Ao final da análise, acurácia, precisão e sensibilidade foram de 98%, em média. Por fim, pode-se afirmar que o método proposto permitiu comparar e selecionar adequadamente o algoritmo e o subconjunto ideal de dias para prever o estado do sistema de iluminação artificial.

Palavras-chave: Aprendizagem de máquina, aprendizagem supervisionada, controle centrado no usuário, inferência de conforto, conforto visual.

ABSTRACT

The current building sector scenario demands new energy efficiency strategies. They need to be capable of identifying and assuring comfortable environments according to users' perceptions. Machine learning – a method of data analysis capable of identifying patterns and make predictions – is an alternative to identify users' preferences and control lighting and heating, ventilation and air-conditioning systems in buildings. Supervised learning is the most common approach because it allows classifying environmental conditions in terms of comfort. However, it is important to identify the algorithms' capacity of making right predictions and adapting to the change in the preferences of building users over time. This research aims to present a method to assess different supervised learning algorithms. The method must allow the identification of the most accurate algorithms to be used in studies of occupant centered control systems. In order to assess algorithms' performance in realistic scenarios, the following data were collected: occupancy, illuminance, temperature, and the current state of openings and artificial lighting system. Data were collected for eight months, between June 2022 and February 2023 in a research laboratory of Federal University of Santa Catarina. They were pre-processed and grouped in subsets within 1, 7, 15 and 30 days. Each subset was used in training and testing the following algorithms: Decision Tree, k-Nearest Neighbors, Multilayer Perceptron, Random Forest and Support Vector Machine, in order to predict the state of the lighting system. The results were statistically compared and the performance of the algorithms was assessed using each models' accuracy, precision and recall. First, the ideal subset to each algorithm (in number of days) was identified. In the next step, algorithms were compared. The best configuration (algorithm and number of days) was submitted to an optimization process. Then, the update of the subset was assessed, aiming to evaluate the optimized algorithm working in a realistic scenario. For this case study, the best results were achieved using the k-Nearest Neighbors and subsets within 7 days for training. The algorithm was able to adapt to changes in users' patterns and could reach a good performance even after total data substitution. At the end of the analysis, accuracy, precision and recall remained around 98%, in average. Finally, it is possible to affirm that the method proposed allowed to appropriately compare and select the algorithm and the ideal subset to predict the state of the artificial lighting system.

Keywords: Machine learning, supervised learning, occupant centred control, comfort inference, visual comfort.

LISTA DE FIGURAS

Figura 1. Relação entre os níveis de automação e a participação do usuário.....	22
Figura 2. Utilização da aprendizagem de máquina em edificações centradas no usuário.....	26
Figura 3. Esquema de funcionamento de uma DT.	27
Figura 4. Exemplificação do algoritmo KNN.	28
Figura 5. Exemplo de MLP com duas camadas ocultas.	28
Figura 6. Esquema geral de funcionamento do algoritmo RF.	29
Figura 7. Hiperplanos traçados pelo SVM para a classificação das amostras.....	30
Figura 8. Quantidade de publicações por ano.....	35
Figura 9. Proporção de inferências realizadas por aprendizagem de máquina.....	36
Figura 10. Duração dos estudos direcionados unicamente para a realização de inferências....	37
Figura 11. Proporção dos trabalhos que utilizam aprendizagem de máquina nos sistemas de climatização, iluminação e persianas.....	38
Figura 12. Duração dos estudos que abordam o controle dos sistemas de iluminação e/ou climatização.	39
Figura 13. Obtenção das preferências dos usuários em sistemas de iluminação.....	52
Figura 14. Obtenção das preferências dos usuários em sistemas de climatização.	53
Figura 15. Fluxograma geral do método.	63
Figura 16. Esquema de ligação dos equipamentos do sistema de aquisição de dados.....	66
Figura 17. Cartões RFID distribuídos aos usuários do local.	67
Figura 18. Sistema de aquisição de dados em funcionamento.	67
Figura 19. Planta baixa do ambiente com múltiplos ocupantes.	68
Figura 20. Escala Likert, utilizada para responder ao questionário.....	69
Figura 21. Organização dos dados em subconjuntos.....	72
Figura 22. Esquema da primeira etapa de testes.....	74
Figura 23. Seleção da quantidade de dias com melhor resultado para cada algoritmo.	76
Figura 24. Seleção do algoritmo com melhor resultado.....	77
Figura 25. Esquema do processo de otimização.....	78
Figura 26. Atualização dos dados de treinamento do algoritmo.	78
Figura 27. Frequência semanal dos ocupantes do laboratório.....	80
Figura 28. Respostas dos usuários sobre seu esforço em economizar energia.....	81
Figura 29. Respostas dos usuários sobre sacrificar seu conforto para economizar energia.	82
Figura 30. Iluminância média horária registrada pelos sensores posicionados em diferentes locais.....	83

Figura 31. Média horária da temperatura ambiente.....	84
Figura 32. Desempenho do algoritmo DT com os diferentes subconjuntos de dados.....	87
Figura 33. Desempenho do algoritmo KNN com os diferentes subconjuntos de dados.	90
Figura 34. Desempenho do algoritmo MLP com os diferentes subconjuntos de dados.....	93
Figura 35. Desempenho do algoritmo RF com os diferentes subconjuntos de dados.	95
Figura 36. Desempenho do algoritmo SVM com os diferentes subconjuntos de dados.	98
Figura 37. Desempenho do algoritmo SVMp com os diferentes subconjuntos de dados.	101
Figura 38. Resultado da atualização diária do conjunto de dados.....	107
Figura 39. Distribuição dos resultados dos testes simulando um cenário realista com atualização dos dados de treino.	107

LISTA DE QUADROS

Quadro 1. Classificação dos algoritmos segundo os tipos de aprendizagem.	40
Quadro 2. Equipamentos utilizados na montagem do sistema de aquisição de dados.	64
Quadro 3. Variáveis do arquivo de dados pré-processado.	71
Quadro 4. Avaliação dos algoritmos em seus respectivos contextos.	108

LISTA DE TABELAS

Tabela 1. Exemplo de conjunto de dados.	31
Tabela 2. Quantidade de publicações por periódico entre 2014 e 2023.	36
Tabela 3. Primeiros subconjuntos de 1 dia.	72
Tabela 4. Matriz de p-valores a ser construída a partir do teste de variância.	75
Tabela 5. Valores das variáveis ambientais.	82
Tabela 6. Distribuição das amostras conforme o estado dos sensores (0 - aberto, 1 - fechado).	85
Tabela 7. Quantidade de amostras de acordo com o estado dos interruptores 1 (I1) e 2 (I2). .	85
Tabela 8. Mediana e intervalo de confiança para as medidas de avaliação dos conjuntos de resultados da DT.	86
Tabela 9. Matriz de p-valores do teste de Mann-Whitney para comparação de medianas, para os resultados da DT.	88
Tabela 10. Avaliação dos testes da DT com todos os subconjuntos de dados.	88
Tabela 11. Mediana e intervalo de confiança para as medidas de avaliação dos conjuntos de resultados do KNN.	89
Tabela 12. Matriz de p-valores do teste de Mann-Whitney para comparação de medianas, para os resultados do KNN.	90
Tabela 13. Avaliação dos testes do KNN com todos os subconjuntos de dados.	91
Tabela 14. Mediana e intervalo de confiança para as medidas de avaliação dos conjuntos de resultados da MLP.	92
Tabela 15. Matriz de p-valores do teste de Mann-Whitney para comparação de medianas, para os resultados da MLP.	94
Tabela 16. Avaliação dos testes da MLP com todos os subconjuntos de dados.	94
Tabela 17. Mediana e intervalo de confiança para as medidas de avaliação dos conjuntos de resultados do RF.	95
Tabela 18. Matriz de p-valores do teste de Mann-Whitney para comparação de medianas, para os resultados do RF.	96
Tabela 19. Avaliação dos testes do RF com todos os subconjuntos de dados.	96
Tabela 20. Mediana e intervalo de confiança para as medidas de avaliação dos conjuntos de resultados do SVM.	98
Tabela 21. Matriz de p-valores do teste de Mann-Whitney para comparação de medianas, para os resultados do SVM.	99
Tabela 22. Avaliação dos testes do SVM com todos os subconjuntos de dados.	99

Tabela 23. Mediana e intervalo de confiança para as medidas de avaliação dos conjuntos de resultados do SVMp.	100
Tabela 24. Matriz de p-valores do teste de Mann-Whitney para comparação de medianas, para os resultados do SVMp.....	102
Tabela 25. Avaliação dos testes do SVMp com todos os subconjuntos de dados.....	102
Tabela 26. Matriz de p-valores obtidos na comparação dos diferentes cenários.	103
Tabela 27. Resultados médios dos melhores cenários de cada algoritmo.	103
Tabela 28. Matriz de p-valores do teste de Mann-Whitney para comparação de medianas, para os resultados com os dados dos diferentes sensores de iluminância.	105
Tabela 29. Resultados dos testes com o KNN e os subconjuntos de 7 dias utilizando diferentes dados de iluminância.	105

SUMÁRIO

1. Introdução	15
1.1. Justificativa	17
1.2. Objetivos	18
1.2.1. Objetivo geral	18
1.2.2. Objetivos específicos	19
1.3. Estrutura do trabalho	19
2. Revisão da literatura	21
2.1. Edificações com sistemas de controle centrados no usuário	21
2.2. Definições sobre a aprendizagem de máquina	23
2.2.1. Algoritmos frequentemente utilizados na identificação de preferências dos usuários	
26	
2.2.1.1. <i>Decision Tree</i>	26
2.2.1.2. <i>k-Nearest Neighbors</i>	27
2.2.1.3. <i>Multilayer Perceptron</i>	28
2.2.1.4. <i>Random Forest</i>	29
2.2.1.5. <i>Support Vector Machine</i>	30
2.2.2. Seleção de características	31
2.2.3. Medidas de avaliação para a aprendizagem supervisionada	32
2.3. Aprendizagem de máquina para o conforto do usuário	34
2.3.1. Aprendizagem de máquina aplicada ao controle centrado nas preferências do	
usuário	39
2.3.2. Personalização dos sistemas de controle centrados no usuário	49
2.3.2.1. Formas de detecção e identificação dos usuários	49
2.3.2.2. Identificação e incorporação de preferências aos sistemas de controle	51
2.3.3. Impacto no consumo de energia	57
2.4. Síntese do capítulo	59
3. Método	62
3.1. Aquisição de dados	64
3.1.1. Sistema de coleta de dados	64

3.1.2. Questionário	68
3.2. Pré-processamento de dados	70
3.3. Análise de desempenho dos algoritmos.....	73
3.3.1. Seleção do subconjunto de dados.....	74
3.3.2. Seleção e otimização do algoritmo.....	77
3.3.3. Atualização do subconjunto de dados	78
4. Resultados e discussão.....	80
4.1. Dados coletados	80
4.2. Dados pré-processados	82
4.3. Análise de desempenho dos algoritmos.....	85
4.3.1. <i>Decision Tree</i>	86
4.3.2. <i>k-Nearest Neighbors</i>	89
4.3.3. <i>Multilayer Perceptron</i>	91
4.3.4. <i>Random Forest</i>	94
4.3.5. <i>Support Vector Machine</i>	97
4.3.6. <i>Support Vector Machine</i> com ponderação de classes	100
4.4. Seleção do algoritmo	102
4.5. Otimização	104
4.6. Simulação da atualização diária do conjunto de dados.....	106
4.7. Importância da avaliação do algoritmo e do subconjunto ideal.....	108
5. Conclusão	110
5.1. Limitações da pesquisa	112
5.2. Sugestões de trabalhos futuros.....	113
Referências	114
Apêndice A	124
Apêndice B	135

1. Introdução

O setor de edificações é um grande consumidor de energia em âmbito mundial. Entretanto, a utilização de equipamentos eficientes e envoltórias adequadas tem permitido criar edificações com baixo consumo energético. Porém, à medida que uma edificação se torna mais eficiente, o impacto dos usuários e suas ações sobre o consumo de energia tende a aumentar (IEA-EBC, 2018a). Neste sentido, o Anexo 79 da IEA (*International Energy Agency*) visa abordar a incorporação de dados de ocupação e comportamento na fase de projeto e operação da edificação (IEA-EBC, 2018b). Se as preferências dos usuários forem incorporadas à edificação e seus sistemas, é possível adotar estratégias de eficiência energética que não prejudiquem sua condição de conforto (Heydarian et al., 2016; Khan; Kolarik, 2022).

O conforto ambiental depende da qualidade do ar e dos ambientes acústico, térmico e visual. A busca pelo conforto térmico e visual é um dos fatores que mais influenciam no consumo de energia elétrica nas edificações (Sansaniwal *et al.*, 2021). Neste sentido, os pesquisadores têm buscado alternativas para reduzir o consumo de energia associado aos sistemas de climatização e iluminação, mantendo um ambiente adequado para a realização das atividades humanas (Li *et al.*, 2023b). Além do uso de equipamentos eficientes, uma das propostas mais comuns é a automação destes sistemas, principalmente em ambientes não residenciais. No processo de automação são utilizados sistemas de controle, que consistem em conjuntos de dispositivos que controlam o funcionamento de um equipamento ou de outros sistemas (Nise, 2012).

López-Lovillo *et al.* (2023) afirmam que a utilização de sistemas de controle nas edificações é essencial para assegurar economia de energia e conforto aos usuários. A automação do controle dos sistemas requer a determinação de regras de controle, fazendo com que os equipamentos funcionem em condições específicas, acionando e desligando ao identificar os limites da faixa de operação programada. No entanto, estas regras de controle pré-determinadas podem não ser agradáveis para todos os usuários (Ahmadi-Karvigh; Becerik-Gerber; Soibelman, 2019). Além disso, é necessário compreender o ponto de vista do usuário, a fim de evitar que ele se sinta insatisfeito com as condições ambientais e/ou com o sistema de controle em si (Lian *et al.*, 2023).

Diante deste cenário, surge o conceito de controle centrado no usuário, que consiste em utilizar sistemas automatizados cujas regras de controle levem em conta pelo menos algum aspecto do indivíduo: presença, localização, atividade desempenhada, entre outros. Um dos aspectos mais importantes a ser considerado (e possivelmente o mais complexo dentre os mencionados) é o conforto (Naylor; Gillott; Lau, 2018). Em alguns trabalhos, verifica-se que

os autores associam a condição de conforto dos usuários com diretrizes propostas por normas. Tendo em vista que as normas (especialmente as que dispõem sobre aspectos luminosos e térmicos) visam assegurar que sejam fornecidas condições ambientais adequadas no interior das edificações, é comum que os parâmetros propostos por elas sejam utilizados como regras de controle. No entanto, por conta da subjetividade associada à percepção de cada indivíduo sobre o ambiente em que está inserido, tais regras podem não representar a sensação de conforto dos usuários (Kim; Schiavon; Brager, 2018; O'Brien *et al.*, 2017; Wang; Hong, 2020). Esta subjetividade, observada no uso dos sistemas de iluminação e climatização, pode ser integrada às regras de controle dos sistemas por meio de algoritmos de aprendizagem de máquina, proporcionando ambientes mais confortáveis e com potencial de economia de energia (Park *et al.*, 2019b).

Na literatura, observa-se a utilização de aprendizagem de máquina para identificar modelos de conforto, prever a sensação térmica e a qualidade do ar, detectar e reconhecer atividades, controlar sistemas de climatização, iluminação, persianas, abertura de janelas, entre outros (Hong *et al.*, 2020). Para realizar o controle, os algoritmos podem se basear na observação das condições do meio. Porém, como já mencionado, é importante incluir o fator subjetivo da percepção humana na tomada de decisão (Zhu *et al.*, 2023). Isto ajuda a evitar que o sistema se torne mais um cujas regras de controle não satisfazem o usuário. As formas mais comuns de conhecer as preferências dos usuários para incluí-las no controle dos sistemas são: monitorar as interações do usuário com as interfaces do sistema e coletar sua opinião de forma direta (por meio de questionários, aplicativos, etc.). Associar estas informações ao uso de inteligência artificial tem se mostrado uma alternativa eficaz para solucionar alguns dos problemas supracitados.

A aprendizagem supervisionada é a mais utilizada neste contexto, principalmente por conta das variáveis, que podem ser tratadas como categorias (Russell; Norvig, 2009). Isto torna possível separar cada conjunto de parâmetros ambientais em categorias como “confortável” e “desconfortável”. Em outras palavras, as variáveis de entrada (que podem ser dados de ocupação, temperatura, iluminância, umidade, entre outros) são classificadas pelos algoritmos em categorias que indicam diferentes níveis de conforto. Neste sentido, algoritmos de aprendizagem supervisionada têm sido usados para prever aspectos do conforto dos usuários e incorporá-los às regras de controle dos sistemas. No caso de sistemas implementados em ambientes reais, a avaliação pode ser feita do ponto de vista do usuário. Os estudos voltados para a realização de inferências de conforto, no entanto, tendem a analisar os modelos por meio de diferentes medidas e técnicas de validação. Nestes casos, não são consideradas as

atualizações constantes dos dados, ignorando as alterações que a percepção de conforto pode sofrer com o passar do tempo.

Neste contexto, verifica-se a necessidade de desenvolver um método para avaliar e comparar o desempenho de diferentes algoritmos, utilizando dados em constante atualização, como em um ambiente real. Para tanto, um estudo de caso foi realizado utilizando um sistema de coleta de dados que permite a interação do usuário e que está associado ao sistema de iluminação artificial. Conforme já mencionado, a iluminação é um dos aspectos que envolve percepção subjetiva de conforto. Tendo em vista a complexidade e os dilemas envolvidos na automação residencial, mencionados por Karjalainen (2013), o estudo de caso foi realizado em um laboratório de pesquisa, cujas atividades assemelham-se às de um escritório.

1.1. Justificativa

A existência de uma iluminação de qualidade em ambientes internos é imprescindível para o conforto, produtividade e segurança dos seres humanos. A evolução da tecnologia tem facilitado a utilização de sistemas de iluminação mais eficientes. Ainda assim, eles são responsáveis por uma parcela significativa do consumo de energia nas edificações (International Energy Agency, 2023). Chew *et al.* (2017) afirmam que os sistemas de iluminação que têm seu funcionamento baseado na ocupação apresentam potencial de economia de energia de até 50% e que o aproveitamento da iluminação natural pode aumentar este potencial para até 70%. No entanto, quando se trata de conforto, não há um consenso entre os autores sobre como quantificá-lo (Putrada *et al.*, 2022). Muitos trabalhos utilizam as normas vigentes como base, o que não facilita a comparação, uma vez que não há concordância sobre os níveis mínimos de iluminância propostos para cada país. No Brasil, exige-se o mínimo de 500lx em ambientes de escritórios (Associação Brasileira De Normas Técnicas, 2013). No Canadá e na Inglaterra, por exemplo, o mínimo exigido são 400lx, na Suécia os limites variam entre 300 e 600lx e em 22 outros países a variação é de 300 a 500lx. Na França, considera-se que para as atividades de escritório atuais, 120lx são suficientes (O'Brien *et al.*, 2020a).

Mesmo a descoberta de um modelo perfeito e de medidas de conforto não faria com que a modelagem e o controle do sistema de iluminação fossem universalmente aceitos, uma vez que as pessoas percebem a luz de diferentes formas. Nos trabalhos encontrados na literatura, verificou-se que alguns usuários de escritórios têm preferência por níveis de iluminação próximos de 1000lx (Sadeghi *et al.*, 2018), outros toleram níveis de iluminância entre 30lx e 280lx para então acionar as lâmpadas (O'Brien *et al.*, 2017), e alguns o fazem com a iluminância próxima de 400lx (Nagy *et al.*, 2015). Cheng *et al.* (2016) ainda identificaram diferenças de

100lx a 300lx nas preferências dos usuários. Curiosamente, foi identificado que alguns usuários toleram um pequeno desconforto por não estarem dispostos a ir até o interruptor para acionar as lâmpadas (Malavazos *et al.*, 2015; Pellegrino *et al.*, 2016). Por outro lado, o estudo de Nagy, Yong e Schlueter (2016) afirma que nem sempre os usuários estão dispostos a abrir mão do conforto para economizar energia.

Dado o caráter subjetivo do conforto visual, verifica-se que o uso de sistemas de controle de iluminação baseados em normas pode não ser a condição ideal. A observação das interações que ocorrem entre os ocupantes e o ambiente é fundamental para a tomada de decisão acerca das regras de controle (Lian *et al.*, 2023). O uso da aprendizagem de máquina neste caso possibilitaria a “personalização” das ações do sistema de acordo com a preferência de cada usuário. Para que o algoritmo identifique as preferências, é necessário utilizar um conjunto de dados que seja representativo para os usuários em questão. Considerando que as preferências podem mudar ao longo do tempo, também é importante verificar se o algoritmo mantém desempenho adequado com a alteração do conjunto de dados.

Na literatura, costuma-se avaliar os algoritmos usando as medidas de desempenho obtidas por meio de validação cruzada. A validação cruzada é um método de reamostragem que usa diferentes partições dos dados para treinar e testar um modelo em diferentes iterações. Para este tipo de validação, a estratificação dos dados é feita de maneira aleatória, sempre abrangendo o conjunto de dados completo (Kohavi, 1995). Neste sentido, este método de avaliação pode não representar o desempenho do algoritmo em um sistema real, pois não utiliza, necessariamente, os dados em ordem cronológica. Desta forma, verifica-se a necessidade de um método com critérios bem definidos para selecionar o algoritmo e as configurações que o fariam prever as preferências dos usuários com mais precisão.

1.2. Objetivos

Nesta seção são descritos os objetivos a serem alcançados com o desenvolvimento desta pesquisa.

1.2.1. Objetivo geral

O objetivo geral deste trabalho é desenvolver um método para orientar a escolha de algoritmos de aprendizagem de máquina a serem utilizados em estudos de sistemas de controle centrados no conforto do usuário de edificações.

1.2.2. Objetivos específicos

Os seguintes objetivos específicos foram elencados:

- Criar um conjunto de dados contendo as preferências de iluminação de usuários de um laboratório de pesquisa e as diversas condições de iluminância e ocupação;
- Identificar os algoritmos mais utilizados na literatura e analisar sua capacidade de aprendizagem conforme as medidas de desempenho adequadas;
- Identificar a combinação algoritmo-subconjunto de dados cujo desempenho é superior aos demais (configuração ideal);
- Avaliar o desempenho da configuração ideal simulando computacionalmente seu funcionamento em um cenário realístico, por meio da atualização dos dados de treinamento e teste.

1.3. Estrutura do trabalho

Este trabalho divide-se em cinco capítulos. Neste primeiro capítulo é realizada a contextualização do problema, indicando a importância de incorporar as preferências dos usuários aos sistemas de controle, o que pode ser realizado por meio da utilização de algoritmos de aprendizagem de máquina. Identificou-se a inexistência de um método que permita a comparação entre algoritmos para definir qual o mais apropriado considerando a atualização dos dados, fato que direcionou os objetivos deste trabalho. Verificou-se, ainda, que os sistemas de iluminação podem servir de estudo de caso para a validação do método proposto, pois seu funcionamento depende da subjetividade associada ao comportamento do usuário. São apresentados também nesta seção os objetivos e a estrutura do trabalho.

No segundo capítulo apresenta-se uma revisão de literatura dividida em três subseções. A primeira aborda os aspectos gerais das edificações centradas nos usuários. Na segunda subseção são apresentados os conceitos mais relevantes sobre aprendizagem de máquina, os algoritmos mais populares na identificação das preferências dos usuários e as medidas de avaliação. A terceira subseção aborda o uso da aprendizagem de máquina na identificação das preferências dos usuários e sua incorporação aos sistemas de controle. Nesta subseção, trata-se do desempenho dos algoritmos, da detecção e distinção dos usuários, das formas de identificar preferências, da satisfação dos usuários com os sistemas implementados e do potencial de economia de energia.

No terceiro capítulo, descreve-se o método proposto para atingir os objetivos deste trabalho. A partir da coleta de dados de iluminância, estado do sistema de iluminação e

ocupação, propõe-se uma série de testes com diferentes algoritmos. A primeira etapa de testes consiste em identificar a quantidade de dias ideal para cada algoritmo prever o estado do sistema de iluminação. A segunda etapa permite comparar os algoritmos e selecionar aquele com desempenho superior aos demais. Em seguida, propõe-se a otimização da configuração com melhor desempenho (algoritmo e quantidade de dias ideal). Na última etapa, apresenta-se um teste elaborado para verificar o desempenho do algoritmo escolhido em um ambiente real.

Em seguida, o quarto capítulo apresenta os resultados alcançados e as discussões pertinentes. No quinto capítulo, são apresentadas as principais conclusões, bem como as limitações desta pesquisa e sugestões de trabalhos futuros. Por fim, os apêndices apresentam um quadro síntese da revisão bibliográfica e as respostas dos questionários aplicados.

2. Revisão da literatura

Este capítulo contempla a revisão da literatura dos temas relevantes para a compreensão e fundamentação deste trabalho.

2.1. Edificações com sistemas de controle centrados no usuário

Edificações deveriam ser projetadas para atender às demandas de seus ocupantes. No entanto, a negligência com relação a determinadas interações entre o usuário e a edificação pode resultar em uma edificação que não atinge os níveis de conforto propostos por normas e não atende às expectativas dos usuários (O'Brien *et al.*, 2020b). Neste sentido, o conceito de projeto e operação de edificações centrados no usuário surge como uma alternativa para melhorar o desempenho energético das edificações e o conforto ambiental de seus ocupantes (IEA-EBC, 2018b).

Na busca pela eficiência energética, surgiram maneiras de automatizar os sistemas, retirando o controle das mãos do usuário em diferentes níveis. Esta estratégia visa evitar desperdícios e comportamentos inadequados que possam elevar o consumo de energia, sobretudo em edificações não residenciais. No entanto, isso pode gerar prejuízos para o conforto do usuário, seja pela percepção de que ele não possui controle sobre o ambiente em que está inserido ou porque as regras e condições determinadas aos sistemas por meio da automação não estão proporcionando um ambiente confortável (Ahmadi-Karvigh; Becerik-Gerber; Soibelman, 2019; Bavaresco *et al.*, 2019; Day *et al.*, 2020). Tabadkani *et al.* (2021) afirmam que os usuários se sentem mais satisfeitos quando podem fazer ajustes manuais no ambiente, ou quando este é controlado de acordo com suas preferências.

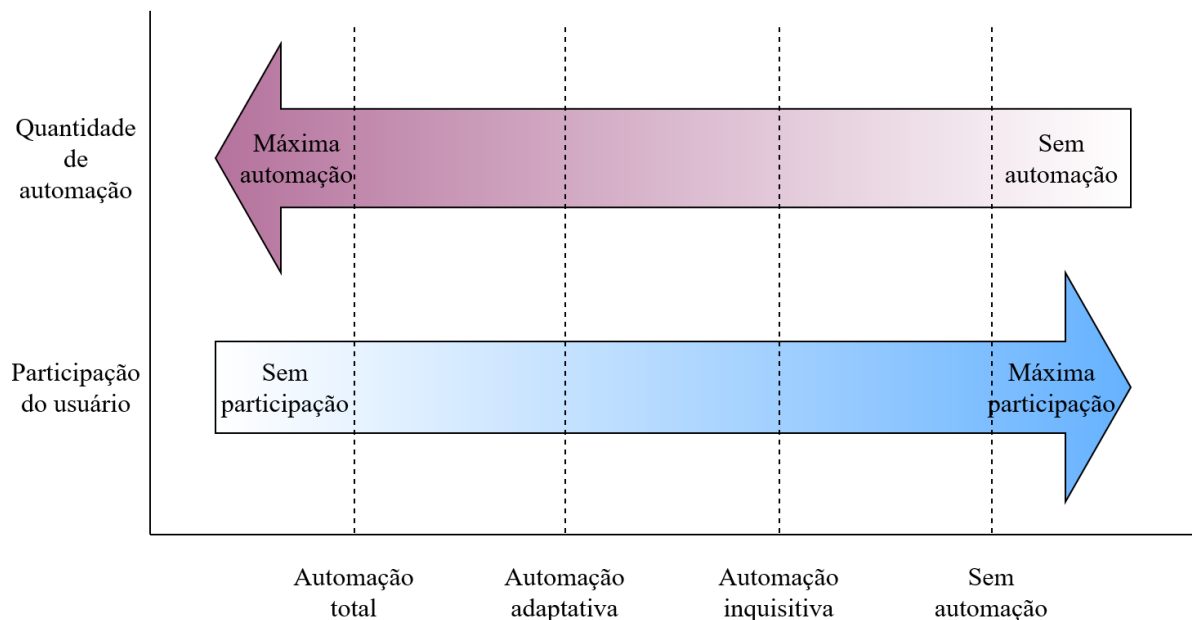
Neste sentido, para assegurar conforto e eficiência energética mantendo a participação do usuário na operação da edificação, é necessário que suas interfaces sejam acessíveis e “amigáveis” do ponto de vista do usuário (O'Brien *et al.*, 2020b), a fim de que ele possa realizar alterações no ambiente conforme suas necessidades. A definição de interface, segundo Day *et al.* (2020), é qualquer coisa com a qual o usuário pode interagir em uma edificação e que pode afetar os serviços, o uso de energia e as condições ambientais no interior da edificação.

Karjalainen (2013) afirma que definir o nível de automação é um dos principais problemas no projeto de sistemas de controle, pois disso depende a satisfação dos usuários. Os níveis de automação são definidos por Ahmadi-Karvigh, Becerik-Gerber e Soibelman (2019) como:

- Sem automação: o sistema não oferece assistência ao usuário. Por ser totalmente manual, a participação do usuário é máxima.
- Automação inquisitiva: o sistema de automação solicita a autorização do usuário antes de realizar qualquer ação. Neste caso, a participação do usuário é maior que o nível de automação.
- Automação adaptativa: a partir da automação inquisitiva prévia, o sistema aprende a preferência do usuário sob diferentes condições. Neste tipo de automação, a participação do usuário diminui com o tempo, enquanto o nível de automação aumenta.
- Automação total: o sistema mantém o controle em qualquer circunstância, funcionando com base em regras pré-estabelecidas. Em outras palavras, a automação é máxima e a participação do usuário é nula.

De acordo com os autores, o nível de automação preferida varia com o contexto associado, mas a automação adaptativa costuma atender melhor as expectativas dos usuários. Hellwig, Schweiker e Boerstra (2020) acrescentam que a satisfação do ocupante diminui à medida que seu controle percebido é reduzido. A Figura 1 ilustra a relação existente entre os níveis de automação apresentados e o nível de participação do usuário.

Figura 1. Relação entre os níveis de automação e a participação do usuário.



Fonte: Adaptado de Ahmadi-Karvigh *et al.* (2017)

Visando encontrar a relação ideal entre consumo de energia e satisfação do usuário, encontra-se na literatura uma variedade de combinações de estratégias de detecção de usuários

e controle dos sistemas (Naylor; Gillott; Lau, 2018). O controle centrado no usuário pode ser baseado na presença, no número de pessoas (contagem de usuários), na localização, no conforto ou na atividade desempenhada. Por sua vez, o tipo de controle varia entre reativo, preditivo, por atividade ou preferência. Neste trabalho, a revisão direciona-se para os que se baseiam na preferência dos usuários. Ressalta-se, porém, que as categorias não são mutuamente exclusivas.

As preferências dos usuários podem ser identificadas na fase de projeto ou operação da edificação e de diferentes formas. As mais comuns são os questionários, o uso de *feedback* (voluntário ou solicitado) e o monitoramento das ações e interações dos usuários com os sistemas da edificação (Khan; Kolarik, 2022; Khan; Kolarik; Weitzmann, 2020; Park et al., 2019b). Também é possível fazer uso de ambientes imersivos virtuais (Hegazy; Yasufuku; Abe, 2020; Heydarian *et al.*, 2017; Latini; Di Giuseppe; D’Orazio, 2023; Mahmoudzadeh; Afacan; Adi, 2021), no entanto, alguns aspectos da realidade são difíceis de serem simulados com realismo (Zhu *et al.*, 2018). Outra alternativa é fazer uso da aprendizagem de máquina para identificar, entre os dados coletados, as preferências dos usuários. Este assunto é tratado com mais detalhes na seção 2.3, onde são abordados os sistemas de controle cujo funcionamento baseia-se na identificação das preferências dos usuários por algoritmos de aprendizagem de máquina.

2.2. Definições sobre a aprendizagem de máquina

A aprendizagem de máquina consiste em treinar os computadores para “aprender” a partir de dados previamente coletados. Esta abordagem é apropriada para os casos em que não é possível escrever programas para solucionar problemas, uma vez que a solução não é conhecida *a priori*. Em geral, a aprendizagem de máquina pode ser utilizada para gerar conhecimento sobre experiências passadas, na modelagem preditiva ou na tomada de decisões (Djenouri *et al.*, 2019). A previsibilidade do comportamento e/ou das preferências dos ocupantes é uma destas situações.

Os algoritmos de aprendizagem de máquina podem ser classificados em três categorias: aprendizagem supervisionada, aprendizagem não supervisionada e aprendizagem por reforço (Bonaccorso, 2017).

A aprendizagem supervisionada é caracterizada pela presença de um supervisor, cuja tarefa principal é classificar pares entrada-saída que devem servir de base para o aprendizado. Neste caso, é necessário que o modelo possua uma habilidade de generalização para evitar um problema chamado *overfitting*, que acontece quando o modelo prediz corretamente apenas as

amostras com que foi testado, apresentando erros significativamente grandes para outras amostras (Bonaccorso, 2017).

Um exemplo típico desta abordagem é a Classificação: dado um conjunto finito de classes conhecidas, busca-se encontrar uma solução que permita identificar (ou prever) a que categoria uma nova informação pertence. Outro exemplo é a Regressão, em que, aprendendo uma função numérica que relaciona os dados de entrada e de saída, é possível prever um valor a partir de uma entrada. As ferramentas mais comuns de aprendizagem supervisionada são as Redes Neurais Artificiais (RNA), o *Support Vector Machine* (SVM), o *k-Nearest Neighbors* (KNN), a Regressão Logística (RLog), as Árvores de Decisão (DT, do inglês *Decision Tree*) e o *Random Forest* (RF). A qualidade das inferências está intimamente relacionada com o conjunto de dados e a escolha do algoritmo, sendo necessária a realização de testes. O custo computacional também pode ser um dos critérios para a seleção do algoritmo, juntamente com os resultados obtidos nos testes (Djenouri *et al.*, 2019).

De acordo com Russel e Norvig (2009), para verificar a capacidade de generalização de um modelo, pode-se fazer uso de validação cruzada. Esta técnica consiste em particionar os dados em subconjuntos mutuamente exclusivos que devem servir para treinamento e validação do modelo. Existem três técnicas para aplicar a validação cruzada:

- *Holdout*: os dados são particionados aleatoriamente em uma amostra h e outra y . A amostra y será usada para testar a qualidade do modelo gerado por h . A desvantagem desta técnica consiste no risco de serem utilizados poucos dados para o treinamento ou teste;
- *k-fold*: os dados são divididos em k subconjuntos e, em seguida, $1/k$ dos dados é separado para o teste, enquanto o restante é usado para o treinamento. Repete-se o processo k vezes;
- *Leave-one-out*: variação do *k-fold* em que k é igual ao número total de dados do conjunto.

O método de validação mais comum é o *k-fold* (Russell; Norvig, 2009). Existem, ainda, medidas para avaliar os algoritmos de aprendizagem supervisionada. Entre as principais, estão:

- *Acurácia*: indica a efetividade geral do método, isto é, o percentual de acertos;
- *Sensibilidade*: também chamada de *Recall*, indica a probabilidade de o modelo classificar corretamente os casos positivos;
- *Especificidade*: é o oposto da sensibilidade. Indica a probabilidade de o modelo classificar corretamente os casos negativos;

- Precisão: avalia a quantidade de verdadeiros positivos sobre a soma de todos os dados classificados como positivos;
- *F1-score*: relaciona sensibilidade e precisão em um único valor;
- *Area Under Curve* (AUC): indica a capacidade do classificador de distinguir entre as classes. Quanto maior a AUC, melhor o desempenho do classificador.

A aprendizagem não supervisionada baseia-se na ausência de um supervisor. É útil quando é necessário descobrir como um conjunto de elementos pode ser agrupado (Bonaccorso, 2017). Um exemplo conhecido de análise não supervisionada é a *clusterização*, cujo objetivo é agrupar elementos de maneira que os objetos em um grupo tenham mais similaridades entre si do que com os objetos de outros grupos. Para isso, existem técnicas hierárquicas e não hierárquicas. Um dos algoritmos mais conhecidos é o *k-means clustering*, que utiliza técnicas não hierárquicas. Ao contrário da Classificação, o conjunto de *clusters* não é conhecido inicialmente, mas depende do treinamento dos dados (Djenouri *et al.*, 2019).

Neste caso, o que se pode avaliar é a homogeneidade interna e a heterogeneidade entre os grupos. Espera-se que, após o agrupamento, os elementos de um grupo sejam altamente homogêneos e que os grupos sejam altamente heterogêneos entre si (Hair *et al.*, 2009). De acordo com Rosa (2019), as medidas de similaridade mais utilizadas para avaliar agrupamentos são a distância City-Block ou Manhattan, distância Euclidiana, distância Euclidiana quadrada, distância Chebyshev e coeficiente de Pearson. A opção por uma delas depende se o método utilizado é hierárquico ou não-hierárquico.

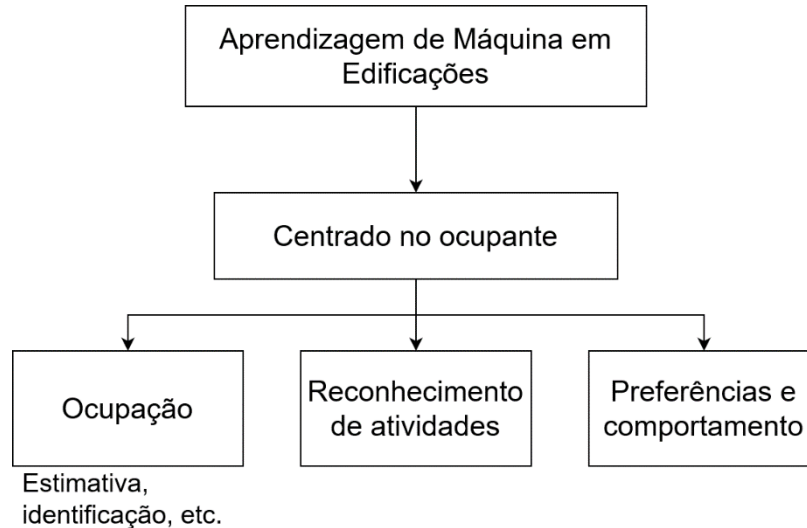
Apesar de não contar com um supervisor, a aprendizagem por reforço difere da categoria anterior por ter o aprendizado baseado em tentativa e erro. Seu funcionamento baseia-se na utilização de uma política (conjunto de ações para cada estado) para decidir se uma determinada ação em um determinado estado é positiva ou não. Se a ação for positiva, o sistema recebe uma recompensa, caso contrário, recebe uma penalidade (Russell; Norvig, 2009). Esta abordagem é particularmente eficiente em ambientes dinâmicos, uma vez que utiliza ideias da teoria dos sistemas dinâmicos, como os Processos de Decisão de Markov (Sutton; Barto, 2018).

Existe ainda uma categoria intermediária, chamada aprendizagem semi-supervisionada. Neste caso, utiliza-se uma pequena quantidade de dados classificados com uma quantidade maior de dados não classificados (Bonaccorso, 2017).

De acordo com Kjærsgaard *et al.* (2018), as técnicas de inteligência artificial aliadas a sensores de diversos tipos podem fornecer diferentes perspectivas a respeito da ocupação humana e suas ações. Os autores ressaltam ainda que tais técnicas são ainda pouco exploradas.

A aplicação de algoritmos de aprendizagem de máquina em edificações divide-se em duas classes: centrada no usuário e nos dispositivos/consumo de energia. A Figura 2 mostra as possibilidades de utilização da aprendizagem de máquina nas edificações centradas no usuário.

Figura 2. Utilização da aprendizagem de máquina em edificações centradas no usuário.



Fonte: Adaptado de Djenouri *et al.* (2019).

A utilização de aprendizagem de máquina para aprender as preferências dos usuários e seus comportamentos é abordada nas próximas subseções.

2.2.1. Algoritmos frequentemente utilizados na identificação de preferências dos usuários

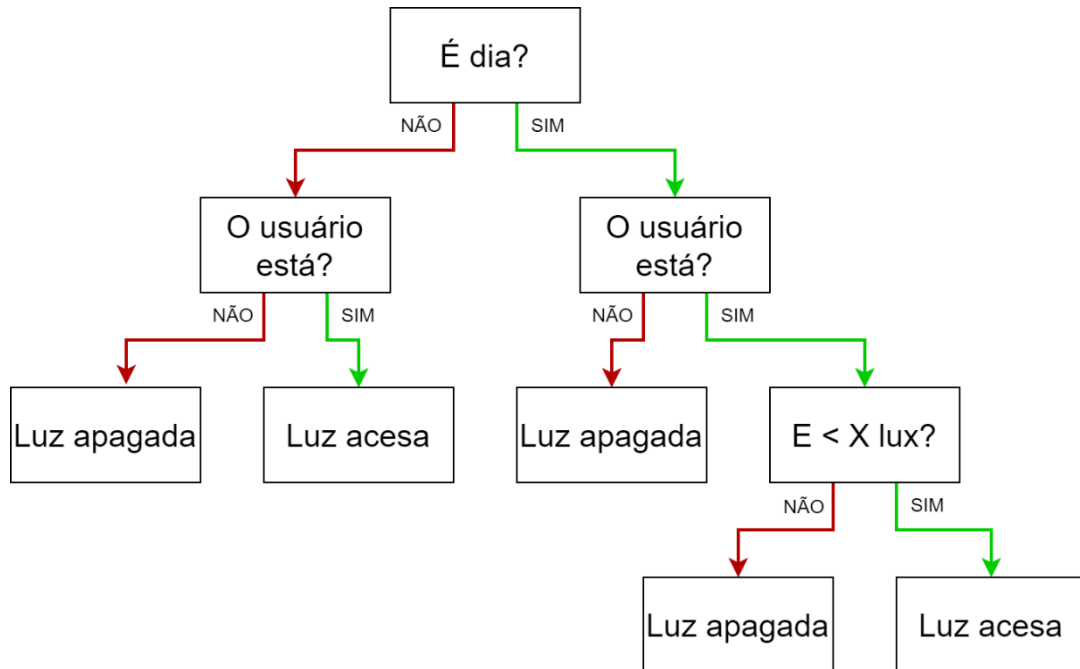
Os algoritmos de aprendizagem supervisionada são caracterizados por precisarem passar por um processo de “treinamento” a fim de identificar corretamente as saídas para cada possível entrada. Em outras palavras, os algoritmos são alimentados por um conjunto de dados contendo informações de entrada e saídas esperadas. Ao longo do treinamento, os algoritmos são capazes de aprender certos padrões e, em seguida, indicar as saídas adequadas para cada nova entrada. As subseções a seguir descreverão brevemente os algoritmos mais utilizados para identificar as preferências dos usuários e suas formas de avaliação.

2.2.1.1. *Decision Tree*

Este algoritmo pode ser descrito como um processo que particiona recursivamente o conjunto de dados. Seu objetivo é criar um modelo que possa prever um determinado valor a partir do

aprendizado de regras observadas no conjunto de dados (De Ville, 2013). A Figura 3 ilustra o processo simplificado de uma *Decision Tree*.

Figura 3. Esquema de funcionamento de uma DT.




Durante o processo de treinamento, os dados vão sendo particionados com base em algum critério, dividindo-se em nós na árvore. Na etapa de inferência, uma dada entrada vai sendo “levada adiante” pelos nós da árvore movendo-se para a direita ou para a esquerda, a partir das regras aprendidas.

2.2.1.2. *k-Nearest Neighbors*

Neste algoritmo, considera-se que os dados constituem pontos em um espaço n-dimensional. Cada um destes pontos pertence a uma classe e o processo de classificação é realizado comparando uma amostra com seus vizinhos próximos. Em outras palavras, ao comparar uma amostra desconhecida (círculo branco ao centro da Figura 4) e compará-la com seus dois vizinhos mais próximos ($k = 2$), esta amostra será classificada como “roxa”. Caso ela seja comparada aos cinco vizinhos mais próximos, será classificada como “laranja”. Sugere-se que o número de k não seja par, a fim de evitar empates durante o processo de classificação (Larose; Larose, 2014).

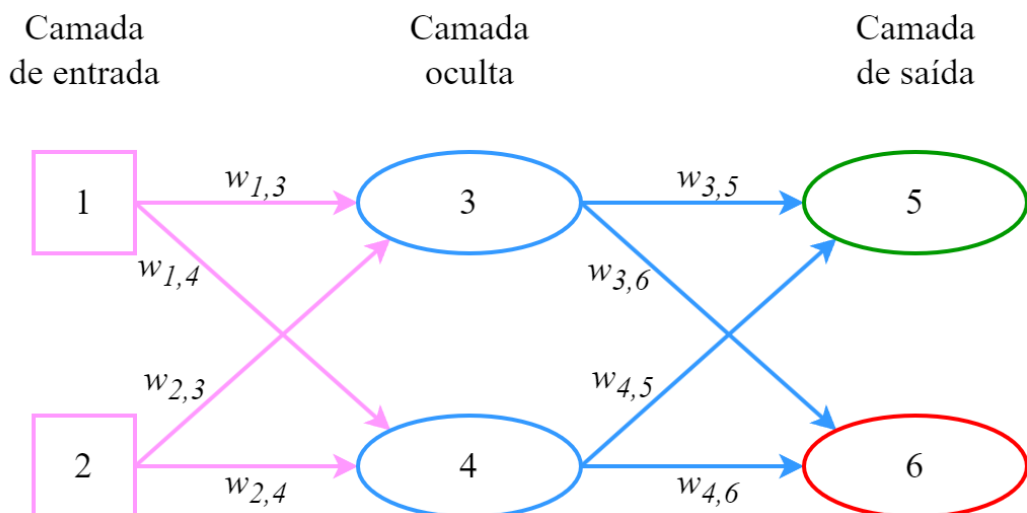
Figura 4. Exemplificação do algoritmo KNN.



2.2.1.3. Multilayer Perceptron

Uma rede neural do tipo MLP consiste em um sistema de neurônios interconectados que representa a relação não-linear entre os vetores de entrada e saída. Os neurônios são conectados por ponderações w e saídas que são função da soma das entradas do neurônio modificadas por uma função de transferência (ou ativação), g . A saída de cada nó (neurônio) é a entrada para a próxima camada da rede, definindo a direção do processamento da informação (*feed forward*) (Gardner; Dorling, 1998). Para compreender o funcionamento das redes MLP, pode-se levar em conta a rede neural da Figura 5.

Figura 5. Exemplo de MLP com duas camadas ocultas.



Fonte: Adaptado de Russell e Norvig (2009).

Tendo como vetor de entrada $\mathbf{x} = (x_1, x_2)$, a saída na unidade 5 será descrita por meio da Equação 1.

$$a_5 = g\left(w_{0,5} + w_{3,5}g\left(w_{0,3} + w_{1,3}x_1 + w_{2,3}x_2\right) + w_{4,5}g\left(w_{0,4} + w_{1,4}x_1 + w_{2,4}x_2\right)\right) \quad (1)$$

Onde:

a_5 é a saída na unidade 5;

g é a função de ativação;

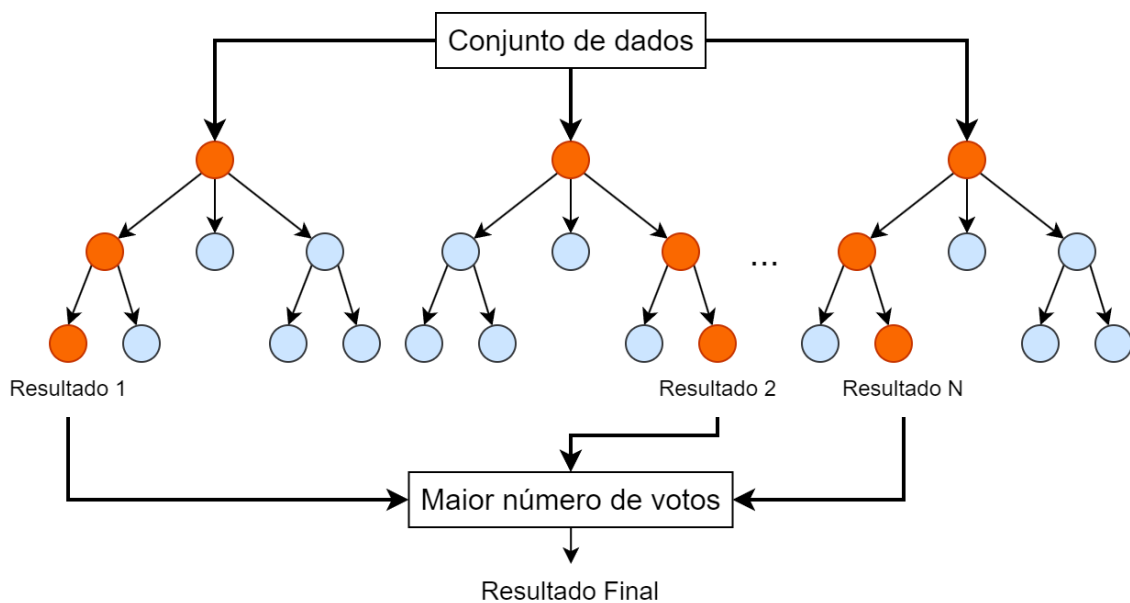
$w_{i,j}$ são as ponderações de ligação entre os neurônios i e j ;

x_i são os elementos do vetor de entrada \mathbf{x} .

2.2.1.4. *Random Forest*

O *Random Forest* consiste em um conjunto de árvores de decisão, que são treinadas com os mesmos parâmetros, mas diferentes subconjuntos de dados. Enquanto uma *Decision Tree* cria regras para a tomada de decisões, o *Random Forest* seleciona aleatoriamente subconjuntos e faz observações sobre eles para, ao final, tomar decisões (Figura 6). Os principais parâmetros do RF são o tamanho dos nós, o número de árvores e de características da amostra (Breiman, 2001).

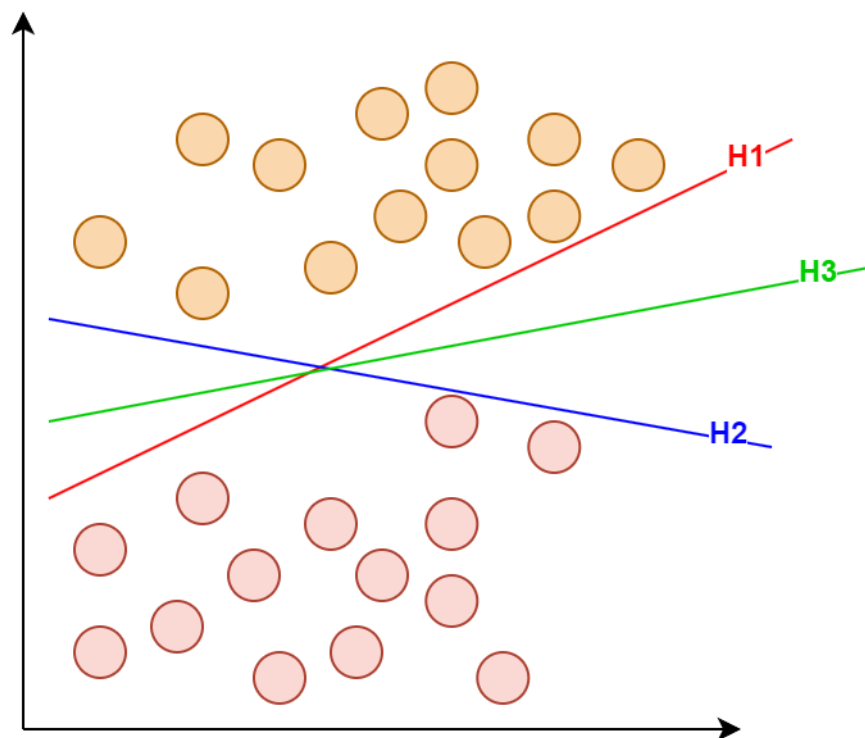
Figura 6. Esquema geral de funcionamento do algoritmo RF.



2.2.1.5. Support Vector Machine

De acordo com Chang e Lin (2011), um algoritmo do tipo SVM pode ser utilizado em diferentes problemas de aprendizado, como regressão ou classificação. A partir dos dados de treino, este algoritmo utiliza atributos da amostra (x) para prever uma determinada classe (y). De forma geral, o SVM traça possíveis hiperplanos que possam separar as classes, buscando pelo mais adequado, como mostra a Figura 7. Idealmente, o hiperplano mais adequado é o que possui a maior margem em relação a todas as classes (H3).

Figura 7. Hiperplanos traçados pelo SVM para a classificação das amostras.



O SVM é um algoritmo baseado em *kernel*, que pode ser linear, polinomial, sigmoide ou uma função de base radial. A escolha do *kernel* pode depender das características do conjunto de dados. Além disso, outros parâmetros que precisam ser adotados de forma apropriada são o custo da penalidade (C) e γ . Se o valor de C for muito alto, a taxa de acertos do modelo pode ser alta durante o treinamento, mas baixa para a inferência. No caso de γ , valores elevados podem levar ao *overfitting*, e valores baixos ao *underfitting*.

Há, ainda, a possibilidade de atribuir pesos para cada classe (possível saída). O algoritmo realiza a ponderação por meio da Equação 2, o que tende a melhorar os resultados quando as classes são desbalanceadas. Neste trabalho, o uso do SVM com ponderação por pesos será chamado de SVMp.

$$WC_n = \frac{TA}{QC * QA} \quad (2)$$

Onde:

WC_n é o peso atribuído à classe n ;

n é a classe;

TA é o número total de amostras no conjunto de dados;

QC é quantidade de classes;

QA é a quantidade de amostras na classe n .

2.2.2. Seleção de características

Na aprendizagem de máquina, as variáveis de entrada utilizadas na criação de modelos são chamadas de características (ou *features*, em inglês). Para exemplificar, pode-se considerar o conjunto de dados da Tabela 1. Cada coluna do conjunto de dados consiste em uma característica. Algumas destas características, no entanto, podem não contribuir significativamente para o desenvolvimento do modelo. É possível, ainda, que o excesso de características cause lentidão no processamento dos dados e/ou faça com que o modelo incorpore padrões irrelevantes.

Tabela 1. Exemplo de conjunto de dados.

temp_interna	temp_externa	iluminancia	ar_cond	interruptor	usuario1	usuario2
22,1	25,0	589	on	on	1	1
20,0	25,5	874	off	on	1	0
...

Neste sentido, reduzir a quantidade de características e utilizar apenas as mais relevantes para o modelo pode ser uma alternativa para sua otimização. A verificação pode ser realizada manualmente, treinando o modelo repetidamente com diferentes quantidades de características ou por meio de métodos como o *Feature Selection*, que estima a relevância de cada característica para o resultado final. No entanto, este método não pode ser utilizado com todos os algoritmos existentes, por conta das características de cada algoritmo.

2.2.3. Medidas de avaliação para a aprendizagem supervisionada

Para avaliar o desempenho dos algoritmos, pode-se utilizar a validação cruzada, além das medidas de acurácia, sensibilidade, especificidade, precisão e *F1-score* (Russell; Norvig, 2009). A acurácia é descrita por meio da Equação 3 e indica a efetividade geral do modelo. Consiste na soma dos verdadeiros positivos com os verdadeiros negativos, dividida pelo total de amostras. No contexto deste estudo de caso, pode-se definir:

- Verdadeiros positivos: seriam os casos em que o algoritmo identifica corretamente o acionamento do sistema de iluminação na presença dos usuários;
- Verdadeiros negativos: acontecem quando o algoritmo identifica corretamente que há, pelo menos, um usuário no ambiente, mas que o sistema de iluminação deve permanecer desligado;
- Falsos positivos: são os casos em que a rede supõe o acionamento do sistema de iluminação, mas ele deveria permanecer desligado;
- Falsos negativos: contrários aos falsos positivos, são os casos em que a rede supõe que o sistema deve permanecer desligado enquanto, na verdade, ele deve ser acionado.

$$A = \frac{VP + VN}{TA} \quad (3)$$

Onde:

A é a acurácia do modelo (%);

VP é o número de verdadeiros positivos;

VN é o número de verdadeiros negativos;

TA é o número total de amostras.

A sensibilidade é calculada por meio da razão entre os verdadeiros positivos e a soma dos falsos negativos com os verdadeiros positivos. Esta medida indica a probabilidade de o modelo classificar corretamente os casos positivos e é descrita por meio da Equação 4.

$$S = \frac{VP}{VP + FN} \quad (4)$$

Onde:

S é a sensibilidade do modelo (%);

VP é o número de verdadeiros positivos;

FN é o número de falsos negativos.

A especificidade indica a probabilidade de os casos negativos serem classificados corretamente. É a razão entre os verdadeiros negativos e a soma dos falsos positivos e os verdadeiros negativos, sendo descrita por meio da Equação 5.

$$E = \frac{VN}{FP + VN} \quad (5)$$

Onde:

E é a especificidade do modelo (%);

VN é o número de verdadeiros negativos;

FP é o número de falsos positivos.

A precisão indica quantos dados realmente são positivos, entre todos os que foram classificados como positivos. É a razão entre os verdadeiros positivos e a soma destes com os falsos positivos, como descreve a Equação 6.

$$Pr = \frac{VP}{VP + FP} \quad (6)$$

Onde:

Pr é a precisão do modelo (%);

VP é o número de verdadeiros positivos;

FP é o número de falsos positivos.

O *F1-score* é descrito pela Equação 7. Este parâmetro une, em um único valor, precisão e sensibilidade para determinar a qualidade geral do modelo. Se o valor de F1 for baixo, é um indicativo de que a precisão ou a sensibilidade estão baixos.

$$F1 = 2 * \frac{Pr * S}{Pr + S} \quad (7)$$

Onde:

F1 é o valor do parâmetro *F1-score*;

Pr é a precisão do modelo (%);

S é a sensibilidade do modelo (%).

A utilização das medidas de avaliação supracitadas é fundamental para assegurar a qualidade do modelo, identificando a quantidade de falsos positivos e negativos, especialmente se a amostra estiver desbalanceada. Em outras palavras, se 90% dos dados coletados forem de acionamento de lâmpadas, a acurácia do algoritmo em questão pode vir a ser de 90% sem que ele seja capaz de identificar qualquer situação em que as lâmpadas deveriam ser desligadas. Neste caso, verificar a sensibilidade, a especificidade e precisão dos resultados permitiria identificar se o modelo foi capaz de realizar previsões adequadas mesmo com um conjunto de dados tendencioso. Outra situação em que a identificação de falsos positivos e/ou negativos é importante é na inferência de conforto dos ocupantes. Um modelo pode classificar equivocadamente tanto as situações de conforto quanto as de desconforto. No entanto, classificar as condições desconfortáveis como confortáveis pode ocasionar mais prejuízo aos ocupantes do que o oposto.

2.3. Aprendizagem de máquina para o conforto do usuário

A utilização da aprendizagem de máquina no contexto das edificações centradas no usuário tem ganhado espaço junto a outras soluções e, mais recentemente, sido apresentada como abordagem principal. É possível encontrar menções ao uso da aprendizagem de máquina em revisões voltadas para o conforto térmico (Arakawa Martins; Soebarto; Williamson, 2022; Chen *et al.*, 2023; Grassi *et al.*, 2022; Xie *et al.*, 2020), controle dos sistemas de climatização (Ala'raj *et al.*, 2022; Lee; Karava, 2020; Peng *et al.*, 2022; Zhang; Tzempelikos, 2021) e iluminação (López-Lovillo *et al.*, 2023; Plörer *et al.*, 2021) ou para o controle centrado no ocupante de forma geral (Halhouli Merabet *et al.*, 2021; Han *et al.*, 2019; Park *et al.*, 2019b). Revisões voltadas exclusivamente para o tema elencam os autores que utilizaram esta abordagem para prever a ocupação de ambientes (Dai; Liu; Zhang, 2020; Zhang; Wu; Calautit, 2022) e a abertura de janelas (Dai; Liu; Zhang, 2020), melhorar diferentes aspectos da iluminação (tecnologias, eficiência, segurança, conforto) em ambientes internos e externos (Putrada *et al.*, 2022), criar modelos de conforto térmico personalizados (Qavidel Fard; Zomorodian; Korsavi, 2022) e analisar o impacto do conforto térmico na cognição, trabalho e saúde dos ocupantes (Li *et al.*, 2023b). Observa-se que são várias as possibilidades de utilização

da aprendizagem de máquina no contexto das edificações centradas no usuário. Porém, nesta etapa da revisão bibliográfica foram selecionados trabalhos que:


- Fizeram uso de algoritmos de aprendizagem de máquina e/ou com capacidade de aprender de forma dinâmica;
- Incluíram a dimensão humana na formulação do problema;
- Consideraram o conforto térmico e/ou visual dos usuários de escritório em sua abordagem.

Os critérios de exclusão utilizados foram:

- Possuir foco apenas em economia de energia;
- Abordar a questão do conforto dos usuários com base em normas ou modelos clássicos da literatura;
- Tratar apenas de controle de janelas e persianas.

Desta forma, esta etapa da revisão da literatura encontrou 61 artigos, publicados entre 2014 e dezembro de 2023 (Figura 8) em diferentes periódicos e anais de eventos, considerados devido à sua relevância na área da computação.

Figura 8. Quantidade de publicações por ano.



A ocorrência de trabalhos encontrados em cada periódico pode ser vista na Tabela 2. A maior parte dos trabalhos foi encontrada nos periódicos *Building and Environment* e *Energy and Buildings*. Dentre as publicações, foram encontrados desde estudos que coletaram dados a fim de realizar inferências sobre os aspectos relacionados ao conforto até estudos que realizaram análises dos sistemas de climatização, iluminação e persianas de forma simultânea.


Uma parte significativa dos trabalhos de inferência foram desenvolvidos em ambientes controlados, assim como alguns estudos de controle. Os demais estudos de controle foram desenvolvidos em campo e por meio de simulações computacionais.

Tabela 2. Quantidade de publicações por periódico entre 2014 e 2023.

Periódico	Quantidade de trabalhos
<i>Building and Environment</i>	23
<i>Energy and Buildings</i>	14
<i>Proceedings</i>	7
<i>Applied Energy</i>	2
<i>Buildings</i>	1
<i>Building Research and Information</i>	1
<i>Building Simulation</i>	1
<i>Automation in Construction</i>	1
<i>Science and Technology for the Built Environment</i>	1
<i>Sustainable Cities and Society</i>	1
<i>Journal of Building Engineering</i>	1
<i>Sensors</i>	1
<i>Applied Ergonomics</i>	1
<i>Applied Sciences</i>	1
<i>Technologies</i>	1
<i>Sustainability</i>	1
<i>IEEE Sensors Journal</i>	1


A maior parte dos trabalhos revisados concentra-se no uso da aprendizagem de máquina para a realização de inferências a respeito dos aspectos envolvendo o conforto dos usuários. Dentre estes, mais de 85% abordam questões referentes ao ambiente térmico, conforme mostra a Figura 9. Salienta-se que os estudos que avançam até a etapa de conforto também precisam realizar inferências sobre as preferências dos usuários. No entanto, para fins de organização, estes estudos não estão inclusos nesta categoria.

Figura 9. Proporção de inferências realizadas por aprendizagem de máquina.



Nos estudos de inferência, observa-se predominância de curtos períodos de coleta de dados, o que pode ser visto na Figura 10. Em geral, estes estudos são conduzidos em ambientes controlados e, por isso, duram apenas algumas horas. Estima-se que, em decorrência disso, apenas três autores tenham levado em conta as interações dos usuários (Lu; Cochran Hameen, 2021; Wang *et al.*, 2023; Xiong *et al.*, 2020). Durante a coleta de dados, os pesquisadores costumam variar as condições ambientais a fim de induzir diferentes sensações nos usuários e coletar diferentes *feedbacks*. A partir disso, estima-se ser possível identificar quais condições são preferidas por um ou mais participantes do estudo.

Figura 10. Duração dos estudos direcionados unicamente para a realização de inferências.




Esta abordagem torna-se interessante quando não é possível desenvolver este tipo de estudo em ambientes reais. Fatores como a necessidade de instalação de equipamentos de monitoramento e tempo disponível podem ser determinantes neste sentido. No entanto, a coleta de dados *in loco* e por períodos mais longos favorece a oportunidade de identificar hábitos e mudanças nas preferências dos ocupantes ao longo do tempo.

Entre os estudos que analisaram a etapa de controle, constatou-se que a aprendizagem de máquina é utilizada com mais frequência em sistemas de climatização do que em sistemas de iluminação artificial, conforme mostra a Figura 11. Desde 2021, todos os trabalhos publicados a respeito do tema referem-se aos sistemas de climatização. Destaca-se que os sistemas de controle de persianas não eram o foco deste trabalho e, portanto, foram

considerados apenas os estudos que realizavam esta análise em paralelo com a dos demais sistemas.


Figura 11. Proporção dos trabalhos que utilizam aprendizagem de máquina nos sistemas de climatização, iluminação e persianas.



A duração dos estudos apresentou diferenças significativas, conforme mostra a Figura 12. Dentre os trabalhos de maior duração, três utilizaram simulação. Um deles consiste no estudo de três anos, que avaliou vários cenários do funcionamento dos sistemas de climatização, iluminação e persianas (Ouf; Park; Gunay, 2020). Os outros dois estudos que realizaram simulação foram o primeiro artigo encontrado com a temática desta revisão (Gunay *et al.*, 2014) e um artigo de conferência (Park; Nagy, 2020), ambos com duração igual a doze meses. Os demais implementaram e avaliaram o controle em sistemas reais (Gunay *et al.*, 2017, 2018; Sarkar; Nambi; Prasad, 2016). Nos estudos de menor duração, três foram analisados por meio de simulação (Carreira *et al.*, 2018; Deng; Chen, 2020; Laftchiev; Romeres; Nikovski, 2021). A maior vantagem da simulação nestes casos é a liberdade para analisar diversos cenários, testar diferentes estratégias e abordagens. Porém, não é possível avaliar o desempenho do sistema na presença de usuários reais no dia-a-dia, ou mesmo que o próprio usuário dê sua opinião sobre o funcionamento do sistema, indicando ou não satisfação e as razões associadas.

Observou-se também que grande parte dos trabalhos com duração inferior a um mês foram desenvolvidos em ambientes controlados (Jung; Jeoung; Hong, 2022; Laftchiev; Romeres; Nikovski, 2021; Lei *et al.*, 2022; Li *et al.*, 2021; Li; Zhang; Zhao, 2019; Zhang *et al.*, 2023) e que, dentre os estudos que solicitam voto dos usuários, apenas dois tiveram duração superior a 30 dias (Rajith; Soki; Hiroshi, 2018; Sarkar; Nambi; Prasad, 2016). Estima-se que isto esteja relacionado a possíveis incômodos ou desconfortos associados à necessidade frequente de participação dos usuários ou a presença dos pesquisadores e/ou equipamentos de monitoramento no ambiente.

Figura 12. Duração dos estudos que abordam o controle dos sistemas de iluminação e/ou climatização.



Outro aspecto importante a esse respeito é que os estudos de curta duração não permitem avaliar possíveis mudanças de preferências dos usuários associadas a sazonalidade, por exemplo, e a forma como isso pode afetar o desempenho dos sistemas de controle.

2.3.1. Aprendizagem de máquina aplicada ao controle centrado nas preferências do usuário

Identificou-se o uso de algoritmos de aprendizagem supervisionada, não-supervisionada e por reforço, além de trabalhos que utilizaram modelos matemáticos para realizar a aprendizagem dinâmica das preferências dos usuários. O Quadro 1 reúne os algoritmos utilizados e sua classificação quanto à forma de aprendizagem.

Quadro 1. Classificação dos algoritmos segundo os tipos de aprendizagem.

Aprendizagem supervisionada	
Algoritmo	Autor(es)
<i>Convolutional Neural Network</i> (CNN)	Baek <i>et al.</i> (2023), Chaudhuri <i>et al.</i> (2019), Ma e Pan (2021)
<i>Decision Tree</i> (DT) ¹	Aryal e Becerik-Gerber (2020), Cen, Cheng e Wong (2022), Choi e Yeom (2019), Ghahramani, Tang e Becerik-Gerber (2015), Jeoung et al. (2022), Jia <i>et al.</i> (2022), Katić <i>et al.</i> (2018), Katić, Li e Zeiler (2020), Ma e Pan (2021), Peng, Nagy e Schlüter (2019), Pigliautile <i>et al.</i> (2020), Salehi, Ghanbaran e Maerefat (2020), Yang <i>et al.</i> (2022), Yu <i>et al.</i> (2022), Intharachathorn, Jareemit e Watcharapinchai (2023), Aparicio-Ruiz <i>et al.</i> (2023)
<i>Discriminant Analysis</i> ²	Aryal e Becerik-Gerber (2019), Pigliautile <i>et al.</i> (2020), Yu <i>et al.</i> (2022)
<i>Ensemble Learning</i> ³	Cen, Cheng e Wong (2022), Jeoung et al. (2022), Jia <i>et al.</i> (2022), Salehi, Ghanbaran e Maerefat (2020), Yang <i>et al.</i> (2022)
<i>Gaussian Mixed Model</i> (GMM)	Ma e Pan (2021)
<i>k-Nearest Neighbors</i> (KNN) e <i>k-Neighbors Classifier</i> (KNC)	Aryal e Becerik-Gerber (2019), Aryal e Becerik-Gerber (2020), Cen, Cheng e Wong (2022), Cosma e Simha (2019), Ghahramani, Tang e Becerik-Gerber (2015), Li, Menassa e Kamat (2017), Pigliautile <i>et al.</i> (2020), Wang <i>et al.</i> (2023), Yang <i>et al.</i> (2022), Yu <i>et al.</i> (2022), Aparicio-Ruiz <i>et al.</i> (2023)
<i>Naive Bayes</i> (NB) e <i>Gaussian Naive Bayes</i> (GNB)	Aguilera, Toftum e Kazanci (2019), Peng, Nagy e Schlüter (2019), Pigliautile <i>et al.</i> (2020), Aparicio-Ruiz <i>et al.</i> (2023)
<i>Gaussian Process Regression</i> (GPR) e <i>Gaussian Process Classifier</i> (GPC)	Cosma e Simha (2019), Katić <i>et al.</i> (2018), Salehi, Ghanbaran e Maerefat (2020)

Quadro1 (continuação). Classificação dos algoritmos segundo os tipos de aprendizagem.

Aprendizagem supervisionada	
Algoritmo	Autor(es)
<i>Random Forest</i> (RF)	Aryal e Becerik-Gerber (2019), Aryal e Becerik-Gerber (2020), Cen, Cheng e Wong (2022), Chaudhuri <i>et al.</i> (2018b), Chaudhuri <i>et al.</i> (2019), Cosma e Simha (2019), Jayathissa <i>et al.</i> (2020), Jeoung et el. (2022), Jia <i>et al.</i> (2022), Jung, Jazizadeh e Diller (2019), Li, Menassa e Kamat (2017), Li, Menassa e Kamat (2018), Lu <i>et al.</i> (2019), Ma e Pan (2021), Morresi <i>et al.</i> (2021), Pigliautile <i>et al.</i> (2020), Shan <i>et al.</i> (2020), Wang <i>et al.</i> (2023), Yu <i>et al.</i> (2022), Zhang <i>et al.</i> (2022). Li <i>et al.</i> (2023a), Aparicio-Ruiz <i>et al.</i> (2023)
Redes neurais artificiais*. ⁴ (RNA)	Aguilera, Toftum e Kazanci (2019), Chaudhuri <i>et al.</i> (2018a), Chaudhuri <i>et al.</i> (2019), Deng e Chen (2020), Jeoung et el. (2022), Jia <i>et al.</i> (2022), Katić <i>et al.</i> (2018), Laftchiev, Romeres e Nikovski (2021), Ma e Pan (2021), Mandaric, Skocir e Jezic (2020), Peng, Nagy e Schlüter (2019), Rajith, Soki e Hiroshi (2018), Salehi, Ghanbaran e Maerefat (2020), Shan <i>et al.</i> (2020), Zhong e Choi (2017), Zhu <i>et al.</i> (2018), Li <i>et al.</i> (2023a)
Regressões linear (RL) e logística (RLog)	Cen, Cheng e Wong (2022), Ghahramani, Tang e Becerik-Gerber (2015), Gunay <i>et al.</i> (2017), Gunay <i>et al.</i> (2018), Jia <i>et al.</i> (2022), Jung, Jazizadeh e Diller (2019), Li, Menassa e Kamat (2017), Li <i>et al.</i> (2018), Li <i>et al.</i> (2021), Li, Zhang e Zhao (2019), Ouf, Park e Gunay (2020), Zhang <i>et al.</i> (2023)
<i>Support Vector Machine</i> (SVM) ⁵	Aryal e Becerik-Gerber (2019), Aryal e Becerik-Gerber (2020), Cen, Cheng e Wong (2022), Chaudhuri <i>et al.</i> (2018a), Chaudhuri <i>et al.</i> (2019), Cosma e Simha (2019), Ghahramani, Tang e Becerik-Gerber (2015), Jeoung et el. (2022), Jiang e Yao (2016), Jung, Jazizadeh e Diller (2019), Katić <i>et al.</i> (2018), Katić, Li e Zeiler (2020), Li, Menassa e Kamat (2017), Lu <i>et al.</i> (2019), Lu e Cochran Hameen (2021), Ma e Pan (2021), Morresi <i>et al.</i> (2021), Peng, Nagy e Schlüter (2019), Pigliautile <i>et al.</i> (2020), Wang <i>et al.</i> (2023), Yang <i>et al.</i> (2022), Yu <i>et al.</i> (2022), Li <i>et al.</i> (2023a), Aparicio-Ruiz <i>et al.</i> (2023)

Quadro 1 (continuação). Classificação dos algoritmos segundo os tipos de aprendizagem.

Aprendizagem não-supervisionada	
<i>Clusterização*</i>	Sadeghi <i>et al.</i> (2018), Sarkar, Nambi e Prasad (2016)
<i>k-means</i>	Carreira <i>et al.</i> (2018), Jayathissa et al (2020)
Aprendizagem por reforço	
<i>Branching Dueling Q-Network</i>	Lei <i>et al.</i> (2022)
<i>Q-Learning</i>	Cheng <i>et al.</i> (2016), Park <i>et al.</i> (2019a), Park e Nagy (2020)
<i>Reinforcement learning-based**</i>	Jung, Jeoung e Hong (2022)
Modelo matemático com atualização dinâmica	
Análise estatística dinâmica	Nagy <i>et al.</i> (2015), Nagy, Yong e Schlueter (2016), Ouf, Park e Gunay (2020)
Filtro de Kalman (FK)	Gunay <i>et al.</i> (2014)
Rede/ Classificação/ Inferência Bayesiana	Ghahramani, Tang e Becerik-Gerber (2015), Sadeghi <i>et al.</i> (2018), Xiong <i>et al.</i> (2020)

¹ Inclui: *Bagged Trees (Random Forest Bag + DT)*, *Boosted Trees (AdaBoost + DT)*, *Classification Tree (CT)*, *Extra Tree Classifier (ETC)* e *RUSBoosted Trees (RUSBoost + DT)*.

² Inclui: Linear, quadrática e variações.

³ Inclui: *Fit Regression Ensemble (FRE)*, *Gradient Boosting (GB)* e *Light Gradient Boosting Machine (LGBM)*.

⁴ Inclui: *Extreme Learning Machine (ELM)*, *Long Short-Term Memory (LSTM)*, *Multilayer Perceptron (MLP)*, *Nonlinear Autoregressive Neural Network (NAR)* e *Nonlinear Autoregressive Neural Network with Exogenous Inputs (NARX)*.

⁵ Inclui: *Support Vector Classifier (SVC)*.

*Algoritmo não nomeado de forma específica.

**Algoritmo de aprendizagem por reforço com adaptações.

De forma geral, a abordagem mais utilizada foi a aprendizagem supervisionada, presente em 49 dos 61 trabalhos. A aprendizagem por reforço e a não-supervisionada estiveram presentes em cinco e quatro trabalhos, respectivamente. Os modelos matemáticos foram encontrados em seis estudos. Em alguns casos, o modelo matemático foi combinado com o uso de aprendizagem supervisionada (Ouf; Park; Gunay, 2020) ou não-supervisionada (Sadeghi *et al.*, 2018). Em termos mais específicos, nos trabalhos com o objetivo de realizar inferências sobre as preferências ou conforto dos usuários, os algoritmos mais utilizados foram o RF (dezenove ocorrências), o SVM (dezesesseis ocorrências), a DT (onze ocorrências) e o KNN (dez ocorrências). Redes neurais artificiais também foram frequentemente utilizadas, sob diferentes configurações. Entre os estudos que abordaram controle dos sistemas de climatização e/ou iluminação, os algoritmos mais utilizados foram as redes neurais e a regressão logística, com sete e cinco ocorrências, respectivamente.

Considerando os algoritmos utilizados em cada tipo de sistema, observou-se que não há padrão para solucionar cada tipo de problema. Porém, identificou-se o uso de abordagens semelhantes em trabalhos subsequentes: análise estatística dinâmica (Nagy *et al.*, 2015; Nagy; Yong; Schlueter, 2016), regressão logística (Gunay *et al.*, 2017, 2018), *Q-learning* (Park *et al.*, 2019a; Park; Nagy, 2020), regressão linear (Li *et al.*, 2018, 2021; Li; Zhang; Zhao, 2019), SVM, KNN e RF (Aryal; Becerik-Gerber, 2019, 2020), *Boosted Trees*, *Bagged Trees* e SVM (Katić *et al.*, 2018; Katić; Li; Zeiler, 2020), SVM e RF (Chaudhuri *et al.*, 2018a, 2018b, 2019) e SVM (Lu *et al.*, 2019; Lu; Cochran Hameen, 2021).

Alguns autores avaliaram a qualidade do algoritmo utilizado por meio de medidas de desempenho como R^2 , *Mean Absolute Error* (MAE), *Mean Square Error* (MSE), *Root Square Mean Error* (RMSE), AUC, sensibilidade, especificidade, precisão, *F1-score* e acurácia.

Laftchiev, Romeres e Nikovski (2021) transformaram a medida de erro em graus, reportando que seu sistema era capaz de identificar, por meio de redes neurais, a temperatura adequada para o funcionamento do sistema de climatização com MAE de 0,5°C e RMSE igual a 0,6°C, valores que os autores consideraram adequados. Zhu *et al.* (2021) avaliaram o desempenho de uma rede neural na identificação da preferência de temperatura e classificação dos usuários de acordo com as mudanças de *setpoint*. Os autores utilizaram o MSE e encontraram erro de 0,28, atestando a qualidade dos resultados. As redes neurais também apresentaram bons resultados na inferência de votos de sensação térmica, com R^2 igual a 0,89 (Deng; Chen, 2020), na identificação das preferências de cenários de iluminação, com acurácia de 88,5% (Mandarić; Skocir; Jezic, 2020), e na inferência de conforto térmico, com acurácia igual a 89,2% (Shan *et al.*, 2020). Para a inferência de sensação térmica individual de cinco usuários, as redes neurais apresentaram acurácia variando entre 72,8% e 82,9% e sensibilidade de 68,3% a 89,4% (Zhong; Choi, 2017). Baek *et al.* (2023) utilizaram uma CNN para prever o conforto térmico de ocupantes a partir de imagens térmicas, e obtiveram acurácia de 96,0%.

A regressão linear foi utilizada para prever a sensação térmica e obteve R^2 de 0,94 (Li *et al.*, 2018). O mesmo tipo de inferência foi realizado a partir do C-SVC e do *Predicted Mean Vote* (PMV), com acurácias de 89,9% e 49,7%, respectivamente (Jiang; Yao, 2016). Em outros estudos, autores utilizaram o algoritmo RF e obtiveram acurácias de 80,0% (Li; Menassa; Kamat, 2017), 84,0% (Wu *et al.*, 2023), 92,8% (para homens) e 94,3% (para mulheres) (Chaudhuri *et al.*, 2018b). Na inferência quanto à preferência térmica, a acurácia do algoritmo atingiu 91,0% (Zhang *et al.*, 2022). Choi e Yeom (2019) utilizaram a árvore de decisão J48 para prever a satisfação térmica de dezesseis usuários. A acurácia do algoritmo variou com o tipo de dado de entrada, ficando entre 34,5% usando apenas o índice de massa corporal e 95,2%

utilizando temperaturas corporais e gênero. Em Intharachathorn *et al.* (2023), o desempenho da DT na previsão de sensação térmica de 32 usuários resultou em acurácia igual a 66,9%.

Aparicio-Ruiz *et al.* (2023) avaliaram o desempenho dos algoritmos RF, DT, SVM, KNN e NB quanto à inferência de sensação térmica após um ano de coleta de dados. Os autores verificaram a acurácia, sensibilidade, precisão e *F1-score* dos algoritmos. O melhor resultado foi obtido a partir do uso do RF, com acurácia e sensibilidade iguais a 59,1% e precisão igual a 56,9%. A DT, o SVM e o KNN alcançaram medidas de avaliação entre 51,6% e 56,3%. O pior desempenho foi obtido com o NB, com acurácia e sensibilidade iguais a 50,5% e precisão igual a 29,0%.

Li, Menassa e Kamat (2018) realizaram a inferência quanto ao conforto térmico de 12 usuários a fim de verificar a necessidade de aquecimento ou resfriamento. Utilizando o algoritmo RF, a acurácia individual para resfriamento e para aquecimento (separadamente) variou entre 82,1% e 95,5%. O modelo geral, unindo resfriamento e aquecimento, obteve acurácia média de 85,0%. Na inferência de sensação térmica personalizada, o RF atingiu acurácia média de 88,0%, mas no caso de múltiplos usuários, observou-se desempenho insatisfatório com acurácia de 54,4% (Jeoung *et al.*, 2022). Verificou-se, no entanto, que identificar a preferência de múltiplos usuários pode ser uma tarefa complexa independente do algoritmo utilizado. É o caso do estudo de Jia *et al.* (2022), que utilizaram GB, RF, RLog, DT e RNA para a inferência de sensação e conforto térmico de vinte usuários. A acurácia média dos modelos individuais variou de 73,1% (RLog) a 99,7% (RNA), enquanto a média geral permaneceu entre 30,1% e 52,5%. Nas inferências por gênero os autores alcançaram acurácias de 67,2% na inferência quanto à sensação térmica para os homens usando a DT e 48,8% na inferência quanto ao conforto térmico das mulheres usando o RF.

Conforme observado, o desempenho dos algoritmos varia conforme o conjunto de dados utilizado. Neste sentido, selecionar um algoritmo com base nos resultados de outros estudos não costuma ser adequado. Por isso, outros autores também optaram por testar diferentes algoritmos e comparar seu desempenho para eleger o mais adequado para o seu caso. O parâmetro de comparação utilizado por cada autor varia, especialmente de acordo com o conjunto de dados utilizado. Jung, Jazizadeh e Diller (2019), por exemplo, utilizaram a acurácia como parâmetro de escolha, apesar de também terem calculado o parâmetro F1-score. Os autores argumentam que a acurácia seria suficiente pois o conjunto de dados estava balanceado. Em seu trabalho, foram comparados os algoritmos RF, SVM e RLog para prever a preferência térmica de 32 usuários. A melhor acurácia foi obtida a partir do uso do RF, com valor médio de 97,0%, seguido da RLog (95,9%) e SVM (93,7%). A comparação de acurácias levou Peng, Nagy e Schlüter (2019) a descartar o uso dos algoritmos GNB e DT (acurácias de 90,0% e

96,0%, respectivamente) para identificar as preferências de temperatura dos usuários em seu estudo. Os outros dois algoritmos cogitados, no entanto, obtiveram acurácias iguais (C-SVC e MLP com 97,0%) e os autores basearam-se na estabilidade de cada um para realizar a escolha, optando pelo uso da rede neural.

No estudo de Cosma e Simha (2019), a melhor inferência quanto ao desconforto por calor dos 24 usuários se deu a partir dos algoritmos SVM e RF *Classifier*. Os autores avaliaram a qualidade das previsões por meio da acurácia, precisão e sensibilidade, obtendo valores de 87,7%, 90,0% e 88,0%, respectivamente, para os dois algoritmos. Também foram testados os algoritmos *Gaussian Process Classifier* e *k-Neighbors Classifier*, que obtiveram performances ligeiramente piores.

Chaudhuri *et al.* (2019) realizaram a inferência quanto ao conforto térmico de vinte usuários por meio dos algoritmos SVM, RF e CNN. A acurácia máxima foi obtida pelo RF (94,3%), seguido da CNN (93,3%) e do SVM (86,8%). Os autores ainda compararam com o PMV, cuja acurácia máxima foi 73,0%. Aryal e Becerik-Gerber (2019) estimaram a sensação e a satisfação térmica individual de usuários com os algoritmos RF, SVM, duas configurações de KNN e *Subspace Linear Discriminant*. Segundo os autores, todos os algoritmos apresentaram bom desempenho para ambas as predições, com acurácias acima de 85,0%. O melhor desempenho foi o do KNN, com acurácia de 94,0%. O modelo que combina sensação e satisfação apresentou resultados inferiores, mas o KNN se manteve com a acurácia mais alta que os demais, de 76,0%. Em outro estudo, os autores compararam os algoritmos RF, KNN, SVM e DT, também para inferir sensação e satisfação térmica (Aryal; Becerik-Gerber, 2020). Semelhantemente ao observado no trabalho anterior, o KNN apresentou melhor desempenho por uma pequena melhoria na acurácia, que foi de 90,0% e 94,0% para as inferências de sensação e satisfação, respectivamente.

Para identificar as preferências visuais dos usuários, Sadeghi *et al.* (2018) utilizaram dados de iluminância e uma combinação de Classificação Bayesiana com clusterização. Segundo os autores, o modelo é capaz de aprender as preferências de novos usuários com 80,1% de acurácia obtendo dezesseis amostras de suas preferências. Com 24 amostras, a acurácia atinge 83,4%.

O estudo de Yang *et al.* (2022) comparou o desempenho dos algoritmos DT, KNN, SVM e alguns algoritmos de *Ensemble Learning* para inferir sensação, preferência e conforto térmico individual. Os autores avaliaram acurácia, sensibilidade, precisão e F1-score. Foram apresentados os resultados de apenas dois usuários. De maneira geral, o algoritmo SVM apresentou o melhor resultado, com acurácia de 93,0%, 92,4% e 95,4% para a inferência de sensação, preferência e conforto térmico, respectivamente. Yu *et al.* (2022) também avaliaram

alguns algoritmos de *Ensemble Learning*, além do SVM, da DT, do KNN e da *Discriminant Analysis*. Os algoritmos foram avaliados sob diferentes configurações de hiperparâmetros com o objetivo de identificar o mais adequado para lidar com dados de equipamentos “profissionais” e de baixo custo. Após avaliar acurácia, sensibilidade, precisão e AUC, os autores concluíram que o melhor algoritmo para prever a sensação térmica dos usuários seria o KNN. No caso dos dados obtidos por equipamentos profissionais, atingiu-se acurácia de 83,6%, precisão de 89,0%, sensibilidade de 84,0% e AUC igual a 0,86. No segundo caso, obteve-se acurácia de 75,4%, precisão de 79,0%, sensibilidade de 82,7% e AUC igual a 0,87. Salienta-se que os hiperparâmetros utilizados para cada caso foram diferentes.

Li *et al.* (2023a) compararam o desempenho dos algoritmos SVM, RF e ELM para a previsão de sensação e conforto térmico durante o verão. Os dois últimos algoritmos apresentaram acurácias semelhantes, em torno de 88,0%. O SVM obteve 90,0% de acurácia e, após o processo de otimização, a medida subiu para 96,0%. Os autores também compararam com o desempenho do PMV, cuja acurácia foi de apenas 33,7%.

O SVM também apresentou o melhor desempenho na inferência quanto ao conforto térmico no estudo de Wang *et al.* (2023). O algoritmo apresentou acurácia de 95,8%, F1-score igual a 96,0% e AUC de 0,97. Também foram analisados os algoritmos KNN e RF, além da variação dos seus hiperparâmetros (incluindo o SVM). É interessante observar que, para algumas configurações do SVM, o desempenho da inferência foi pior que dos outros dois algoritmos por conta das características do conjunto de dados. Diante disso, é importante enfatizar a necessidade de conhecer o conjunto de dados com que se está trabalhando e utilizar as medidas de avaliação adequadas durante o processo de escolha do algoritmo.

Jeoung *et al.* (2022) compararam RF, SVM, DT, GB e RNA na inferência dos votos de sensação térmica individual e coletivamente. O algoritmo com melhor desempenho foi o GB, com acurácia média de 88,2% para a inferência personalizada e 55,8% com múltiplos usuários. O pior desempenho foi o do algoritmo SVM, com acurácia média individual de 51,2% e 28,3% para múltiplos usuários.

Há casos em que pode ser viável optar pelo algoritmo de menor acurácia. A comparação de acurácia dos algoritmos SVM (86,8%) e *Extreme Learning Machine* (79,7%) para a inferência quanto ao conforto térmico levaria à escolha do primeiro (Chaudhuri *et al.*, 2018a). No entanto, os autores argumentam que a velocidade de processamento do segundo algoritmo pode ser mais interessante na prática.

Lu *et al.* (2019) compararam os algoritmos SVM, RF e PMV na inferência quanto ao conforto térmico individual de dois usuários. Como medidas de avaliação, os autores utilizaram a precisão, sensibilidade e F1-score. O SVM apresentou o melhor resultado, atingindo 100%

em todas as medidas de avaliação para o modelo feminino e valores entre 95,0% e 97,5% para o modelo masculino. As medidas de avaliação do RF permaneceram entre 90,4% e 92,5%, enquanto para o PMV os valores ficaram entre 31,8% e 41,6%. Em seguida, Lu e Hameen (2021) optaram por analisar seus dados utilizando a sensibilidade como medida de avaliação. A decisão dos autores se baseou no desbalanceamento do conjunto de dados, que possuía mais dados de conforto e satisfação térmica do que o oposto. O algoritmo utilizado foi o SVM, que costuma apresentar melhor desempenho com este tipo de conjunto de dados. Em termos de modelos individuais, os resultados variaram significativamente conforme o ocupante (46,1% a 100,0% para a inferência de satisfação e 61,5% a 100,0% para a de sensação). Os modelos gerais por gênero atingiram sensibilidade entre 73,5% e 87,0%.

Para definir o melhor algoritmo para a inferência quanto à sensação térmica em seu estudo, Salehi, Ghanbaran e Maerefat (2020) compararam o R^2 e o MAE dos algoritmos DT, RNA, *Gaussian Process Regression* e *Fit Regression Ensemble*. O melhor desempenho foi do algoritmo *Gaussian Process Regression*, com R^2 igual a 0,85 e MAE igual a 0,53. O algoritmo apresentou erro máximo de 6% tanto para a inferência de sensação de calor quanto de frio. Para este caso, o PMV apresentou erro menor que 1% para a sensação de calor e 52% para a de frio.

Morresi *et al.* (2021) compararam SVM, RF e *Extra Tree Classifier* na inferência quanto ao conforto térmico de 23 usuários. O algoritmo RF apresentou o melhor desempenho, com acurácia média de 93,7%, seguido pelo *Extra Tree Classifier* (93,4%) e SVM (89,5%). Os autores também realizaram a validação conhecida como *leave-one-out*, testando também o uso de MLP, CNN e LSTM. O melhor resultado permaneceu sendo do RF, com MAE de 1,4 e MAPE de 24%.

Katic *et al.* (2018) utilizaram redes neurais (NARX e NAR), SVR, GPR, *Boosted Trees* e *Bagged Trees* para realizar inferência do conforto térmico individual de dois usuários. O melhor desempenho foi da rede NARX, com MSE entre 0,00029 e 0,00020 e RMSE entre 0,043 e 0,049. É interessante salientar que as configurações utilizadas para atingir o resultado ótimo para cada usuário foram diferentes, demonstrando a importância de avaliar diferentes algoritmos e configurações para cada conjunto de dados. Em trabalho subsequente, Katic, Li e Zeiler (2020) utilizaram a acurácia e AUC para avaliar o desempenho dos algoritmos SVM, *RUS Boosted Trees*, *Boosted Trees*, *Bagged Trees*. O melhor desempenho foi do SVM, com acurácia média de 80,0% e 87,0% para a inferência de conforto e sensação térmica, respectivamente. A AUC média mostrou-se consistente nos dois casos, segundo os autores, em torno de 0,80.

As mesmas medidas de avaliação foram utilizadas por Cen, Cheng e Wong (2022). Os autores buscaram prever sensação térmica, preferência de temperatura e velocidade do ar por

meio dos algoritmos RLog, SVM, DT, RF, *Extreme Gradient Boosting* e LGBM. Os três últimos apresentaram melhor desempenho. Em termos de análise individual, a acurácia média e AUC foram de 82,0%/0,92, 84,5%/0,92 e 80,7/0,91 para a inferência de sensação térmica, preferência de temperatura e velocidade de vento, respectivamente. Na análise em grupo, o melhor resultado para a inferência quanto à sensação térmica foi do RF (73,3%/0,89), enquanto o LGMB obteve os melhores resultados para a inferência quanto à temperatura e velocidade do ar preferidas (82,2%/0,92 e 77,7%/0,91).

Aguilera, Toftum e Kazanci (2019) utilizaram a AUC como índice para avaliar os algoritmos para a inferência quanto à preferência térmica dos usuários presentes em seus estudos. Os autores compararam a utilização de lógica *Fuzzy*, *Naive Bayes*, redes neurais e PMV. De forma geral, a melhor inferência foi realizada pelo NB, com AUC igual a 0,73, seguido pelo PMV, com 0,70. Os autores argumentam que o resultado se deve às características do NB, que consegue fazer inferências de forma satisfatória mesmo em conjuntos de dados desbalanceados, como era o caso.

Pigliautile *et al.* (2020) concluíram que o algoritmo mais adequado para prever a sensação térmica dos usuários em seu estudo seria o SVM, com 84,0% de acurácia, seguido por NB (82,0%), RF (79,0%), LDA (77,0%), DT (72,0%) e KNN (68,0%). O modelo proposto por Ghahramani, Tang e Becerik-Gerber (2015) atingiu acurácia de 70,1% e especificidade de 76,7% na inferência das preferências térmicas dos usuários. O uso da rede Bayesiana com aprendizagem online foi superior aos algoritmos KNN (64,8%, 68,6%), RLog (66,7%, 70,4%), DT (66,3%, 68,5%), SVM (63,5%, 69,4%) e também ao PMV, que obteve o pior resultado: 56,0% e 69,5% de acurácia e especificidade, respectivamente.

Para realizar a inferência quanto às preferências térmicas, visuais e acústicas de 30 usuários, Jayathissa *et al.* (2020) utilizaram uma combinação de *k-means* e RF. O primeiro foi utilizado para agrupar os ocupantes de acordo com suas preferências, enquanto o segundo foi usado para realizar as inferências. Os autores avaliaram as possibilidades e verificaram que o melhor modelo apresentou F1-score de 64,0%, 80,0% e 87,0% para as preferências térmica, visual e acústica, respectivamente. A acurácia das previsões para novos usuários ficou entre 72,0% e 87,0%.

Ma e Pan (2021) buscaram prever o conforto visual usando os algoritmos *Classification Tree*, RF, SVM e *Gaussian Mixed Model*. As medidas usadas para a avaliação foram acurácia, precisão, sensibilidade, F1-score e AUC. Os autores constataram que a melhor inferência se deu a partir do uso do RF, com acurácia entre 85,1% e 88,3%, precisão entre 85,0% e 88,0%, sensibilidade de 83,0% a 89,0%, F1-score entre 84,0% e 86,0% e AUC igual a 0,72.

Diante do observado, pode-se assumir que os algoritmos apresentaram resultados promissores, cada qual em seu contexto. A possibilidade de avaliar previamente o desempenho dos algoritmos por meio da acurácia é uma das vantagens deste tipo de abordagem. Ressalta-se que o desempenho dos algoritmos também pode ser influenciado pelo conjunto de dados utilizado. Neste sentido, é importante conhecer o conjunto de dados e identificar possíveis vieses na amostra por meio de medidas como sensibilidade, especificidade e precisão. É interessante destacar que a acurácia pode apresentar valores altos quando alguma das medidas de avaliação não está adequada, mas o oposto não acontece com frequência. Isto é, se o valor da acurácia for ruim, provavelmente as demais medidas não serão boas. Por fim, também é válido recorrer aos algoritmos que podem apresentar melhor desempenho em caso de conjuntos desbalanceados.

A preferência pelos algoritmos de aprendizagem supervisionada pode estar associada ao fato de que as preferências indicadas pelos próprios usuários podem ser tratadas como variáveis categóricas (muito quente, quente, neutro, frio, muito frio, claro, agradável, escuro). No caso da aprendizagem não-supervisionada, é o próprio algoritmo que “cria” as categorias (grupos ou *clusters*) e classifica os dados, isto é, não há uma referência do ponto de vista do usuário indicando determinadas condições ambientais como satisfatórias ou não. A aprendizagem por reforço, por sua vez, pode demandar grande quantidade de interações do usuário com as interfaces para atingir desempenho satisfatório. Ressalta-se, ainda, a necessidade de encontrar uma forma de ponderar as preferências dos usuários em ambientes compartilhados, a fim de encontrar o melhor cenário em termos de satisfação dos usuários.

2.3.2. Personalização dos sistemas de controle centrados no usuário

Esta seção apresenta as práticas mais comuns encontradas na literatura em termos de identificação e/ou distinção de usuários e de suas preferências.

2.3.2.1. Formas de detecção e identificação dos usuários

A forma de detecção dos usuários pode variar consideravelmente. Uma das dificuldades associadas a este tema é a violação de privacidade dos usuários. Observa-se que várias possibilidades foram exploradas, algumas visando distinguir os usuários, outras apenas contá-los ou detectá-los. Os dispositivos de detecção mais utilizados foram os sensores de movimento (Gunay *et al.*, 2017, 2018; Nagy *et al.*, 2015; Nagy; Yong; Schlueter, 2016; Peng; Nagy; Schlüter, 2019). Destaca-se, no entanto, que um dos principais problemas apontados nos

trabalhos que utilizam este tipo de tecnologia é a ausência de movimentos que ativem os sensores, pois as atividades desempenhadas em escritórios podem ser relativamente monótonas. Além disso, este tipo de monitoramento não é capaz de distinguir os usuários e, portanto, pode prejudicar o desempenho do sistema na personalização das condições de controle em ambientes com múltiplos usuários.

Os autores de trabalhos desenvolvidos em ambientes controlados puderam desenvolver seus experimentos levando em conta os dados dos usuários presentes no local (Aryal; Becerik-Gerber, 2020; Baek *et al.*, 2023; Cen; Cheng; Wong, 2022; Chaudhuri *et al.*, 2018a, 2018b, 2019; Choi; Yeom, 2019; Cosma; Simha, 2019; Jia *et al.*, 2022; Jiang; Yao, 2016; Jung; Jeoung; Hong, 2022; Jung; Jazizadeh; Diller, 2019; Katić *et al.*, 2018; Katić; Li; Zeiler, 2020; Laftchiev; Romeres; Nikovski, 2021; Lei *et al.*, 2022; Li; Menassa; Kamat, 2018; Li *et al.*, 2018, 2021; Li; Zhang; Zhao, 2019; Lu *et al.*, 2019; Lu; Cochran Hameen, 2021; Ma; Pan, 2021; Morresi *et al.*, 2021; Pigliautile *et al.*, 2020; Sadeghi *et al.*, 2018; Salehi; Ghanbaran; Maerefat, 2020; Shan *et al.*, 2020; Wang *et al.*, 2023; Yang *et al.*, 2022; Yu *et al.*, 2022; Zhang *et al.*, 2023, 2022; Zhong; Choi, 2017). Algo semelhante foi observado no trabalho de Rajith, Soki e Hiroshi (2018), que consideraram plena ocupação durante o desenvolvimento do estudo. Este tipo de decisão pode resultar na generalização dos modelos de preferência, que podem considerar dados de usuários que sequer estarão presentes durante o período de operação do sistema. Outros autores consideraram a interação dos usuários (com as interfaces dos sistemas ou a partir de votos) como sinal de presença, realizando a contagem dos indivíduos, mas sem distingui-los (Li; Menassa; Kamat, 2017; Zhu *et al.*, 2021). Alternativamente, verificou-se o desenvolvimento de interfaces em que os usuários pudessem se identificar e indicar suas preferências (Aguilera; Toftum; Kazanci, 2019; Aryal; Becerik-Gerber, 2019; Cheng *et al.*, 2016; Ghahramani; Tang; Becerik-Gerber, 2015; Xiong *et al.*, 2020).

Outras alternativas para a detecção e distinção de usuários são o uso da tecnologia *Bluetooth* (Deng; Chen, 2020; Jayathissa *et al.*, 2020; Park *et al.*, 2019a), a utilização da localização do *smartphone* (Jeoung *et al.*, 2022; Sarkar; Nambi; Prasad, 2016) e o uso de identificadores por radiofrequência (RFIDs) (Carreira *et al.*, 2018). Apesar de serem úteis para a distinção dos usuários, estes tipos de soluções dependem da participação direta dos usuários. Isso pode se tornar um problema se os usuários não forem devidamente orientados ou se não estiverem atentos à necessidade de estarem constantemente com seus dispositivos ou cartões RFID. Encontrou-se ainda o uso de fechaduras inteligentes para a detecção e distinção dos usuários (Mandaric; Skocir; Jezic, 2020). No entanto, os autores não especificam se isso se dá a partir de impressões digitais, cartões RFID ou outros.

Em alguns trabalhos que analisaram sistemas de controle centrados na preferência dos usuários por meio de simulação, observou-se o uso de modelos de ocupação e preferência disponíveis na literatura (Gunay *et al.*, 2014; Ouf; Park; Gunay, 2020; Park; Nagy, 2020; Wu *et al.*, 2023). As formas de detecção de usuários apresentadas até então podem apenas informar se há usuários presentes ou não (e algumas podem identificá-los). Entretanto, não são capazes de prever a ocupação em qualquer horizonte temporal. Para isso, seria necessário coletar dados por um período de tempo e utilizar algum algoritmo para realizar a previsão (Barrett; Linder, 2015).

Detectar a presença de um ou mais ocupantes é uma etapa fundamental para o funcionamento correto de um sistema de controle centrado no usuário. A partir dela, é possível verificar se existe ou não a necessidade de realizar ajustes na climatização e/ou iluminação no local. Nos trabalhos analisados, verificou-se que existem diferentes formas de realizar esta tarefa, cada uma com suas vantagens e desvantagens. Dar ao usuário a tarefa de informar sua presença pode conferir-lhe maior senso de responsabilidade e percepção de controle sobre o ambiente, mas também pode ser entendido como uma tarefa a mais que ele pode não estar disposto a realizar.

Identificar cada usuário é igualmente importante, pois permite que o sistema seja mais preciso com relação as condições ambientais que devem ser proporcionadas. Além disso, nos casos de ambientes com múltiplos usuários, a identificação dos que estão presentes possibilita a personalização das condições ambientais conforme a tolerância do grupo. Em outras palavras, a presença de um usuário mais sensível pode fazer com o que o sistema realize mais ações do que se houvessem apenas usuários tolerantes no ambiente. A realização deste tipo de ponderação, contudo, ainda é um desafio, conforme observado na seção 2.3.1.

2.3.2.2. Identificação e incorporação de preferências aos sistemas de controle

Zhu *et al.* (2023) argumentam que identificar as preferências de um ou mais usuários é uma tarefa complexa, uma vez que não é possível defini-las como um intervalo de parâmetros físicos estáticos. Por outro lado, formular um sistema que seja capaz de alterar dinamicamente seu funcionamento – incluindo continuamente dados de “preferência” – também pode não ser a melhor ideia, uma vez que as alterações podem estar mais ligadas a hábitos do que a preferências. Ainda não há consenso sobre uma forma ideal de identificar as preferências dos usuários para incorporar no funcionamento dos sistemas de controle. No entanto, o que se observa na literatura é que isso tem sido feito a partir do monitoramento da interação dos usuários com as interfaces do sistema ou por voto direto (questionários e/ou votos em escala).

A revisão dos estudos que utilizaram a aprendizagem de máquina na etapa de inferência das preferências dos usuários mostrou que os autores costumam utilizar o sistema de votos. Estima-se que, pelo fato de serem estudos conduzidos em ambientes controlados e em curtos períodos de tempo, esta pode ter sido a alternativa mais adequada encontrada pelos pesquisadores. Apenas dois estudos combinaram os votos com o monitoramento das interações (Lu; Cochran Hameen, 2021; Wang *et al.*, 2023).

Nos estudos que incluíram as preferências dos usuários no funcionamento de algum sistema de controle, a frequência da utilização das duas abordagens foi semelhante em termos quantitativos: quatorze trabalhos utilizaram os votos dos usuários e onze optaram por utilizar sua interação com as interfaces. Por outro lado, os trabalhos voltados para os sistemas de iluminação (Figura 13) tenderam a utilizar as interações dos usuários com as interfaces do sistema, enquanto os estudos direcionados aos sistemas de climatização (Figura 14) utilizaram os votos com maior frequência. Em ambos os casos, as informações coletadas costumam ser associadas com condições ambientais (temperatura interna e/ou externa, umidade, iluminância), dados fisiológicos ou pessoais (vestimenta, por exemplo) no momento da resposta.

Figura 13. Obtenção das preferências dos usuários em sistemas de iluminação.


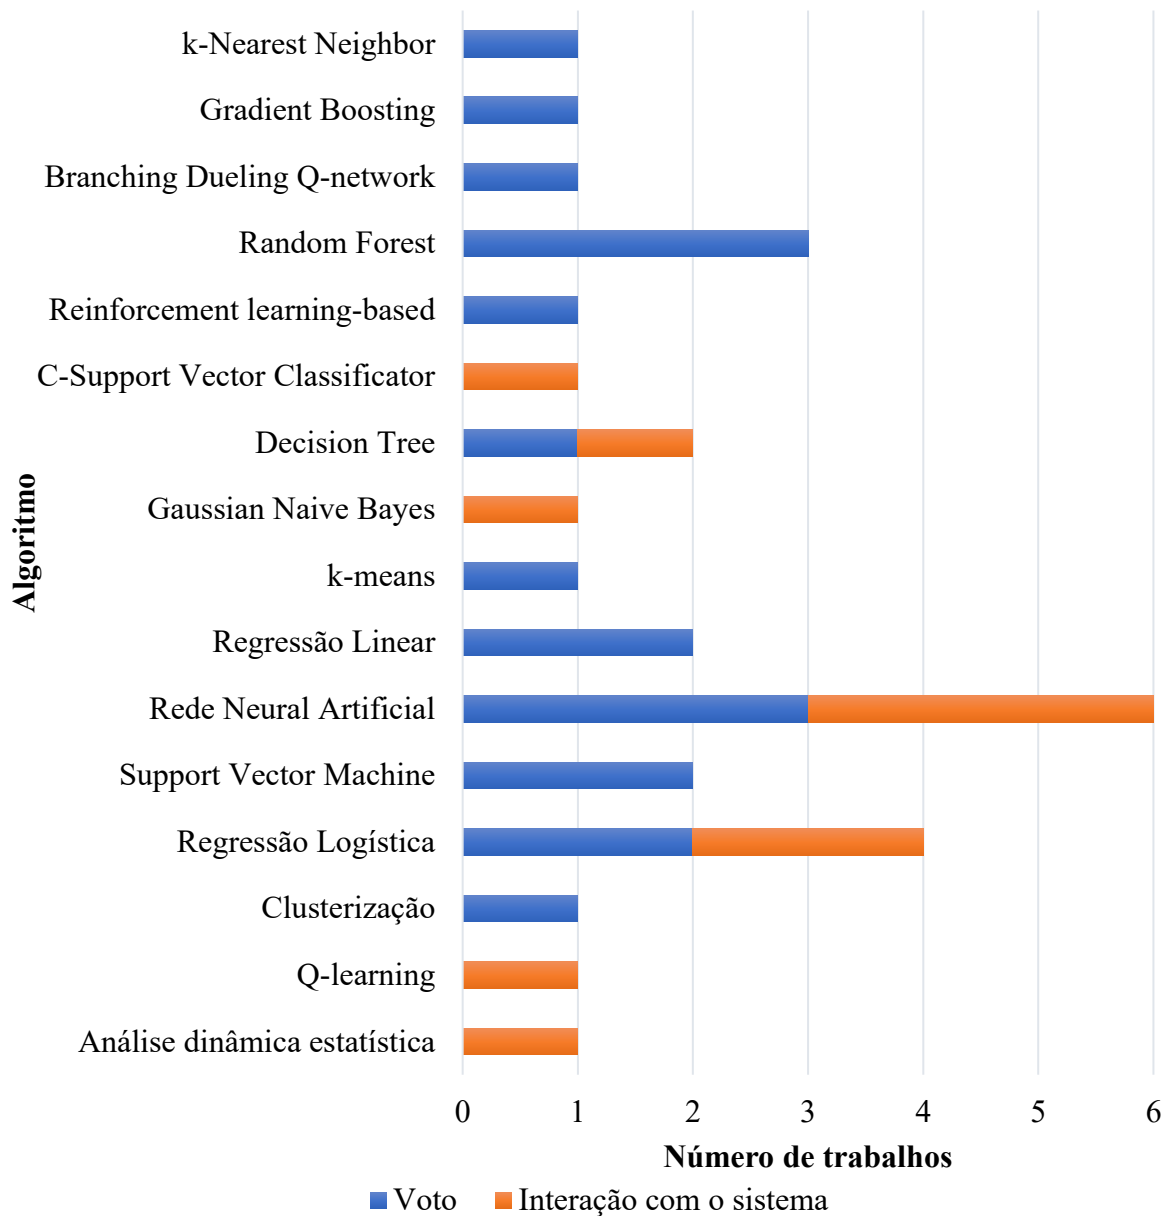


Figura 14. Obtenção das preferências dos usuários em sistemas de climatização.



As informações solicitadas pelos pesquisadores costumam ser em modelo de escala de conforto (como a proposta pela ASHRAE), no entanto, o tipo de informação pode variar. Alguns autores solicitam votos de sensação (Baek *et al.*, 2023; Chaudhuri *et al.*, 2018b, 2019; Deng; Chen, 2020; Jeoung *et al.*, 2022; Jiang; Yao, 2016; Jung; Jeoung; Hong, 2022; Li *et al.*, 2018; Li; Zhang; Zhao, 2019; Morresi *et al.*, 2021; Park; Nagy, 2020; Shan *et al.*, 2020; Yu *et al.*, 2022), enquanto outros optam por questionar preferência (Aguilera; Toftum; Kazanci, 2019; Ghahramani; Tang; Becerik-Gerber, 2015; Jayathissa *et al.*, 2020; Jung; Jazizadeh; Diller, 2019; Rajith; Soki; Hiroshi, 2018; Zhang *et al.*, 2023), conforto (Cosma; Simha, 2019; Lu *et al.*, 2019; Zhong; Choi, 2017), satisfação (Choi; Yeom, 2019) ou aceitabilidade (Mandarić; Skocir; Jezic, 2020). Há ainda os que solicitam várias destas informações:

- Conforto e satisfação (Aryal; Becerik-Gerber, 2020);
- Sensação e satisfação (Aryal; Becerik-Gerber, 2019; Li *et al.*, 2021; Lu; Cochran Hameen, 2021); sensação e preferência (Cen; Cheng; Wong, 2022; Li; Menassa; Kamat, 2017; Zhang *et al.*, 2022);
- Conforto e sensação (Katić *et al.*, 2018; Katić; Li; Zeiler, 2020; Wang *et al.*, 2023);
- Três ou mais fatores entre os supracitados (Lei *et al.*, 2022; Ma; Pan, 2021; Pigliautile *et al.*, 2020; Salehi; Ghanbaran; Maerefat, 2020; Yang *et al.*, 2022).

A coleta de múltiplas informações pode ser útil para comprovar a subjetividade da percepção de conforto. Há relatos na literatura de usuários que declararam sensação de conforto “neutra” e, ao mesmo tempo, estavam insatisfeitos com o ambiente (Aryal; Becerik-Gerber, 2019). Também é possível identificar a preferência do usuário oferecendo-lhe a opção de votar por aumentar ou diminuir a temperatura (Carreira *et al.*, 2018) ou mesmo em termos qualitativos, como “claro” e “escuro” (Cheng *et al.*, 2016). Sarkar, Nambi e Prasad (2016) solicitaram a preferência dos usuários sobre o ambiente térmico e visual em termos de “preferível”, “amigável”, “desconfortável” e “hostil”.

Em geral, a coleta dos votos é feita via *web*, aplicativo do *smartphone* ou *smartwatch*. Alguns autores solicitam o voto dos usuários em momentos ou intervalos de tempo determinado (Chaudhuri *et al.*, 2018a, 2018b; Cosma; Simha, 2019; Ghahramani; Tang; Becerik-Gerber, 2015; Jayathissa *et al.*, 2020; Jeoung *et al.*, 2022; Jia *et al.*, 2022; Jiang; Yao, 2016; Li *et al.*, 2018; Li; Zhang; Zhao, 2019; Pigliautile *et al.*, 2020; Sadeghi *et al.*, 2018; Salehi; Ghanbaran; Maerefat, 2020; Yu *et al.*, 2022; Zhang *et al.*, 2022; Zhong; Choi, 2017), enquanto outros os deixam livres para fazê-lo quando quiserem (Baek *et al.*, 2023; Jung; Jazizadeh; Diller, 2019; Morresi *et al.*, 2021; Shan *et al.*, 2020; Yang *et al.*, 2022). Sarkar, Nambi e Prasad (2016) constataram que, em média, 78% dos *feedbacks* indicaram conforto nos momentos em que o nível de iluminação foi ajustado por iluminação em excesso ou insuficiente. Pode-se supor, a partir desta informação, que os usuários somente lembram de informar que estão em conforto quando este é restaurado. Em estudos de curta duração, contudo, pode não ser interessante optar pelo *feedback* voluntário. Aguilera, Toftum e Kazanci (2019) relatam que o número de *feedbacks* decaiu ao longo dos dias do experimento. Devido ao curto intervalo de tempo para coletar dados suficientes para realizar inferências, por exemplo, o esquecimento dos usuários pode comprometer a qualidade dos resultados (Yang *et al.*, 2022).

De forma geral, verifica-se que os autores consideram que a ausência de votos significa que os usuários estão confortáveis (Li; Menassa; Kamat, 2017; Rajith; Soki; Hiroshi, 2018) ou, no mínimo, tolerando a condição ambiental em que se encontram (Ouf; Park; Gunay, 2020).

A mesma premissa é adotada pelos autores que monitoram a interação dos usuários com as interfaces dos sistemas, isto é, a interação do usuário com a interface (alterando a condição ambiental) é vista como uma tentativa de restabelecimento de conforto (Laftchiev; Romeres; Nikovski, 2021; Peng; Nagy; Schlüter, 2019). Gunay *et al.* (2014) verificaram que as interações com as interfaces do sistema de iluminação (artificial e persianas) reduziram em até 85% a partir da implementação do controle centrado no usuário. Em Park e Nagy (2020), a utilização da aprendizagem por reforço reduziu em cerca de 40% das interações indicando “muito quente”. Neste sentido, à medida que os usuários interagem com o sistema, estão, indiretamente, indicando sua preferência em relação ao ambiente.

Na prática, é possível observar que os usuários contestam (isto é, sobrescrevem) as ações do sistema quando estas não os satisfazem. Ao coletar dados para identificar as preferências de iluminação dos ocupantes, Xiong *et al.* (2020) verificaram que mais de 10% das alterações no ambiente foram contestadas. No trabalho de Gunay *et al.* (2017), os usuários contestaram entre 6% e 8% dos desligamentos de lâmpadas realizados pelo sistema a fim de restabelecer a condição anterior. Em Nagy, Yong e Schlueter (2016), o percentual de contestações foi de 23,6% e 12,6% para os desligamentos e acionamentos, respectivamente. Utilizando regressão logística, Gunay *et al.* (2018) observaram – durante o período de controle automático – entre uma interação a cada três semanas e uma interação a cada 25 semanas. O uso de redes neurais permitiu a Peng, Nagy e Schlüter (2019) reduzir as mudanças de *setpoint* de quatro a nove por mês para uma a cinco no mesmo período de tempo. Lu e Hameen (2021) mostraram ser possível reduzir o número de contestações à medida que o algoritmo SVM aprendia os votos e as contestações dos usuários.

A necessidade de identificar as preferências dos usuários fica evidente ao observar que alguns percebem o ambiente escuro por volta dos 140lx (Nagy *et al.*, 2015), enquanto outros o fazem aos 200lx e outros, ainda, com mais de 400lx de iluminância (Cheng *et al.*, 2016). Neste sentido, realizando ajustes na iluminação a partir de votos de “claro” ou “escuro”, o sistema de Cheng *et al.* (2016) alcançou 92% dos votos de satisfação acima de 4 em escala sétima. A incorporação dos votos dos usuários no controle do sistema de climatização aumentou em 11% a aceitabilidade térmica (Lei *et al.*, 2022). Comparando o funcionamento dos sistemas com o controle manual, foram observadas reduções no nível de desconforto entre 10,9% (Jung; Jeoung; Hong, 2022) e 53,7% (Li; Menassa; Kamat, 2017). Em Jeoung *et al.* (2022), o voto de sensação térmica em escala sétima foi de 0,7 (mantendo uma temperatura fixa no sistema de controle) para 0,4 utilizando o algoritmo de inferência de sensação térmica, reduzindo em 33% os votos de desconforto. O sistema de Li, Zhang e Zhao (2019), que utilizou o *feedback* dos usuários para realizar o ajuste da temperatura recebeu nota 5,56 (em uma escala de satisfação

de 1 a 7). Em estudo similar, Li *et al.* (2021) verificaram que o voto de satisfação média foi de 4,61 para o cenário com temperaturas de operação fixas, 5,20 com o controle de temperatura baseado no *feedback* dos usuários e 5,30 com o controle baseado na inferência de temperatura. A comparação com modelos clássicos da literatura também demonstra a vantagem dos sistemas de controle personalizados. Zhong e Choi (2017) obtiveram 84,7% de probabilidade de conforto utilizando redes neurais para a inferência do conforto dos usuários, enquanto com o PMV este percentual foi de 64,7%.

A forma de interação dos usuários também pode fornecer informações relevantes. Usuários mais sensíveis tendem a interagir mais com as interfaces e fornecer mais *feedbacks* do que usuários tolerantes (Ouf; Park; Gunay, 2020). Neste caso, é importante que os algoritmos tenham capacidade de aprender com rapidez. Adicionalmente, usuários que solicitam mudanças mais drásticas (por exemplo, alterações de 5°C na temperatura de *setpoint*) costumam ser caracterizados como mais radicais do que conservadores (mudança de 1°C) (Zhu *et al.*, 2021). A inclusão da preferência de múltiplos usuários nos sistemas de controle pode ser um desafio, como evidenciado por Deng e Chen (2020). Para um único ocupante, os autores conseguiram reduzir o desconforto em 100%, reduzindo gradativamente o percentual até atingir 85% de melhoria com cinco ocupantes. Neste sentido, a estratégia de classificar usuários em perfis, sugerida por Zhu *et al.* (2021), pode ser útil.

No entanto, o trabalho de Wu *et al.* (2023) mostra a importância do cuidado com as generalizações, isto é, de como é necessário ter em mente a subjetividade do conforto de cada indivíduo e seu nível de tolerância. Os autores realizaram um experimento com um grupo de usuários utilizando um sistema de controle baseado em votos de conforto, sensação e aceitabilidade de outro grupo de pessoas. Apesar do voto médio de sensação térmica ter permanecido entre $\pm 0,5$, houve votos de “extremamente desconfortável”, “inaceitável” e “totalmente inaceitável”. O estudo de Mandaric, Skocir e Jezic (2020) também evidencia esta necessidade. Ainda que 86,37% dos ajustes de iluminação tenham recebido notas 3 e 4 (em uma escala de 1 a 4) em cenários de um único ocupante, na presença de mais de um ocupante houve um decréscimo de notas 4 e alguns usuários reportaram que deixariam o ambiente naquelas condições de iluminação. No estudo de Park *et al.* (2019a), dois dos cinco usuários optaram por manter o sistema de controle automático de iluminação desligado durante praticamente todo o estudo, fazendo os ajustes de forma manual. Em outro estudo, os autores obtiveram relatos de um usuário que afirmou não considerar o controle automático importante e que a iluminação de tarefa seria a melhor alternativa para o problema da iluminação (Nagy; Yong; Schlueter, 2016).

Diante do contexto apresentado, é importante salientar que identificar as preferências dos usuários e incluí-las em um sistema de controle não tornará, necessariamente, o ambiente

mais confortável ou os usuários mais satisfeitos. A situação pode ser ainda mais complexa em ambientes compartilhados. Ainda que os dados não indiquem impactos negativos no conforto depois da implementação dos sistemas, a análise individual de *feedback* pode mostrar usuários significativamente insatisfeitos. O descontentamento, nestes casos, pode se dar por falta de controle percebido, dificuldade de compreensão sobre o funcionamento do sistema ou por não considerar que sua implementação seja importante. Nestes cenários, é comum que o usuário se declare insatisfeito com o funcionamento do sistema e até mesmo o boicote (Nagy *et al.*, 2015; Park *et al.*, 2019a). Day e Gunderson (2015) relatam que os usuários que recebem treinamento acerca do sistema de controle são mais propensos a se sentirem satisfeitos com o ambiente do que aqueles que não receberam o devido treinamento. Desta forma, para que os sistemas possam ser avaliados corretamente é necessário considerar todo o contexto em que o usuário está inserido, buscando novas medidas e formas de avaliação não apenas em termos de conforto, mas também para a avaliação da satisfação com o sistema de controle.

2.3.3. Impacto no consumo de energia

O trabalho de Ouf, Park e Gunay (2020) demonstra, por meio de simulações, que o aumento ou redução do consumo de energia está intimamente ligado às configurações do sistema de controle. Estas, por sua vez, dependem diretamente do perfil do usuário. De acordo com os autores, a associação deste tipo de sistema personalizado com usuários tolerantes costuma resultar em economia de energia, enquanto usuários mais sensíveis costumam induzir o sistema a um aumento do consumo de energia elétrica. Peng, Nagy e Schlüter (2019) observaram variações no potencial de economia de energia entre 4,0% e 25,0% em quatro escritórios distintos, utilizando a mesma abordagem, devido as diferenças nos perfis dos usuários.

Ao implementar um sistema adaptativo utilizando um filtro de Kalman, Gunay *et al.* (2014) observaram que o consumo de energia reduziu cerca de 13,0% em relação ao controle manual. Jeoung *et al.* (2022) também compararam o desempenho do sistema ao controle manual e encontraram diferença de 27,0% utilizando o algoritmo *Gradient Boosting*.

Comparando o controle adaptativo com o de *setpoint* fixo, observa-se diferenças mais expressivas, como o de Gunay *et al.* (2014) e o de Zhang *et al.* (2023) que atingiram 35,0%. Outros autores obtiveram resultados positivos ao comparar sistemas adaptativos com os sistemas automáticos comuns, que operam por rotina ou *setpoint* fixo. Cheng *et al.* (2016) e Lei *et al.* (2022) utilizaram aprendizagem por reforço e verificaram potencial de economia de energia de 10,0% e 13,9%, respectivamente. Utilizando técnicas de clusterização, Sarkar, Nambi e Prasad (2016) alcançaram entre 27,0% e 39,0% de economia de energia. Li, Zhang e

Zhao (2019) utilizaram regressão linear para encontrar potencial de economia diária de até 13,8% usando o controle baseado no *feedback* da sensação térmica. Em Li *et al.* (2021), os autores verificaram que o controle baseado na inferência de sensação térmica poderia proporcionar economia de energia cerca de 10% maior em comparação ao obtido no trabalho anterior.

Apesar de serem comuns, os sistemas de controle que operam com *setpoint* fixo podem contribuir para o aumento do consumo de energia (Hellwig; Schweiker; Boerstra, 2020). A fim de evitar situações que possam causar desconforto aos usuários, tais sistemas costumam operar com parâmetros mais “conservadores” (por exemplo, mínimo de 500 lux). No entanto, se os usuários possuem preferência (ou até mesmo tolerância) para ambientes mais escuros, como se vê na literatura (140lx em Nagy *et al.* (2015)), pode haver desperdício de energia. Tal situação foi observada por Gunay *et al.* (2014). Ao comparar o consumo de energia durante a operação manual do sistema de iluminação e de persianas com o controle automático operado com *setpoint* fixo, os autores descobriram que haveria um aumento, no segundo caso, pouco maior que 30%.

Este tipo de situação evidencia a necessidade de identificar as condições em que os usuários se sentem satisfeitos e/ou quais desconfortos são capazes de suportar até decidirem realizar uma ação sobre o ambiente. Ainda que nem sempre os usuários estejam dispostos a abrir mão do conforto em vista da economia de energia (Nagy; Yong; Schlueter, 2016), Malavazos *et al.* (2015) afirmam que alguns usuários toleram pequenos desconfortos para evitar o inconveniente de ir até o interruptor. Neste sentido, os sistemas de controle capazes de operar a partir das preferências dos usuários têm apresentado resultados promissores.

Zhong e Choi (2017) encontraram, utilizando redes neurais, potencial de economia de energia de 9,3% comparando com o consumo baseado na zona de conforto dada pelo método do PMV. Também a partir de redes neurais, Rajith, Soki e Hiroshi (2018) encontraram potencial de economia de energia entre 20% e 40% evitando desperdícios e sem comprometer a satisfação dos usuários. Carreira *et al.* (2018) também encontraram potencial de economia de energia dentro deste intervalo. Os autores verificaram que, utilizando o algoritmo *k-means* e os votos dos usuários no controle do sistema de climatização, seria possível economizar cerca de 26% de energia elétrica, mantendo mais de 70% dos usuários em conforto térmico. A estimativa de economia encontrada por Chaudhuri *et al.* (2019) usando o RF variou entre 16,0% e 34,4%. Nagy *et al.* (2015) propuseram modos de operação favorecendo o conforto ou a economia de energia. Quando comparados ao caso base, cuja única estratégia de eficiência é apagar todas as lâmpadas após as 19h, o modo conforto apresentou redução de 23,2% e o modo de economia de energia reduziu em 37,9% o consumo com energia elétrica. Por outro lado, a implementação

do controle adaptado às preferências dos usuários provocou aumento do consumo de energia em alguns ambientes de curta permanência, como uma sala de impressão. Os autores verificaram que os usuários tinham o hábito de entrar e sair da sala sem acionar o sistema de iluminação artificial. Portanto, associar um sensor de presença ao acionamento das lâmpadas – ainda que de acordo com as preferências dos usuários – não resultou em economia de energia.

Diante disso, salienta-se que o potencial de economia de energia está associado ao perfil dos usuários, conforme já mencionado. Da mesma forma que os usuários podem optar por desligar o controle automático por preferirem o controle manual, seus hábitos podem influenciar diretamente no consumo de energia. Estes fatos reforçam a ideia de que é necessário observar o contexto em que o sistema de controle centrado no usuário seria implementado a fim de obter resultados mais satisfatórios.

2.4. Síntese do capítulo

O capítulo de revisão da literatura serviu de base para compreender os conceitos associados às edificações e aos sistemas de controle centrados no usuário, identificando os pontos mais abordados nos estudos e quais ainda necessitam de contribuições.

A seção 2.1 abordou aspectos gerais acerca das edificações centradas no usuário, salientando que a automação dos sistemas em prol da eficiência energética pode não satisfazer o ocupante. Tendo em vista as vantagens da automação adaptativa (Ahmadi-Karvigh *et al.*, 2017), indicou-se a importância de identificar as condições ambientais mais confortáveis e/ou preferidas conforme os usuários e incluí-las no controle automático dos sistemas. Apresentou-se, ainda, a aprendizagem de máquina como forma de identificar as preferências dos usuários.

A seção 2.2, tratou dos principais conceitos a respeito dos algoritmos de aprendizagem de máquina. Descreveram-se brevemente as principais abordagens e suas formas de avaliação. Em seguida, foram apresentados os principais algoritmos utilizados na identificação das preferências dos usuários, bem como suas medidas de avaliação.

A utilização da aprendizagem de máquina como ferramenta para identificar as preferências dos usuários foi apresentada na seção 2.3. Verificou-se que esta abordagem foi aplicada para a inferência de diferentes aspectos do conforto térmico e visual dos usuários. A literatura apresenta o uso de diferentes algoritmos para prever conforto, sensação, preferência, satisfação, entre outros. Foram encontrados estudos limitados à realização de inferência e também trabalhos que avaliaram a etapa de controle baseado nestas previsões. A comparação entre os resultados, no entanto, pode não ser justa, pois cada situação apresenta particularidades

que influenciam no desempenho dos algoritmos. A síntese das características de cada trabalho pode ser encontrada no Apêndice A.

Observou-se que a maior parte dos estudos de inferência foi realizada em ambientes controlados e duraram apenas algumas horas. Os trabalhos direcionados ao controle dos sistemas tiveram duração relativamente maior. Em ambos os casos, a abordagem supervisionada apresentou maior número de ocorrências. *Decision Tree*, *k-Nearest Neighbors*, redes neurais artificiais, *Random Forest* e *Support Vector Machine* foram os algoritmos mais recorrentes.

Em termos de desempenho, frequentemente utilizou-se validação cruzada e a medida de avaliação mais comum foi a acurácia. Além disso, foram avaliadas a precisão dos modelos, sensibilidade e outras medidas que auxiliam a verificação da qualidade das predições. De forma geral, os algoritmos alcançaram bons resultados dentro do contexto em que foram apresentados, especialmente nos casos de conforto individual. No caso de múltiplos usuários, verifica-se que existe maior dificuldade em ponderar as preferências de todos os usuários (ou, ao menos, dos mais exigentes). Salienta-se, no entanto, que a validação cruzada ou com subconjuntos aleatórios pode não representar um cenário real, com atualização constante do conjunto de dados.

A identificação das preferências dos usuários deu-se a partir da solicitação de votos e/ou do monitoramento das suas interações com as interfaces dos sistemas. Observou-se que a utilização de votos foi mais recorrente nos trabalhos realizados em ambientes controlados. O monitoramento das interações dos ocupantes mostrou que estes contestam as ações do sistema automático quando estas não lhe são agradáveis.

Enquanto nos estudos de inferência a qualidade da inferência foi avaliada pela qualidade do modelo, nos estudos de controle foi possível questionar os usuários. Em geral, os autores obtiveram avaliações positivas, mas verificaram que é importante avaliar cada caso individualmente. Neste contexto, fica evidente que é importante considerar não apenas as preferências dos usuários em termos ambientais, mas também do nível de controle que desejam ter sobre o ambiente em que estão.

Por fim, observou-se ser possível economizar energia a partir do controle centrado nas preferências dos usuários, mas esta não é uma consequência intrínseca da sua implementação. O fator determinante neste sentido é o perfil do ocupante. Portanto, se o objetivo do sistema de controle centrado no usuário é proporcionar conforto, a economia de energia não deve direcionar as regras de controle.

A partir da revisão de literatura, verificou-se que a aprendizagem de máquina é uma ferramenta útil e eficaz no contexto do controle centrado no usuário. A escolha do algoritmo

mais adequado costuma basear-se nas características do conjunto de dados e nas medidas de avaliação, obtidas por meio de validação cruzada. No entanto, ao implementar um sistema de controle real, é preciso ter em mente que as preferências dos usuários podem mudar. Em outras palavras, o conjunto de dados será completamente diferente após um determinado tempo e, portanto, as medidas de avaliação do algoritmo podem não ser as mesmas. Portanto, também seria necessário verificar o comportamento dos resultados após a atualização dos dados. Neste sentido, este trabalho visa desenvolver um método que possibilite tal avaliação em um cenário realístico. Desta forma, pretende-se evitar que o sistema não seja capaz de se adaptar às mudanças de preferências dos usuários após sua implementação.

3. Método

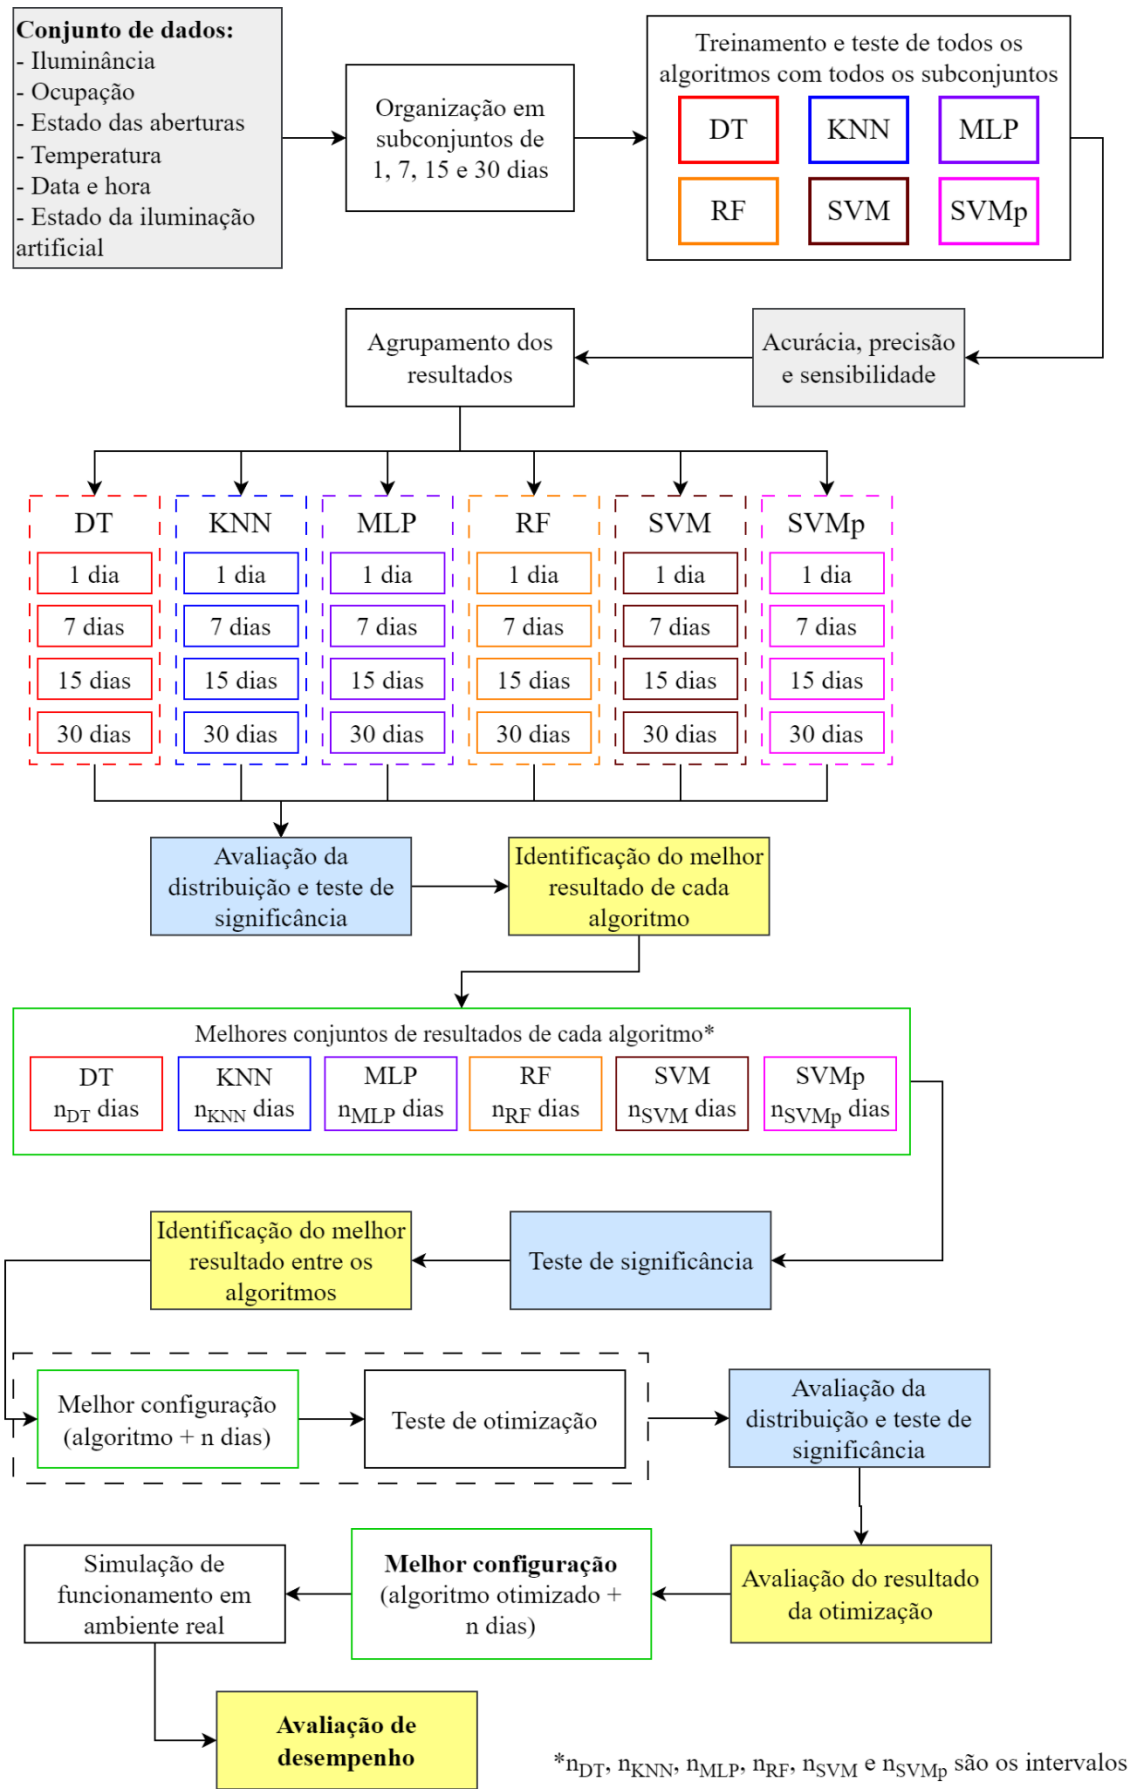
Este capítulo apresenta o método utilizado para alcançar os objetivos propostos neste trabalho. O fluxograma das etapas do método pode ser visto na Figura 15. Para avaliar o desempenho de diferentes algoritmos, foram coletados dados de iluminância, ocupação e estado do sistema de iluminação artificial, todos estes associados ao horário e dia da verificação. Os dados foram coletados por meio de um sistema de aquisição de dados em um laboratório de pesquisa (cujas atividades desempenhadas assemelham-se as de um escritório). Um questionário foi aplicado visando obter informações gerais sobre o ambiente e os usuários. A identificação das preferências do usuário baseou-se no princípio – também adotado na literatura – de que os usuários interagem com as interfaces do sistema visando manter e/ou restaurar sua sensação de conforto ou condição ambiental preferida. Neste sentido, os dados de monitoramento da ocupação e do estado do sistema de iluminação foram usados para identificar as condições preferidas dos usuários. Por outro lado, as informações obtidas com o questionário foram úteis para caracterizar o local e os usuários.

O período de coleta ocorreu entre junho de 2022 e fevereiro de 2023. Os dados coletados passaram por um pré-processamento e foram criados 914 diferentes subconjuntos contendo dados de 1, 7, 15 ou 30 dias para o treino dos algoritmos e a mesma quantidade de dias para o teste. A seleção dos algoritmos foi realizada com base na revisão da literatura, e estes foram testados com todos os subconjuntos de dados. Após cada teste, foram calculadas a acurácia, precisão e sensibilidade dos modelos, a fim de verificar a qualidade das predições.

Os resultados foram agrupados por algoritmos e quantidade de dias de treino e teste. Verificou-se o tipo de distribuição dos resultados e testes de significância foram realizados, a fim de garantir que os grupos tivessem diferenças significativas entre si. Desta forma, foi possível identificar a quantidade de dias de treino que favorecia o aumento da acurácia para cada algoritmo. Em seguida, foram comparados os melhores cenários, isto é, as medidas de avaliação de cada algoritmo treinados com a quantidade de dados “ideal” encontrada na etapa anterior. Após realizar o teste de significância com estes cenários, foi possível encontrar o algoritmo com o melhor desempenho para o caso em questão.

A fim de realizar a otimização do modelo, verificou-se a possibilidade de utilizar apenas um ponto de referência de iluminância, ao invés de dois. Três modelos foram avaliados (um com duas referências de iluminância e dois com uma referência), comparados estatisticamente e a configuração ideal pode ser selecionada. Por fim, um teste com atualização do subconjunto de dados simulou o desempenho do algoritmo em um ambiente real com atualização diária da aprendizagem.

Figura 15. Fluxograma geral do método.



3.1. Aquisição de dados

Este trabalho baseou-se na premissa de que os usuários buscam atingir a sensação de conforto a partir da interação com as interfaces do sistema de iluminação. Esta premissa foi adotada por outros autores na literatura, conforme apresentado na seção 2.3.2.2. Neste contexto, esta seção apresenta o procedimento de coleta de dados ambientais e de usuários, aprovado pelo Comitê de Ética da UFSC sob o parecer nº 5.120.398.

3.1.1. Sistema de coleta de dados

Para realizar a avaliação dos diferentes algoritmos, criou-se um conjunto de dados que relaciona o estado do sistema de iluminação artificial com as diversas configurações de ocupação. Foram coletados os seguintes dados:

- Iluminância (natural e artificial em conjunto): medida em lux;
- Ocupação: todas as chegadas e saídas dos usuários;
- Estado da iluminação artificial: quais conjuntos de lâmpadas estão acesos e/ou apagados;
- Temperatura do ar: medida em graus Celsius;
- Estado das aberturas: quais estão abertas e/ou fechadas;
- Data e hora: no formato dd/mm/aaaa; hh:mm:ss.

A coleta de dados foi realizada por meio de um sistema de aquisição de dados. Os equipamentos utilizados na montagem deste sistema estão listados no Quadro 2.

Quadro 2. Equipamentos utilizados na montagem do sistema de aquisição de dados.

Equipamento	Finalidade e informações importantes
Arduíno UNO	Microcontrolador.
Arduíno MEGA	Microcontrolador.
BH1750	Sensor de iluminância; Resolução: 1lx (lux); Faixa de medição: 1 - 65535lx; Baixa variação de medição: +/- 20%.
BMP280	Sensor de temperatura; Faixa de temperatura -40 - 85°C; Precisão temperatura: ±1.0°C.

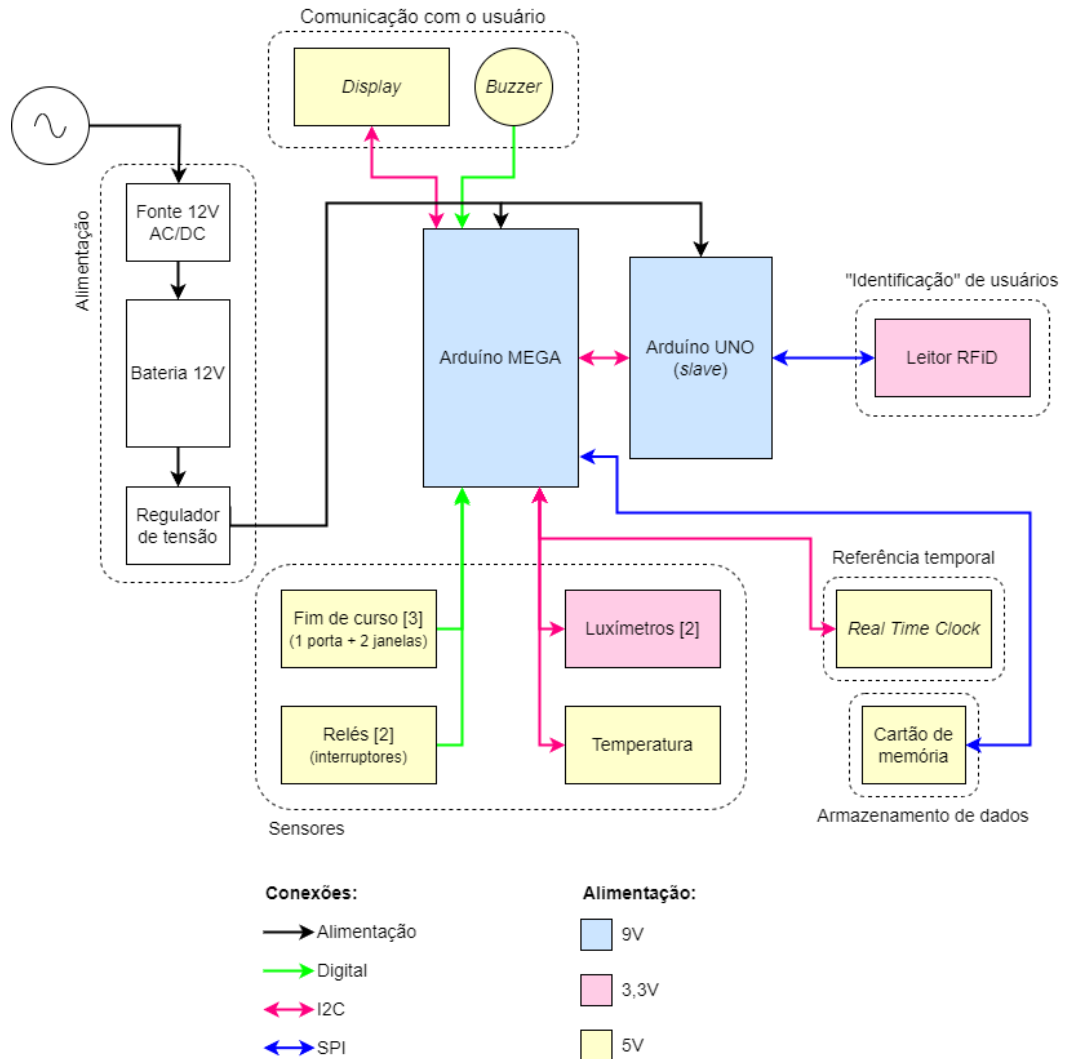
Quadro 2 (continuação). Equipamentos utilizados na montagem do sistema de aquisição de dados.

Equipamento	Finalidade e informações importantes
DS3231	Relógio em tempo real; Acurácia: ± 2 ppm de 0 - 40°C; Acurácia: ± 3.5 ppm de -40 - 85°C.
Display LCD	Comunicação com o usuário
KW12-3	Sensor de fim de curso para identificação do estado das aberturas; Velocidade de operação: 0,1mm – 1m/s; Frequência de operação mecânica: 400 vezes por minuto; Frequência de operação elétrica: 30 vezes por minuto.
MFRC522	Leitura do cartão RFID, indica a presença do usuário; Interface SPI.
Módulo cartão micro SD	Armazenamento de dados no cartão de memória; Interface SPI.
Módulo I2C e conectores	Comunicação entre os componentes e o microcontrolador.
Relé	Indicação do acionamento de cada interruptor.

O esquema de conexão dos equipamentos pode ser observado na Figura 16. A ideia de utilizar o sistema proposto baseia-se na sua relativa simplicidade e baixo custo, além de ser independente da existência de um sistema de controle central.

No primeiro mês, os dados foram coletados em intervalos de dois minutos, a fim de identificar mudanças bruscas de iluminância. Contudo, essa configuração foi alterada no mês seguinte, por questões técnicas. A coleta de dados passou a ser feita em intervalos de cinco minutos, isto é, a cada cinco minutos o sistema identifica a iluminância no momento, os conjuntos de lâmpadas que estão acesos ou apagados e se há usuários no ambiente (e quem são, pelo uso do cartão RFID). Entre junho de 2022 e fevereiro de 2023, cada uma destas verificações foi armazenada juntamente com o dia e o horário da medição.

Figura 16. Esquema de ligação dos equipamentos do sistema de aquisição de dados.



No início do estudo, os usuários receberam um cartão RFID e foram instruídos a utilizá-lo a cada chegada e saída para informar o sistema sobre sua presença. Cada cartão RFID possui um código único (Figura 17). Desta forma, o sistema foi capaz de identificar a presença (ou ausência) de cada usuário, armazenando esta informação junto com as demais variáveis ambientais.

O sistema foi instalado em um laboratório no Centro de Ciências, Tecnologias e Saúde (CTS) da Universidade Federal de Santa Catarina (UFSC), em Araranguá. A Figura 18 mostra o sistema instalado no local.

Figura 17. Cartões RFID distribuídos aos usuários do local.




Figura 18. Sistema de aquisição de dados em funcionamento.

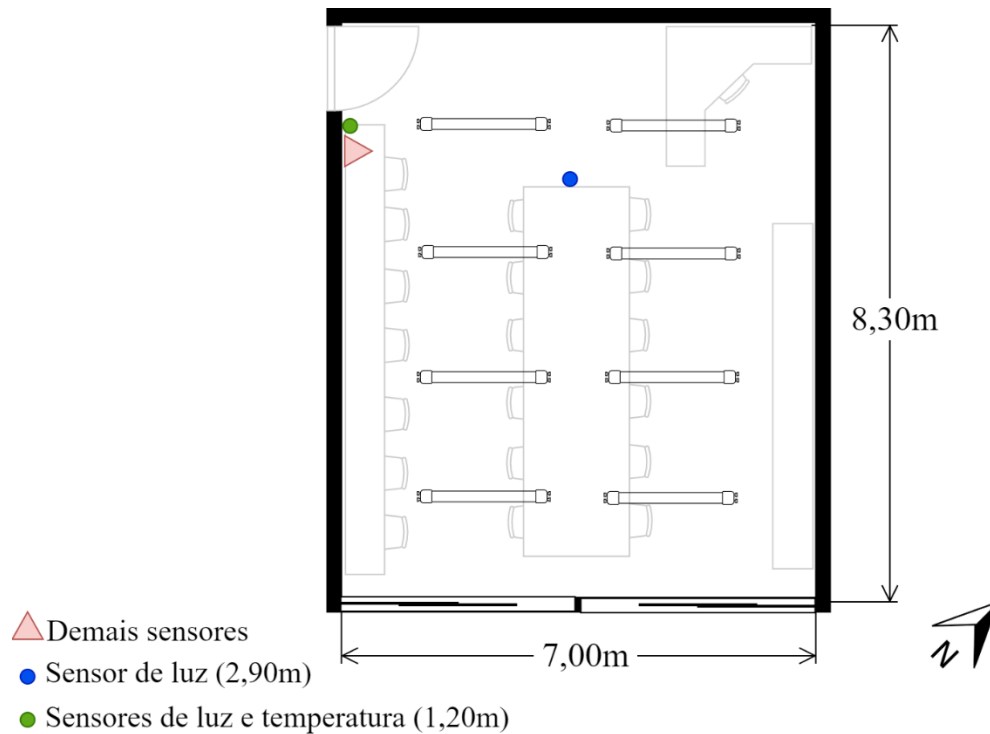


O laboratório possui funcionamento semelhante ao de um escritório, com atividades de leitura, escrita e no computador. A ocupação no ambiente varia ao longo do dia, conforme os horários dos 25 estudantes que fazem parte do laboratório. Além disso, em determinadas ocasiões, os ocupantes desenvolvem robôs para participar de competições, permanecendo mais tempo no laboratório (inclusive no período da noite).

A Figura 19 mostra a planta baixa do ambiente, com o posicionamento das aberturas, luminárias e os locais onde foram instalados os equipamentos. Foram instalados dois sensores

de iluminância, em locais onde se acreditaria obter leituras significativamente diferentes. Estima-se que o sensor posicionado no teto sofre menos influência da iluminação artificial e dos possíveis efeitos de concentração da luz natural. Neste sentido, deve-se verificar se algum posicionamento apresenta melhores resultados na etapa de aprendizagem ou se os dados podem ser complementares.

Figura 19. Planta baixa do ambiente com múltiplos ocupantes.



3.1.2. Questionário

Neste trabalho, optou-se por identificar as condições ambientais preferidas dos usuários a partir do monitoramento das suas interações com o sistema de iluminação. Um questionário foi elaborado com o intuito de verificar algumas características gerais do ambiente e dos usuários.


O questionário foi aplicado via *Google Forms*, após o início do funcionamento do sistema de aquisição de dados. Os estudantes foram instruídos a identificar-se utilizando apenas o código do seu cartão RFID, mostrados na Figura 17. A primeira pergunta diz respeito ao tempo que os usuários permanecem no laboratório. Neste caso, os ocupantes poderiam decidir por opções pré-determinadas:

- Até 10h semanais;
- Entre 11h e 20h semanais;
- Entre 21h e 30h semanais;

- Entre 31h e 40h semanais;
- Mais de 40h semanais.

Para as demais informações, a fim de evitar possíveis erros de interpretação, decidiu-se elaborar afirmações e solicitar aos ocupantes seu nível de concordância com cada uma delas. Para isso, utilizou-se a escala Likert, mostrada na Figura 20.

Figura 20. Escala Likert, utilizada para responder ao questionário.



As informações solicitadas foram:

1. Sua principal tarefa é realizada no computador.
2. Sua principal tarefa é de leitura e escrita (em papel).
3. Você tem interesse em tecnologias de automação e controle dos sistemas das edificações.
4. Você faz esforço para economizar energia, sempre que possível.
5. Você sacrifica seu conforto para economizar energia.
6. Você prefere iluminação natural do que artificial.
7. Você aciona a iluminação artificial apenas quando considera que não há luz natural o suficiente para desempenhar o seu trabalho.
8. Você desliga a iluminação artificial quando está muito claro.
9. Você desliga a iluminação artificial quando deixa o ambiente por períodos longos.
10. Você considera importante ter um sistema de iluminação artificial automatizado.
11. Você prefere um sistema automático que acione as luzes para você.
12. Você prefere um sistema automático que apague as luzes para você.
13. Você costuma usar a ventilação natural como mecanismo de restauração do conforto térmico.
14. Você está satisfeito com as condições de iluminação do seu ambiente de trabalho.

15. Você está satisfeito com a quantidade de luz natural no seu ambiente de trabalho.
16. Você está satisfeito com a quantidade de luz artificial no seu ambiente de trabalho.
17. Em seu ambiente de trabalho, você sofre com ofuscamento (brilho excessivo e incômodo).
18. Você consegue resolver o problema do ofuscamento com cortinas. (Caso não haja ofuscamento, não é necessário responder esta questão)
19. Você se sente confortável sob as condições de iluminação do seu ambiente de trabalho.
20. Você está satisfeito com as condições térmicas do seu ambiente de trabalho.
21. Você está satisfeito com a qualidade da ventilação natural no seu ambiente de trabalho.
22. Você está satisfeito com a qualidade da climatização artificial do seu ambiente de trabalho.
23. A incidência de radiação solar direta no seu ambiente de trabalho lhe incomoda.
24. Você se sente confortável sob as condições de climatização do seu ambiente de trabalho.
25. Você considera importante ter controle sobre a iluminação no seu ambiente de trabalho.
26. Você sente que tem controle sobre a iluminação no seu ambiente de trabalho.
27. Você considera importante ter controle sobre a climatização no seu ambiente de trabalho.
28. Você sente que tem controle sobre a climatização no seu ambiente de trabalho.

As informações obtidas a partir das respostas não devem ser usadas para o treinamento dos algoritmos. No entanto, devem ser úteis para explicar possíveis questionamentos que possam surgir nas etapas seguintes, como a de seleção de características mais relevantes.

3.2. Pré-processamento de dados

Esta etapa consiste em preparar, organizar e estruturar os dados coletados pelo sistema descrito na seção 3.1. O pré-processamento dos dados foi realizado em Python 3.8.17, com a biblioteca Pandas 2.0.3. Inicialmente, as informações de data e hora foram separadas. Desta forma, foi

possível extrair as informações individualmente para utilizar no treinamento dos modelos, pois a ocupação tende a ser menor aos finais de semana. Além disso, pode haver usuários durante o período da noite. Neste sentido, a extração das informações de forma individual pode ser útil para os algoritmos.

Em seguida, realizou-se uma busca por discrepâncias ou inconsistências que pudessem prejudicar as etapas seguintes, por exemplo:

- Dados anômalos;
- Eventos que prejudiquem o funcionamento adequado do sistema de coleta de dados (cobrir permanentemente o sensor de luz, por exemplo).

O arquivo com os dados pré-processados passou a ter 38 colunas, das quais 25 referem-se aos usuários. As variáveis correspondentes a cada uma das informações estão descritas no Quadro 3. A iluminância foi medida em lux e a temperatura em °C.

Quadro 3. Variáveis do arquivo de dados pré-processado.

Variável	Descrição	Tipo da variável
data_ano	Ano em que a amostra foi coletada	Inteiro
data_mes	Mês em que a amostra foi coletada	Inteiro
data_dia	Dia em que a amostra foi coletada	Inteiro
data_hora	Hora em que a amostra foi coletada	Inteiro
data_minuto	Minuto em que a amostra foi coletada	Inteiro
data_dia_da_semana	Dia da semana em que a amostra foi coletada	Inteiro
iluminancia_caixa	Iluminância no sensor localizado na estação de medição	Inteiro
iluminancia_teto	Iluminância no sensor localizado no teto do ambiente	Inteiro
temperatura	Temperatura ambiente	Flutuante
porta	Estado da porta do ambiente	Booleano
janela1	Estado da janela 1 do ambiente	Booleano
janela2	Estado da janela 2 do ambiente	Booleano
usuario_X	Indicação de presença do usuário no ambiente	Booleano
output	Estado dos dois conjuntos de lâmpadas	Inteiro

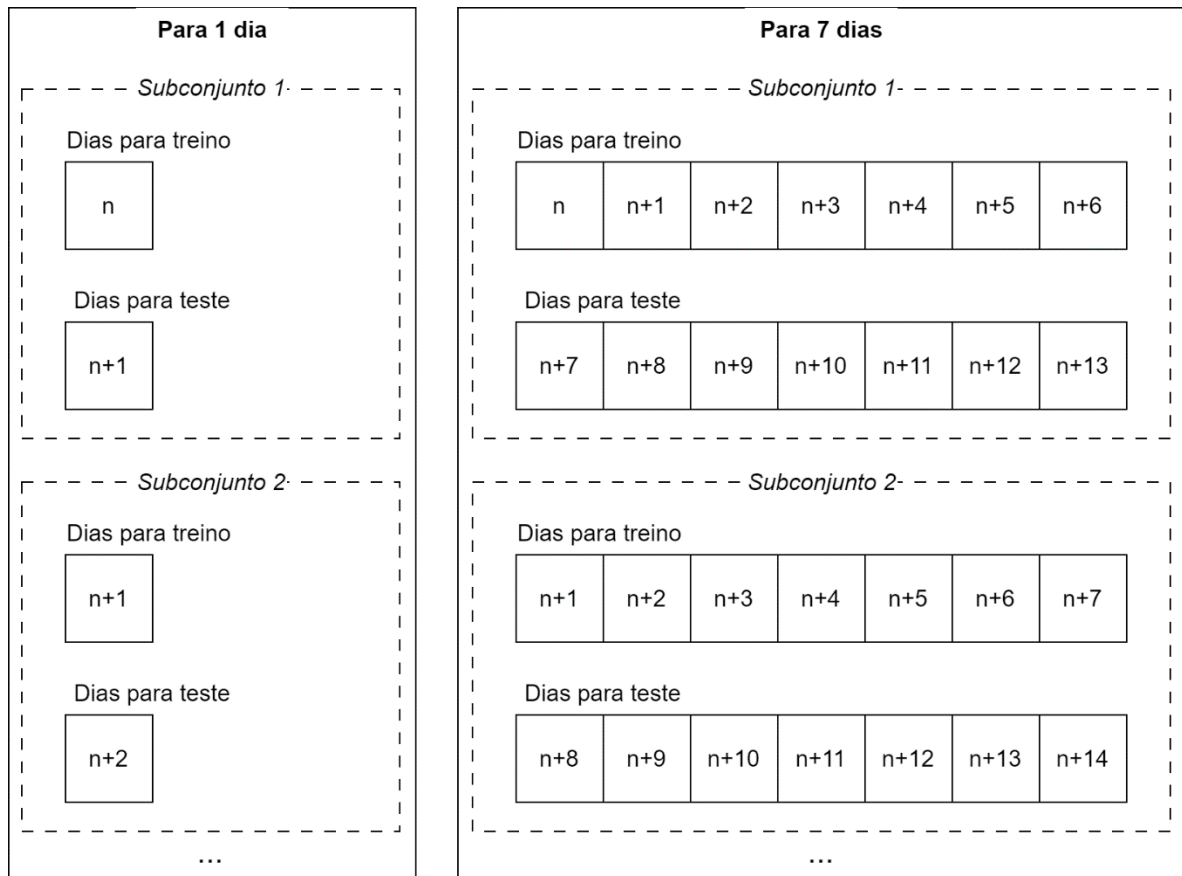
O conjunto de dados foi organizado em subconjuntos, conforme o exemplo da Figura 21. O primeiro subconjunto de dados continha o primeiro dia (n) do conjunto de dados completo para ser usado para o treino e o dia seguinte (n+1) para o teste do algoritmo. O segundo subconjunto continha o dia n+1 para treino e o dia n+2 para teste. O mesmo procedimento foi repetido até chegar ao último dia do conjunto de dados completo. Tomando novamente o conjunto de dados completo, repetiu-se o procedimento para criar subconjuntos de 7, 15 e 30 dias (com quantidades iguais de dias para treino e teste dos algoritmos). A fim de exemplificar

o que foi feito, a Tabela 3 mostra os períodos a que se referem os primeiros subconjuntos de 1 dia.

Tabela 3. Primeiros subconjuntos de 1 dia.

Subconjunto	Dia selecionado para treinamento	Dia selecionado para teste
1	07/06/2022	08/06/2022
2	08/06/2022	09/06/2022
3	09/06/2022	10/06/2022
...

Figura 21. Organização dos dados em subconjuntos.



As 38 características presentes nos subconjuntos de dados descrevem a condição do ambiente em um determinado momento, incluindo quais usuários estão presentes. Neste sentido, é interessante que os subconjuntos de dados sejam compostos por todas as 38 características. Desta forma, os algoritmos terão o máximo de informação possível sobre o ambiente e os usuários para poder realizar as inferências sobre o sistema de iluminação.

3.3. Análise de desempenho dos algoritmos

Os subconjuntos de dados resultantes da seção 3.2 foram utilizados nesta etapa, a fim de avaliar o desempenho dos algoritmos selecionados, que foram os cinco com maior ocorrência da literatura. Observou-se que todos eram algoritmos de aprendizagem supervisionada, o que pode ser justificado pelas características da abordagem, isto é, o usuário é quem determina a saída adequada para cada condição de entrada. Os algoritmos selecionados foram:

- *Decision Tree*: com profundidade máxima (*max_depth*) igual a três. Para medir a qualidade das ramificações, utilizou-se o parâmetro *Gini Impurity*.
- *k-Nearest Neighbors*: com *k* igual a cinco e todos os pontos da vizinhança possuindo pesos iguais.
- Rede Neural Artificial: do tipo *Multilayer Perceptron*, com duas camadas ocultas. A primeira e a segunda camada possuem cinco e dois neurônios, respectivamente. O *lbfgs* foi o método de otimização de pesos utilizado.
- *Random Forest*: com profundidade máxima igual a três e 100 “árvores na floresta”. Para avaliar a qualidade das ramificações, utilizou-se a função *Gini*.
- *Support Vector Machine*: do tipo SVC, com *kernel* linear e $C = 1$.

No caso do SVM, foi realizado um teste adicional utilizando o SVMp. Desta forma, foi possível verificar se a atribuição de pesos às classes traria alguma melhoria ao desempenho do algoritmo.

Todos os experimentos foram realizados com os algoritmos implementados pela biblioteca *Scikit-Learn 1.3.0*, que contém vários algoritmos já implementados. Isto facilita a criação de modelos, pois não é necessário programar todo o algoritmo, apenas ajustar os parâmetros de interesse (Pedregosa *et al.*, 2011). Foram mantidos os valores padrão para os parâmetros que não foram especificados. Os algoritmos utilizados estão disponíveis em repositório *online*¹.

A partir disso, foi possível classificar os dados, determinando quatro possíveis saídas (classes) para cada entrada:

- Classe 0 – todas as lâmpadas ligadas;
- Classe 1 – um conjunto de lâmpadas ligado e o outro desligado;
- Classe 2 – um conjunto de lâmpadas desligado e o outro ligado;
- Classe 3 – todas as lâmpadas desligadas.

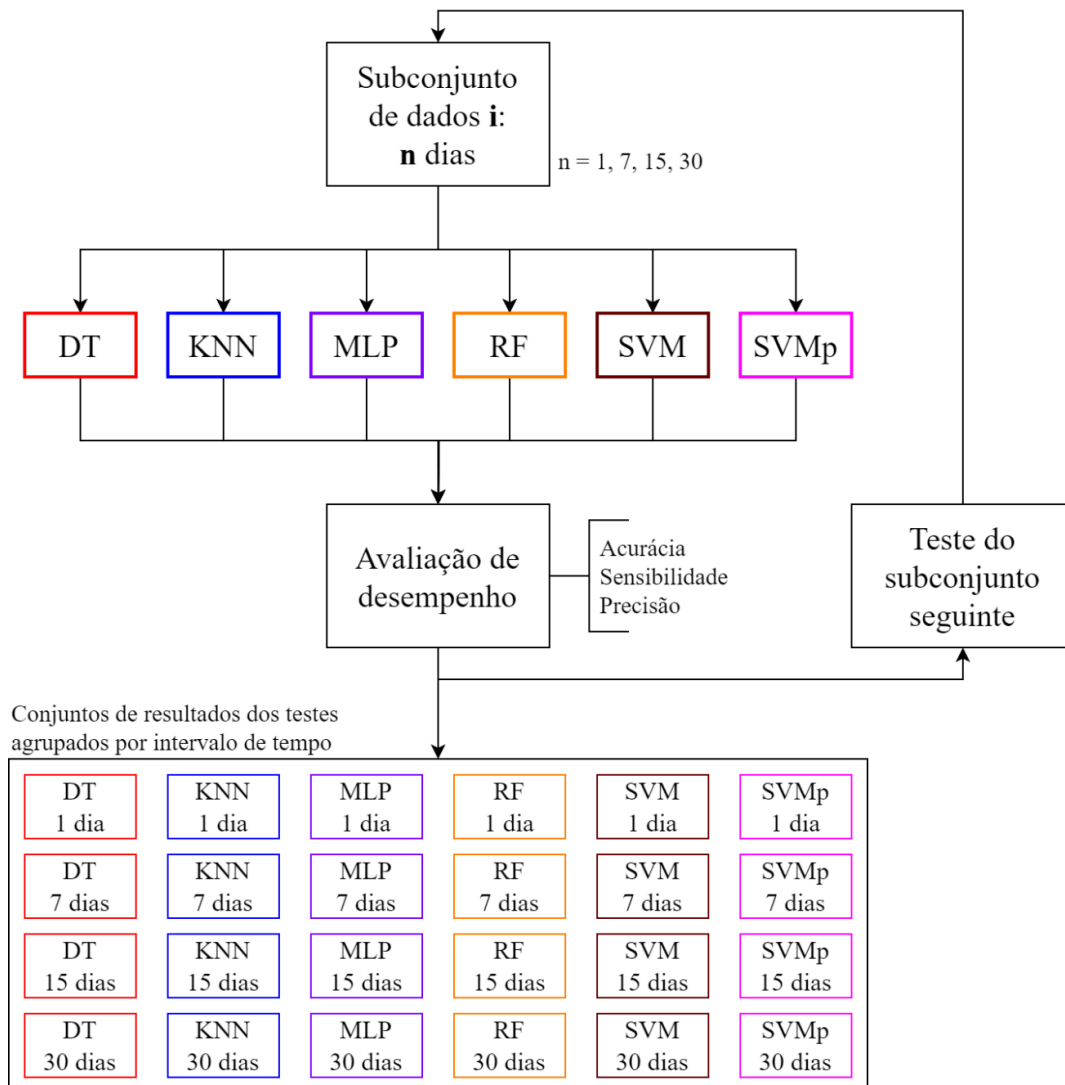
¹ https://github.com/thayanebilesimo/occ_predicting-lighting-system-state

Salienta-se que, mesmo que haja quatro classes, foi mantido o valor de k igual a cinco para o KNN, pois a recomendação para este algoritmo é que se evite números pares de vizinhos.

3.3.1. Seleção do subconjunto de dados

Os experimentos foram realizados com todos os subconjuntos de 1, 7, 15 e 30 dias. No caso do subconjunto de 1 dia, o primeiro dia da amostra serve para treinamento e o dia seguinte para teste. O mesmo procedimento foi adotado com os demais subconjuntos, conforme mencionado anteriormente. A Figura 22 mostra um fluxograma desta etapa de testes.

Figura 22. Esquema da primeira etapa de testes.



Para cada teste, o desempenho dos algoritmos foi avaliado por meio da acurácia (Equação 3). No entanto, dada a possibilidade de a amostra estar desbalanceada, também foram verificadas as medidas de sensibilidade (Equação 4) e precisão (Equação 6). Ao final deste

processo, foram obtidos 24 conjuntos de resultados contendo acurácia, precisão e sensibilidade de cada teste realizado.

O programa Statistica v.10 foi utilizado para obter as estatísticas descritivas de cada conjunto e avaliar a normalidade dos conjuntos de acurácia. A primeira estatística avaliada foi a mediana. Com isso, foi possível verificar a tendência do comportamento dos algoritmos sem tanta influência de possíveis valores extremos, especialmente em casos de distribuição não-normal. Esta verificação permite, também, identificar algoritmos com desempenho consideravelmente insatisfatório antes da execução das etapas posteriores propostas neste método.

A normalidade dos dados foi verificada por meio de uma modificação do teste de Kolmogorov-Smirnov, proposta por Lilliefors, também chamada de Teste de Lilliefors. Este teste retorna um p-valor que indica a possibilidade de aceitar ou rejeitar a hipótese de que a distribuição é normal. Adotou-se um nível de significância de 5%, isto é, se o p-valor for menor que 0,05, pode-se considerar que a distribuição é não-normal.

A natureza dos dados determina o teste de variância a ser aplicado. No caso de distribuições normais, pode-se usar o teste t para verificar se há diferenças significativas entre os conjuntos. Caso a distribuição das acurácias seja não-normal, o teste de Mann-Whitney pode ser utilizado. Ambos os testes podem ser realizados por meio do programa Statistica. O nível de significância adotado foi de 5%. Caso o valor de p para o teste seja menor do que 0,05, pode-se rejeitar a hipótese de semelhança entre os conjuntos de resultados. A partir da conclusão de que há diferenças significativas entre as amostras, ou seja, que a quantidade de dias para treino e teste afeta o resultado obtido, pode-se comparar os conjuntos e identificar qual intervalo de dias leva ao melhor desempenho de cada algoritmo. Nesta etapa, as comparações foram feitas por algoritmo, resultando em seis matrizes semelhantes à apresentada na Tabela 4.

Tabela 4. Matriz de p-valores a ser construída a partir do teste de variância.

Número de dias	1	7	15	30
1	-	p	p	p
7	p	-	p	p
15	p	p	-	p
30	p	p	p	-

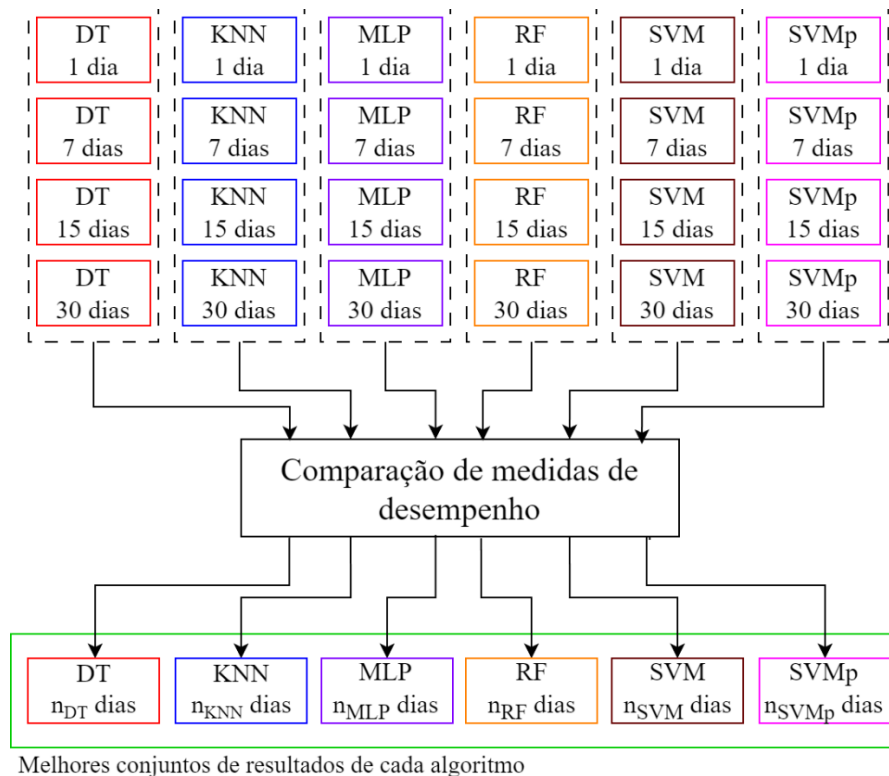
Nos casos em que foram identificadas diferenças significativas entre os conjuntos, os valores médios de acurácia e desvio padrão foram os primeiros a ser comparados. Decidiu-se adotar este procedimento também para os casos de distribuição não-normal, em que a estatística

de tendência central comumente usada é a mediana, pois a ocorrência de valores extremos inferiores (mesmo que sejam considerados espúrios para a estatística) pode afetar significativamente a satisfação e o conforto dos usuários da edificação. A média, por ser uma estatística mais afetada pelos valores extremos, pode ser uma opção mais adequada para este caso, se analisada juntamente com o desvio padrão.

Para exemplificar a justificativa supracitada, pode-se considerar o seguinte cenário: o conjunto de resultados de um algoritmo obteve mediana de 99%. Contudo, a distribuição dos dados foi não-normal, e houve a ocorrência de dias em que a acurácia foi de 5%. Neste caso, ainda que a mediana do conjunto de dados possa ser considerada ótima, nos dias em que a acurácia for igual a 5% o algoritmo errará 95% das decisões e o usuário precisará corrigi-lo com frequência.

Como critérios de desempate, foram observados os valores médios de precisão e sensibilidade, bem como seus respectivos desvios-padrões. Em caso de empate entre todas as medidas de avaliação, optou-se por selecionar o resultado com menor quantidade de dias. Adotou-se o critério da quantidade de dias também nos casos em que não houve diferença significativa entre os conjuntos de dados. Esta decisão baseou-se na premissa de que conjuntos de dados menores podem ser processados em menos tempo, otimizando o processo. A partir desta avaliação, seis conjuntos foram selecionados (Figura 23), um para cada algoritmo.

Figura 23. Seleção da quantidade de dias com melhor resultado para cada algoritmo.



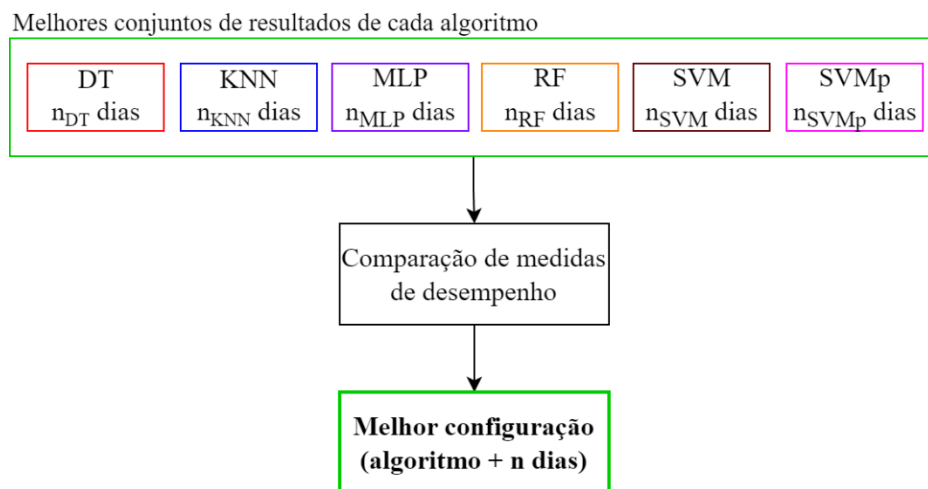
n_{DT} , n_{KNN} , n_{MLP} , n_{RF} , n_{SVM} e n_{SVMp} são os intervalos de tempo ideais encontrados para cada algoritmo.

3.3.2. Seleção e otimização do algoritmo

Os seis conjuntos de dados foram avaliados utilizando o teste de Mann-Whitney para verificar se havia diferenças estatisticamente significativas entre eles. O resultado desta avaliação resultou em uma matriz como a apresentada na Tabela 4, porém, com os conjuntos selecionados ao final da etapa anterior no lugar da quantidade de dias. A comparação foi realizada com base nos mesmos critérios utilizados anteriormente e o melhor algoritmo foi selecionado, conforme mostra a Figura 24.

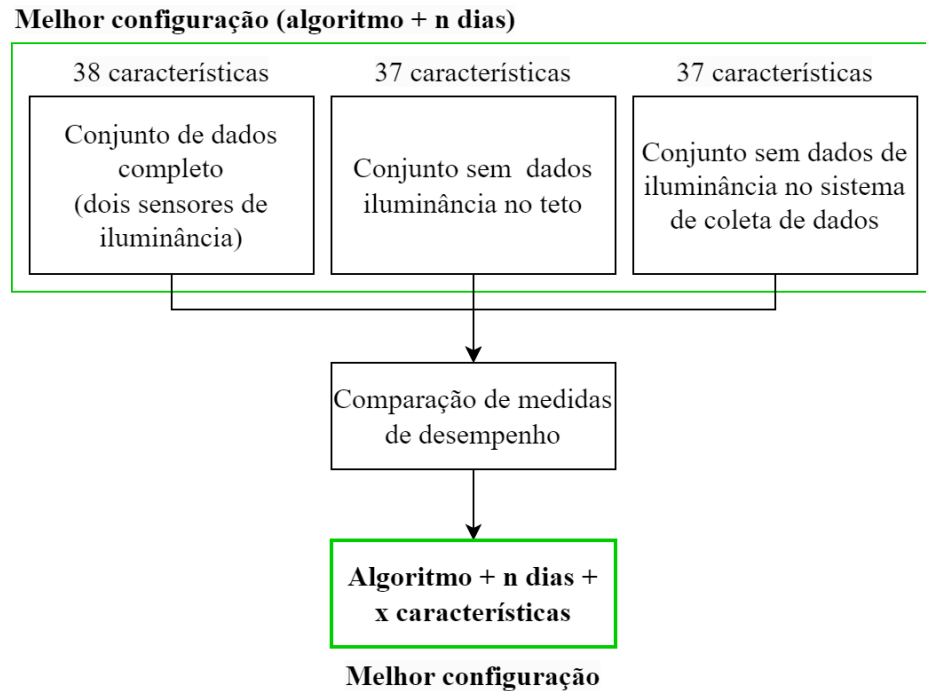
Após a seleção da melhor configuração, avaliou-se a possibilidade de utilizar menos características para o treinamento. A redução do número de características pode levar à otimização do modelo, caso alguma destas seja uma fonte de dados ruidosos. Neste trabalho, verificou-se o impacto do uso dos dados de iluminância de apenas um sensor nos resultados, pois alguns trabalhos encontrados na literatura sugerem a utilização de apenas uma referência de iluminância (Cheng *et al.*, 2016; Nagy *et al.*, 2015; Ouf; Park; Gunay, 2020; Park *et al.*, 2019a).

Figura 24. Seleção do algoritmo com melhor resultado.



Realizou-se, então, o treinamento do algoritmo selecionado com todos os conjuntos de dados do melhor intervalo de dias, porém, utilizando 37 das 38 colunas de características. Dois treinamentos foram realizados: um com a iluminância do sensor posicionado no teto e outro com a iluminância coletada pelo sensor posicionado junto ao sistema de coleta de dados. Os três resultados foram avaliados com o teste de Mann-Whitney e comparados seguindo os mesmos critérios utilizados até então. Desta forma, foi possível determinar se a otimização poderia ser realizada excluindo os dados de um dos sensores de iluminância. A Figura 25 mostra um esquema desta etapa.

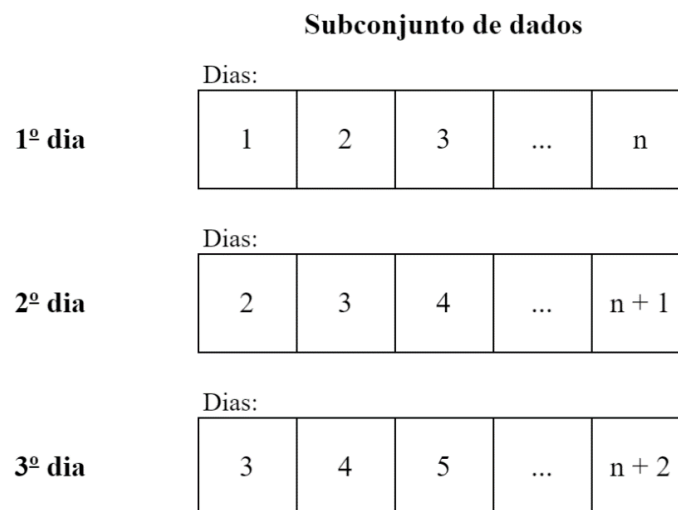
Figura 25. Esquema do processo de otimização.



3.3.3. Atualização do subconjunto de dados

Após a seleção da configuração mais favorável de algoritmo e quantidade de dados para treino, avaliou-se o desempenho desta configuração mediante a atualização do subconjunto de dados. Para isto, simulou-se um cenário realista, treinando e testando o algoritmo como se este estivesse implementado em um ambiente real. Utilizou-se o intervalo de dados selecionado como o ideal para o treinamento e um único dia para teste. A atualização do subconjunto de dados de treino foi realizada conforme mostra a Figura 26.

Figura 26. Atualização dos dados de treinamento do algoritmo.



O subconjunto de dados contém registros de n dias, usados para o treinamento do algoritmo. No primeiro dia de teste do algoritmo (dia $n+1$), os dados usados para treino referiam-se aos n dias anteriores. Ao final do dia, os dados foram atualizados para o novo treinamento (ou atualização) do algoritmo, excluindo os dados do dia 1 e incluindo os do dia $n+1$. O mesmo aconteceu para o restante dos dias, até a utilização de todo o conjunto de dados disponível. As medidas de avaliação foram calculadas após cada atualização, a fim de verificar o desempenho do algoritmo com o passar dos dias.


4. Resultados e discussão

Este capítulo contém os resultados alcançados com o método anteriormente descrito, bem como as discussões pertinentes acerca dos mesmos.

4.1. Dados coletados

Durante o período de aquisição de dados, 81501 amostras foram coletadas pelo sistema instalado. A utilização deste conjunto de dados é abordada a partir da seção 4.2. O questionário foi respondido por dezoito dos 25 ocupantes do laboratório. As respostas consideradas mais relevantes são apresentadas nesta seção. O compilado de todas as respostas pode ser encontrado no Apêndice A. A Figura 27 mostra que destes, cerca de 60% declararam permanecer no ambiente por até dez horas semanais. Apenas um usuário indicou permanência semanal superior a 40 horas.

Figura 27. Frequência semanal dos ocupantes do laboratório.



De forma geral, a maioria dos usuários declarou realizar principalmente atividades no computador e estar satisfeitos com a quantidade de luz natural e artificial no ambiente. Não houve registro de votos de desconforto com as condições de iluminação do ambiente, nem em relação à percepção de controle. Quase 90% dos usuários responderam acionar as lâmpadas apenas quando julgam necessário para realizar suas tarefas. O mesmo percentual de pessoas

declarou desligar a iluminação artificial quando considera que há luz natural o suficiente e quando deixa o ambiente por longos períodos.

Com uma única exceção (voto neutro), os ocupantes declararam ter interesse em tecnologias de automação e controle voltadas para as edificações. Houve indicação de preferência por sistemas com o desligamento automático das lâmpadas (88,8%), corroborando com a literatura (Park *et al.*, 2019a). O acionamento automático foi indicado como desejado por apenas 66,6% dos ocupantes. É interessante observar que apenas três usuários declararam não realizar esforço para economizar energia (Figura 28). No entanto, ao serem questionados sobre priorizar a economia de energia em detrimento de conforto, apenas quatro usuários responderam positivamente (Figura 29). Isto também foi verificado na literatura (Nagy; Yong; Schlueter, 2016).

Figura 28. Respostas dos usuários sobre seu esforço em economizar energia.





Figura 29. Respostas dos usuários sobre sacrificar seu conforto para economizar energia.



Diante das respostas obtidas, constatou-se que o ambiente seria favorável para a coleta de dados e desenvolvimento deste trabalho, com poucas chances de boicote. Ainda que nem todos os usuários tenham respondido aos questionários, não foi encontrada nenhuma objeção para o desenvolvimento das demais atividades.

4.2. Dados pré-processados

A partir do pré-processamento do conjunto de dados foi possível verificar diferenças significativas nas medições de iluminância dos sensores posicionados no teto e sobre a estação de coleta de dados. Conforme esperado, a iluminância máxima registrada pelo sensor posicionado no teto indicou um valor até cinco vezes menor do que o máximo registrado pelo sensor posicionado sobre a estação de medição. De forma semelhante, a iluminância média registrada por cada um dos sensores também apresentou diferença significativa. A temperatura permaneceu relativamente estável. Estas informações podem ser vistas na Tabela 5.


Tabela 5. Valores das variáveis ambientais.

Variável	Mínimo	Máximo	Média	Desvio Padrão
iluminância_caixa (lux)	0	3173,00	108,23	141,24
iluminância_teto (lux)	0	676,00	59,57	81,06
temperatura (°C)	16,98	41,13	26,72	4,54

O desvio padrão encontrado nas medições dos dois sensores de iluminância indica que há variações significativas ao longo das verificações. Isto pode ser devido a incidência direta de luz sobre os sensores, sendo valores espúrios. Porém, considerando que o algoritmo precisará lidar com este tipo de dado, estes não foram excluídos do conjunto. Das 81501 amostras obtidas pelo sensor posicionado sobre o sistema de coleta de dados, mais de 57 mil concentraram-se entre zero e 200lx. Ainda que tenham sido registrados valores acima dos 400lx, sua quantidade foi insignificante (aproximadamente 0,4%) perante os demais dados da amostra. No sensor posicionado no teto, a quantidade de verificações indicando iluminâncias entre zero e 200lx foi ainda maior. Mais de 90% dos dados concentraram-se neste intervalo.


Para melhor observação do comportamento da iluminância ao longo de um dia, a Figura 30 mostra os valores médios obtidos com os dados dos dois sensores utilizados. Observe-se que, mesmo que o valor máximo de iluminância registrado ultrapasse os 3000lx, o valor médio máximo permanece em torno de 200lx, por volta das 15h. Ressalta-se que as curvas não indicam a iluminância média na sala, mas o valor médio incidente nos sensores.

Figura 30. Iluminância média horária registrada pelos sensores posicionados em diferentes locais.



A temperatura permaneceu entre 20°C e 30°C em cerca de 68% das verificações. Este fato pode ser explicado pois os usuários mantinham um aquecedor no ambiente durante os dias mais frios pois, segundo eles, baixas temperaturas prejudicavam o funcionamento da impressora 3D presente no local. A temperatura média horária ao longo de um dia é apresentada na Figura 31.

Figura 31. Média horária da temperatura ambiente.



Na Tabela 6, é possível observar que a porta e as janelas da sala estavam fechadas na maioria das verificações. Estima-se que isto tenha relação com dois fatores, que podem estar além das preferências dos usuários. O primeiro é que o sistema permaneceu realizando verificações durante a noite, pois os usuários relataram que havia ocupação esporádica neste período. O segundo está associado ao uso do aquecedor elétrico.

Os interruptores também permaneceram desligados na maior parte das verificações, como mostra a Tabela 7, levando ao desbalanceamento das classes. Verifica-se, também, que a configuração mais comum de utilização do conjunto de lâmpadas é o acionamento de todas elas simultaneamente.

Tabela 6. Distribuição das amostras conforme o estado dos sensores (0 - aberto, 1 - fechado).

Local	Estado do sensor	Quantidade de amostras
Porta	0	80558
	1	943
Janela 1	0	69287
	1	12214
Janela 2	0	77709
	1	3792

Tabela 7. Quantidade de amostras de acordo com o estado dos interruptores 1 (I1) e 2 (I2).

Estado	Classe	Quantidade de amostras
I1 e I2 ligados	0	22798
I1 ligado e I2 desligado	1	320
I1 desligado e I2 ligado	2	441
I1 e I2 desligados	3	57942

A organização dos dados em subconjuntos de 1, 7, 15 e 30 dias resultou em 914 subconjuntos, sendo:

- 253 subconjuntos contendo 1 dia para treino e 1 dia para teste;
- 241 subconjuntos contendo 7 dias para treino e 7 dias para teste;
- 225 subconjuntos contendo 15 dias para treino e 15 dias para teste;
- 195 subconjuntos contendo 30 dias para treino e 30 dias para teste.

4.3. Análise de desempenho dos algoritmos

Nesta seção, são apresentados os resultados obtidos a partir do treinamento e teste dos algoritmos com os 914 subconjuntos de dados, com o objetivo de identificar o período de tempo que proporciona as melhores medidas de avaliação para cada algoritmo. Todos os subconjuntos utilizados continham 38 características (iluminâncias, temperatura, dados de ocupação de 25 usuários, estado das aberturas...), a fim de fornecer aos algoritmos o máximo de informação possível para realizar as inferências sobre o sistema de iluminação.

Em cada teste realizado, observou-se que os valores de acurácia e sensibilidade coincidiram, assim como em outros estudos encontrados na literatura (Aparicio-Ruiz *et al.*, 2023; Cosma; Simha, 2019).

4.3.1. Decision Tree

Durante o treino com os subconjuntos, este algoritmo estabeleceu a árvore (ou o “caminho”) que guia a decisão de conduzir cada entrada à sua respectiva saída, orientando a classificação dos dados na etapa de teste. A mediana e o intervalo de confiança dos valores de acurácia, precisão e sensibilidade podem ser vistos na Tabela 8. A observação dos valores indica que o algoritmo apresentou desempenho satisfatório, especialmente com os subconjuntos com menor quantidade de dias.

Tabela 8. Mediana e intervalo de confiança para as medidas de avaliação dos conjuntos de resultados da DT.


Cenário	Acurácia (%)		Precisão (%)		Sensibilidade (%)	
	Mediana	Intervalo	Mediana	Intervalo	Mediana	Intervalo
		de confiança		de confiança		de confiança
1 dia	99,65	99,59;99,70	99,95	99,59;99,70	99,65	99,59;99,70
7 dias	97,52	97,15;97,90	97,76	97,41;98,12	97,52	97,15;97,90
15 dias	96,52	96,06;96,99	97,24	96,89;97,59	96,52	96,06;96,99
30 dias	95,37	95,01;95,73	96,13	95,75;96,52	95,37	95,01;95,73

Por outro lado, a análise da distribuição dos resultados, que pode ser vista na Figura 32, fornece um contraponto. Apesar do valor da mediana ser mais elevado para os cenários com menor quantidade de dias de treino e teste, houve casos em que o desempenho do algoritmo foi consideravelmente insatisfatório. À medida que a quantidade de dias no subconjunto aumenta, o valor da mediana diminui, mas a quantidade de valores extremos baixos também ocorre com menor frequência. O teste de normalidade resultou em p-valor menor que 0,01, indicando que a distribuição dos dados é não-normal em todos os casos.

Observa-se que, para os subconjuntos de 1 dia, a maior parte dos dados de acurácia, sensibilidade e precisão (aproximadamente 200 testes) concentram-se acima dos 90%. A ocorrência de valores abaixo de 40% foi observada em quatro testes. Comparando os testes dos subconjuntos de 7 dias com os resultados dos subconjuntos de 1 dia, observou-se aumento na quantidade de valores próximos dos 80%. Isto acontece por consequência da redução da quantidade de resultados abaixo de 60%. Nos resultados com os subconjuntos de 15 dias não foram encontrados valores menores do que 40%. Além disso, 185 dos 225 testes resultaram em acurácia, sensibilidade e precisão acima de 90%. Nos resultados dos testes com os subconjuntos

de 30 dias não foram encontrados valores abaixo de 50% e a maior parte dos dados permaneceu acima de 90%.

Figura 32. Desempenho do algoritmo DT com os diferentes subconjuntos de dados.



A verificação das semelhanças entre as medianas dos conjuntos de acurácia, realizada por meio do teste de Mann-Whitney, resultou nos p-valores apresentados na Tabela 9. É importante lembrar que a obtenção de p-valores menores que 0,05 indica que os grupos possuem diferenças significativas entre si. Para o algoritmo DT, não se observou diferença significativa nos resultados aumentando a quantidade de dias de 15 para 30. Todos os demais conjuntos apresentaram diferenças estatisticamente significativas. Salienta-se que, ainda que o teste de Mann-Whitney compare as medianas dos conjuntos, os valores médios (e respectivos desvios-padrões) foram utilizados como critério de seleção, devido à possível ocorrência de valores extremos que não podem ser desconsiderados na prática.

Tabela 9. Matriz de p-valores do teste de Mann-Whitney para comparação de medianas, para os resultados da DT.

Número de dias	1	7	15	30
1	-	0,000	0,000	0,000
7	0,000	-	0,005	0,000
15	0,000	0,005	-	0,052
30	0,000	0,000	0,052	-

O resultado médio das medidas de avaliação de todos os testes de 1, 7, 15 e 30 dias pode ser visto na Tabela 10. Com base nos critérios adotados, elegeu-se com o melhor resultado para o algoritmo DT o conjunto de 15 dias. Neste cenário, foram obtidos valores mais altos de acurácia e sensibilidade média. Ainda que a precisão média obtida com os subconjuntos de 30 dias tenha sido a mais alta, não há evidência de que os resultados sejam significativamente diferentes dos obtidos com os subconjuntos de 15 dias.

Tabela 10. Avaliação dos testes da DT com todos os subconjuntos de dados.

Subconjunto (dias)	1	7	15	30	
Quantidade de subconjuntos	253	241	225	195	
Acurácia (%)	Média	92,09	93,02	93,16	93,05
	Desvio padrão	15,35	12,02	9,69	9,11
Precisão (%)	Média	91,95	94,76	95,16	95,83
	Desvio padrão	18,33	7,47	6,42	3,35
Sensibilidade (%)	Média	92,09	93,02	93,16	93,05
	Desvio padrão	15,35	12,02	9,69	9,11

É possível encontrar, na literatura, cenários em que o uso deste algoritmo apresentou valores de acurácia entre 50% e 99%. O período de coleta de dados, nestes casos, variou de aproximadamente uma hora até um ano (Aparicio-Ruiz *et al.*, 2023; Cen; Cheng; Wong, 2022; Choi; Yeom, 2019; Ghahramani; Tang; Becerik-Gerber, 2015; Intharachathorn; Jareemit; Watcharapinchai, 2023; Jeoung *et al.*, 2022; Jia *et al.*, 2022; Peng; Nagy; Schlüter, 2019; Pigliautile *et al.*, 2020). Ainda que não seja possível comparar resultados, pois os conjuntos de dados diferem, Choi e Yeom (2019) e Jia *et al.* (2022) encontraram valores médios semelhantes aos obtidos neste trabalho. Os testes realizados pelos autores visavam prever aspectos relacionados ao conforto térmico de usuários em ambientes controlados. Para isso, foram

utilizados dados fisiológicos coletados a cada 5 ou 10 segundos, durante um período aproximado de 100 minutos. No entanto, é interessante observar que, no estudo de Aparicio-Ruiz *et al.* (2023), foram coletados dados ao longo de um ano para realizar inferências quanto ao conforto térmico, mas a acurácia obtida foi pouco maior do que 50%. Com isso, evidencia-se a necessidade de realizar avaliações como a proposta neste trabalho, pois o aumento da quantidade de dados não proporciona, necessariamente, bons resultados.

4.3.2. *k-Nearest Neighbors*


No processo de treino e teste do KNN, cada amostra dos subconjuntos foi comparada com seus cinco vizinhos mais próximos, a fim de classificá-las. A análise das medianas e intervalos de confiança dos conjuntos de resultados (Tabela 11) indica que o algoritmo apresenta desempenho satisfatório em todos os cenários. A hipótese de distribuição normal foi rejeitada para todos os conjuntos ($p < 0,01$).

Tabela 11. Mediana e intervalo de confiança para as medidas de avaliação dos conjuntos de resultados do KNN.

Cenário	Acurácia (%)		Precisão (%)		Sensibilidade (%)	
	Mediana	Intervalo	Mediana	Intervalo	Mediana	Intervalo
		de confiança		de confiança		de confiança
1 dia	99,65	99,59;99,70	99,70	99,66;99,75	99,65	99,59;99,70
7 dias	99,08	98,95;99,21	99,28	99,17;99,39	99,08	98,95;99,21
15 dias	98,44	98,27;98,60	98,56	98,38;98,74	98,44	98,27;98,60
30 dias	98,01	97,85;98,17	98,03	97,79;98,27	98,01	97,85;98,17

A avaliação conjunta das medianas com a distribuição dos resultados (vista na Figura 33) mostra que, também para este caso, os resultados dos subconjuntos de um dia apresentam valores extremos significativamente baixos. Por outro lado, cerca de 220 testes apresentaram acurácia, sensibilidade e precisão acima de 90%. Para os testes com os subconjuntos de 7 dias, observa-se que não houve casos de acurácia, precisão ou sensibilidade abaixo de 65%, demonstrando melhoria em relação aos resultados dos subconjuntos de 1 dia. Com os conjuntos de 15 e 30 dias, não houve ocorrência de valores abaixo de 80%. Nos testes utilizando os subconjuntos de 30 dias, quase a totalidade dos resultados permaneceu acima de 90%.

Figura 33. Desempenho do algoritmo KNN com os diferentes subconjuntos de dados.



A comparação das medianas dos conjuntos de resultados para identificar diferenças significativas entre elas resultou na matriz de p-valores apresentada na Tabela 12. A partir dela, é possível verificar que é possível rejeitar a hipótese de que os conjuntos são estatisticamente semelhantes. Em todos os casos, obteve-se p-valor menor que 0,05.

Tabela 12. Matriz de p-valores do teste de Mann-Whitney para comparação de medianas, para os resultados do KNN

Número de dias	1	7	15	30
1	-	0,001	0,000	0,000
7	0,001	-	0,000	0,000
15	0,000	0,000	-	0,016
30	0,000	0,000	0,016	-

Os valores médios de acurácia, sensibilidade e precisão de todos os subconjuntos de dados estão na Tabela 13. Considerando que não há semelhanças estatísticas entre as medianas

dos grupos e observando os critérios de escolha, o melhor resultado para o KNN foi obtido com os subconjuntos de 7 dias, pois é onde se observa acurácia e sensibilidade com valores mais elevados. A precisão foi ligeiramente superior para os subconjuntos de 15 e 30 dias, no entanto, acurácia e sensibilidade são inferiores em ambos os casos.

Tabela 13. Avaliação dos testes do KNN com todos os subconjuntos de dados.

Subconjunto (dias)	1	7	15	30	
Quantidade de subconjuntos	253	241	225	195	
Acurácia (%)	Média	94,77	97,97	97,67	97,17
	Desvio padrão	12,63	2,96	2,19	2,76
Precisão (%)	Média	94,42	97,39	97,69	97,64
	Desvio padrão	15,15	4,69	2,30	1,85
Sensibilidade (%)	Média	94,77	97,97	97,67	97,17
	Desvio padrão	12,63	2,96	2,19	2,76

Os resultados obtidos neste trabalho foram superiores aos encontrados na literatura. Com exceção dos estudos de Aryal e Becerik-Gerber (2019, 2020), que encontraram acurácias de até 94,0% utilizando o KNN, as acurácias encontradas por outros autores variaram entre cerca de 55,8% e 83,0% (Cen; Cheng; Wong, 2022; Cosma; Simha, 2019; Ghahramani; Tang; Becerik-Gerber, 2015; Li *et al.*, 2023a; Pigliautile *et al.*, 2020).

O período de coleta de dados variou entre 27 minutos e um ano. Nos trabalhos de Aryal e Becerik-Gerber (2019, 2020), que obtiveram resultados semelhantes a este, a coleta de dados aconteceu durante três meses e seis horas, respectivamente. No estudo de Ghahramani *et al.* (2015), em que também houve coleta de dados por três meses, a acurácia foi de apenas 65,0%. De forma semelhante ao observado no caso da DT, o estudo de um ano atingiu resultados pouco acima de 50,0% (Aparicio-Ruiz *et al.*, 2023). Sendo assim, também para o caso do uso do KNN observa-se a necessidade da realização de avaliações prévias, como a que se propõe.

4.3.3. *Multilayer Perceptron*

Após o processo de treinamento da MLP com os subconjuntos, a equação que conduz cada entrada até sua respectiva saída (como no exemplo mostrado na Equação 1) foi utilizada na realização dos testes. De acordo com a observação da Tabela 14, cujos valores foram obtidos a partir dos testes com este algoritmo, verificou-se desempenho inferior ao dos algoritmos avaliados até então. Mesmo no que poderia ser considerado o melhor cenário (pela observação


isolada da Tabela 14), a precisão do algoritmo não ultrapassou os 55%. Para todos os casos, o p-valor encontrado com o teste de Lilliefors foi menor que 0,01, sugerindo a distribuição não normal dos resultados.

Tabela 14. Mediana e intervalo de confiança para as medidas de avaliação dos conjuntos de resultados da MLP.

Cenário	Acurácia (%)		Precisão (%)		Sensibilidade (%)	
	Mediana	Intervalo de confiança	Mediana	Intervalo de confiança	Mediana	Intervalo de confiança
1 dia	73,67	69,57;77,76	54,27	48,55;59,98	73,67	69,57;77,76
7 dias	69,02	66,29;71,76	47,64	44,08;51,21	69,02	66,29;71,76
15 dias	67,53	65,20;69,85	45,60	42,13;49,07	67,53	65,20;69,85
30 dias	70,50	69,04;71,97	49,71	47,77;51,65	70,50	69,04;71,97

A distribuição dos resultados obtidos com este algoritmo pode ser vista na Figura 34 e apresenta padrão diferente dos demais. De todos os 253 testes realizados com os subconjuntos de 1 dia, cerca de 100 apresentaram medidas de avaliação acima de 90%. Isto representa cerca de 40% do total. O percentual de resultados acima de 90% foi ainda menor com os subconjuntos de 7 dias. Por outro lado, houve incremento dos resultados na faixa dos 60%. Algo semelhante pode ser observado nos resultados dos testes com os subconjuntos de 15 dias. Houve redução nos resultados acima de 90% e aumento nos valores próximos de 60%. Os testes com os subconjuntos de 30 dias apresentaram redução na quantidade de resultados abaixo de 20%. No entanto, não houve melhoria nos casos com medidas de avaliação acima de 80%.

Figura 34. Desempenho do algoritmo MLP com os diferentes subconjuntos de dados.



A Tabela 15 apresenta os p-valores obtidos a partir da comparação das medianas dos resultados da MLP. Observa-se que não há diferença significativa entre os conjuntos pois, para todos os casos, o p-valor foi maior do que 0,05. Os valores médios encontrados para todos os subconjuntos estão apresentados na Tabela 16. Ao contrário dos algoritmos já apresentados, a MLP obteve acurácia e sensibilidade médias entre 70% e 75%. Por sua vez, a precisão não atingiu a média de 60% com nenhum dos subconjuntos.

Em termos gerais, os melhores resultados foram obtidos com os subconjuntos de 30 dias. No entanto, não há evidência de que haja diferença significativa entre os grupos de resultados para corroborar com esta afirmação. Neste sentido, o critério utilizado para eleger o melhor resultado baseou-se na quantidade de dias do subconjunto, visando reduzir o tempo de processamento do algoritmo. Em outras palavras, não houve evidência de que o incremento na quantidade de dados melhoraria a qualidade dos resultados, por isso optou-se pelo resultado obtido com o menor custo computacional. Portanto, considera-se que os subconjuntos de 1 dia sejam o melhor caso para o uso da MLP.

Tabela 15. Matriz de p-valores do teste de Mann-Whitney para comparação de medianas, para os resultados da MLP.

Número de dias	1	7	15	30
1	-	0,204	0,189	0,877
7	0,204	-	0,807	0,065
15	0,189	0,807	-	0,095
30	0,877	0,065	0,095	-

Tabela 16. Avaliação dos testes da MLP com todos os subconjuntos de dados.

Subconjunto (dias)		1	7	15	30
Quantidade de subconjuntos		253	241	225	195
Acurácia (%)	Média	71,96	70,64	71,76	75,40
	Desvio Padrão	27,59	22,62	20,77	15,83
Precisão (%)	Média	59,59	55,02	55,82	59,37
	Desvio Padrão	36,22	30,80	29,00	24,14
Sensibilidade (%)	Média	71,96	70,64	71,76	75,40
	Desvio Padrão	27,59	22,62	20,77	15,83

Na literatura, foram encontrados casos em que o uso de redes neurais apresentou acurácia de até 52,6% utilizando dados coletados durante dezesseis dias (Jeoung *et al.*, 2022). No entanto, também há estudos em que a acurácia obtida foi de 80,0% (Chaudhuri *et al.*, 2018a), 82,9% (Zhong; Choi, 2017), 88,5% (Mandarin; Skocir; Jezic, 2020), 89,2% (Shan *et al.*, 2020), 98,0% (Peng; Nagy; Schlüter, 2019) e 99,0% (Jia *et al.*, 2022). Com exceção do estudo de Peng, Nagy e Schlüter (2019), que teve duração de cinco meses, os demais trabalhos supracitados tiveram duração máxima de um dia. Tais diferenças evidenciam, mais uma vez, a influência do conjunto de dados no desempenho do algoritmo.

4.3.4. *Random Forest*


As árvores criadas na etapa de treino do algoritmo e utilizadas na etapa de testes, classificaram cada uma das entradas dos subconjuntos de dados. A verificação das medianas não indicou desempenho inadequado do algoritmo, e a análise isolada da Tabela 17 indica que o incremento na quantidade de dias para treino do algoritmo não melhora os resultados. A avaliação conjunta

com a distribuição dos resultados, vista na Figura 35, no entanto, mostra o contrário. O teste de normalidade resultou em p-valor menor que 0,01, indicando distribuição não-normal.

Tabela 17. Mediana e intervalo de confiança para as medidas de avaliação dos conjuntos de resultados do RF.

Cenário	Acurácia (%)		Precisão (%)		Sensibilidade (%)	
	Mediana	Intervalo de confiança	Mediana	Intervalo de confiança	Mediana	Intervalo de confiança
1 dia	99,65	99,59;99,70	99,65	99,60;99,70	99,65	99,59;99,70
7 dias	97,98	97,68;98,27	97,59	97,24;97,94	97,98	97,68;98,27
15 dias	97,59	97,29;97,89	97,22	96,83;97,60	97,59	97,29;97,89
30 dias	96,54	96,18;96,90	95,91	95,51;96,31	96,54	96,18;96,90

Figura 35. Desempenho do algoritmo RF com os diferentes subconjuntos de dados.



Nos testes com os subconjuntos de 1 dia, aproximadamente 75% resultou em valores de acurácia, precisão e sensibilidade acima de 90%. Comparando com os resultados de 7 dias, verifica-se que houve redução da quantidade de resultados com valores mais baixos, especialmente abaixo de 80%. Utilizando os subconjuntos de 15 dias, não houve valores de acurácia, sensibilidade ou precisão abaixo de 80%. Cerca de 85% dos testes resultaram em medidas de avaliação próximas de 100%. Com os subconjuntos de 30 dias, os resultados ficaram ainda mais concentrados próximos do valor máximo.

A comparação das medianas dos grupos de resultados por meio do teste de Mann-Whitney deu origem à matriz apresentada na Tabela 18. Com exceção dos resultados dos subconjuntos de 7 e 15 dias, todos os demais apresentaram diferenças significativas entre si, com p-valor menor do que 0,05.

Tabela 18. Matriz de p-valores do teste de Mann-Whitney para comparação de medianas, para os resultados do RF.

Número de dias	1	7	15	30
1	-	0,003	0,001	0,000
7	0,003	-	0,567	0,019
15	0,001	0,567	-	0,039
30	0,000	0,019	0,039	-

Os valores médios dos testes com os diferentes subconjuntos podem ser vistos na Tabela 19.

Tabela 19. Avaliação dos testes do RF com todos os subconjuntos de dados.

Subconjunto (dias)	1	7	15	30	
Quantidade de subconjuntos	253	241	225	195	
Acurácia (%)	Média	91,07	95,94	96,75	96,54
	Desvio padrão	16,38	6,35	3,77	2,78
Precisão (%)	Média	91,18	95,51	96,05	95,97
	Desvio padrão	18,54	5,81	3,51	2,99
Sensibilidade (%)	Média	91,07	95,94	96,75	96,54
	Desvio padrão	16,38	6,35	3,77	2,78

Ainda que o melhor resultado tenha sido obtido com os subconjuntos de 15 dias, não há evidência de que haja diferença estatisticamente significativa entre estes resultados e os dos subconjuntos de 7 dias. Neste sentido, opta-se por trabalhar com o subconjunto que leva ao menor custo computacional entre os dois, isto é, o de 7 dias. Desta forma, a comparação foi realizada apenas entre os subconjuntos de 1, 7 e 30 dias. Os subconjuntos de 30 dias foram os que apresentaram melhores medidas de avaliação e, por isso, foram selecionados como opção ideal para uso com o RF.

Os resultados obtidos neste trabalho assemelham-se a outros estudos encontrados na literatura. Chaudhuri *et al.* (2018b, 2019) encontraram acurácias entre 92,8% e 94,3%. Morresi *et al.* (2021) alcançaram 93,7% e Jung, Jazizadeh e Diller (2019) atingiram 97,0% de acurácia. Os resultados obtidos por estes autores foram alcançados com coletas de dados que duraram entre 40 e 120 minutos em ambientes controlados. No entanto, também podem ser encontrados resultados com medidas de avaliação consideravelmente inferiores. É o caso dos estudos de Pigliautile *et al.* (2020), com 79,0% e de Aparicio-Ruiz *et al.* (2023), com 59,1%, cuja coleta de dados se deu ao longo de 100 minutos e um ano, respectivamente. Estes resultados corroboram com o que se afirma ao longo deste trabalho acerca da influência do conjunto de dados no desempenho do algoritmo.


4.3.5. Support Vector Machine

Os testes do SVM foram realizados utilizando os hiperplanos traçados na etapa de treino do algoritmo. No entanto, é importante ressaltar que a quantidade de testes com os subconjuntos de 1 e 15 dias foi menor do que nos demais casos apresentados até então. Isto aconteceu pois o SVM não consegue realizar os testes quando há apenas uma classe nos dados de treino. Em outras palavras, realizar menos testes não foi uma opção, mas uma limitação do algoritmo, pois é impossível classificar os dados se há apenas uma saída possível. Esta situação foi observada em 83 subconjuntos de 1 dia e 23 subconjuntos de 7 dias. Apesar disso, a observação das medianas não aponta para a existência de outros problemas associados ao desempenho do algoritmo (Tabela 20). A distribuição dos resultados apresentou p-valor menor que 0,01 de acordo com o teste de normalidade, indicando não ser normal. A distribuição dos resultados para os testes pode ser vista na Figura 36.

Tabela 20. Mediana e intervalo de confiança para as medidas de avaliação dos conjuntos de resultados do SVM.

Cenário	Acurácia (%)		Precisão (%)		Sensibilidade (%)	
	Mediana	Intervalo	Mediana	Intervalo	Mediana	Intervalo
		de		de		de
		confiança		confiança		confiança
1 dia	98,59	98,32;98,86	99,29	97,91;98,85	98,59	98,32;98,86
7 dias	89,97	88,51;91,44	94,42	94,10;95,70	89,97	88,51;91,44
15 dias	93,65	92,79;94,51	95,48	94,64;95,84	93,65	92,79;94,51
30 dias	95,17	94,65;95,69	95,48	90,92;92,44	95,17	94,65;95,69

Figura 36. Desempenho do algoritmo SVM com os diferentes subconjuntos de dados.



Dentre os subconjuntos de 1 dia testados com sucesso (170), ao menos 120 tiveram medidas de avaliação acima de 90%. No entanto, também foram observados valores na faixa de 30%. Nos resultados dos 218 testes realizados com os subconjuntos de 7 dias é possível observar um declínio na quantidade de medidas de acurácia, sensibilidade e precisão acima dos

90%. Com os subconjuntos de 15 dias, a distribuição dos resultados apresentou redução de cerca de 50% nos valores próximos de 80%. Verificou-se, ainda, aumento na quantidade de ocorrências de valores mais altos. Comparando os testes com os subconjuntos de 30 dias com os demais casos analisados com este algoritmo, observa-se redução significativa na quantidade de resultados com valores abaixo de 80%.

A realização do teste de Mann-Whitney permitiu verificar que não houve diferença significativa entre as medianas dos resultados dos subconjuntos de 7 e 15 dias. Os demais resultados mostraram-se estatisticamente diferentes. Isto pode ser observado na Tabela 21, onde o único p-valor acima de 0,05 está na comparação dos resultados dos subconjuntos de 7 e 15 dias. Neste sentido, considera-se para a comparação os subconjuntos com menor custo computacional (7 dias), uma vez que o aumento na quantidade de dados não altera significativamente o resultado. Foram comparados os resultados médios apresentados na Tabela 22, excluindo-se os resultados dos subconjuntos de 15 dias. Observando as medidas de avaliação, verificou-se que o intervalo de tempo ideal para obter o melhor desempenho do SVM foi o de 30 dias.

Tabela 21. Matriz de p-valores do teste de Mann-Whitney para comparação de medianas, para os resultados do SVM.

Número de dias	1	7	15	30
1	-	0,000	0,000	0,000
7	0,000	-	0,471	0,000
15	0,000	0,471	-	0,008
30	0,000	0,000	0,008	-

Tabela 22. Avaliação dos testes do SVM com todos os subconjuntos de dados.

Subconjunto (dias)	1	7	15	30	
Quantidade de subconjuntos	170	218	225	195	
Acurácia (%)	Média	90,97	83,53	84,89	91,87
	Desvio padrão	15,44	17,86	17,78	8,46
Precisão (%)	Média	93,51	91,79	93,33	95,12
	Desvio padrão	13,37	10,10	8,14	3,66
Sensibilidade (%)	Média	90,97	83,53	84,89	91,87
	Desvio padrão	15,44	17,86	17,78	8,46

Os resultados obtidos por outros autores, utilizando este algoritmo, variaram significativamente. Enquanto Jeoung *et al.* (2022) alcançaram acurácia mínima de 29% na previsão de sensação térmica individual, outros autores atingiram valores acima de 90% mesmo em casos com múltiplos usuários (Aryal; Becerik-Gerber, 2019; Li *et al.*, 2023a; Peng; Nagy; Schlüter, 2019; Yang *et al.*, 2022). Outros autores ainda obtiveram resultados intermediários, entre 55% e 88% (Aparicio-Ruiz *et al.*, 2023; Cen; Cheng; Wong, 2022; Chaudhuri *et al.*, 2018a; Cosma; Simha, 2019; Ghahramani; Tang; Becerik-Gerber, 2015; Ma; Pan, 2021; Pigliautile *et al.*, 2020). A duração da coleta de dados para teste do algoritmo, nos casos mencionados, foi significativamente diferente, variando de cerca de 25 minutos até um ano.

4.3.6. *Support Vector Machine* com ponderação de classes


No treino do SVMp, além de traçar os hiperplanos, foram calculados os pesos para cada classe, utilizando a Equação 2 e os dados apresentados na Tabela 7. Com isso, foi possível realizar inferências na etapa de testes. Neste caso, também houve menos testes com os subconjuntos de 1 e 7 dias, em decorrência da quantidade de classes presente na amostra. Assim como no caso sem ponderação, foram realizados testes com 170 subconjuntos de 1 dia e 218 subconjuntos de 7 dias. Assim como nos demais casos, a distribuição dos resultados também apresentou características não-normais, com p-valor menor que 0,01 para o teste de Lilliefors. As medianas, mostradas na Tabela 23 juntamente com o intervalo de confiança, não indicam a existência de problemas com o desempenho do algoritmo, exceto pelo mencionado anteriormente.

Tabela 23. Mediana e intervalo de confiança para as medidas de avaliação dos conjuntos de resultados do SVMp.

Cenário	Acurácia (%)		Precisão (%)		Sensibilidade (%)	
	Mediana	Intervalo de confiança	Mediana	Intervalo de confiança	Mediana	Intervalo de confiança
1 dia	98,23	97,90;98,57	99,29	99,16;99,43	98,23	97,90;98,57
7 dias	90,79	89,42;92,15	95,26	94,53;96,00	90,79	89,42;92,15
15 dias	92,73	91,77;93,70	95,98	95,46;96,50	92,73	91,77;93,70
30 dias	90,43	89,43;91,44	96,33	95,87;96,79	90,43	89,43;91,44

Ao observar a distribuição dos dados, na Figura 37, observou-se algo semelhante ao obtido com o uso do algoritmo sem ponderação por classes. Para os subconjuntos de 1 dia, cerca de 120 – dos 170 testes – apresentaram medidas de avaliação acima de 90%. No caso dos testes com os subconjuntos de 7 dias, houve redução na quantidade de valores acima de 90% e aumento na faixa entre 60% e 80%. Os resultados para os subconjuntos de 15 dias apresentam aumento no número de ocorrências de acurácia, precisão e sensibilidade acima de 90%. Por outro lado, houve redução na quantidade de valores na faixa dos 80% e abaixo de 40%. Com os subconjuntos de 30 dias, observa-se incremento na quantidade de valores acima de 80%.

Figura 37. Desempenho do algoritmo SVMp com os diferentes subconjuntos de dados.



Comparando as medianas dos grupos de resultados por meio do teste de Mann-Whitney, obteve-se a matriz de p-valores apresentada na Tabela 24. É possível concluir que os resultados dos testes com os subconjuntos de 7, 15 e 30 dias não apresentaram diferenças significativas entre si. Mantendo a decisão de, nestes casos, optar pelos subconjuntos que levam ao menor custo computacional, seleciona-se para comparação apenas o subconjunto de 7 dias, excluindo-se os de 15 e 30. Neste sentido, observando os resultados médios dos testes de 1 e 7

dias, verifica-se que o melhor desempenho do SVMp se deu com os subconjuntos de 1 dia, conforme mostra a Tabela 25.

Tabela 24. Matriz de p-valores do teste de Mann-Whitney para comparação de medianas, para os resultados do SVMp.

Número de dias	1	7	15	30
1	-	0,000	0,000	0,000
7	0,000	-	0,874	0,859
15	0,000	0,874	-	0,861
30	0,000000	0,859	0,861	-

Tabela 25. Avaliação dos testes do SVMp com todos os subconjuntos de dados.

Subconjunto (dias)	1	7	15	30	
Quantidade de subconjuntos	170	218	225	195	
Acurácia (%)	Média	90,75	83,32	84,00	88,12
	Desvio padrão	15,60	18,81	18,13	10,27
Precisão (%)	Média	93,25	90,89	93,69	95,37
	Desvio padrão	14,03	10,24	7,93	3,51
Sensibilidade (%)	Média	90,75	83,32	84,00	88,12
	Desvio padrão	15,60	18,81	18,13	10,27

4.4. Seleção do algoritmo

Após a seleção do intervalo de tempo ideal para cada algoritmo, realizou-se a comparação entre os algoritmos, utilizando o período de tempo selecionado na etapa anterior. Desta forma, foram comparados os seguintes cenários:

- DT com os subconjuntos de 15 dias;
- KNN com os subconjuntos de 7 dias;
- MLP com os subconjuntos de 1 dia;
- RF com os subconjuntos de 30 dias;
- SVM com os subconjuntos de 30 dias;
- SVMp com os subconjuntos de 1 dia.

Inicialmente, verificou-se se havia diferenças significativas entre os grupos de resultados, por meio do teste de Mann-Whitney. Os p-valores obtidos com a aplicação do teste podem ser vistos na Tabela 26. Observou-se que os resultados do melhor cenário para o RF não

apresentaram diferenças significativas com os resultados do melhor cenário para a DT e para o SVMp. Todos os demais grupos de resultados tiveram p-valor menor do que 0,05, indicando diferenças estatisticamente significativas.

Tabela 26. Matriz de p-valores obtidos na comparação dos diferentes cenários.

Algoritmo	Período ideal						
	DT	KNN	MLP	RF	SVM	SVMp	
	15 dias	7 dias	1 dia	30 dias	30 dias	1 dia	
DT	15 dias	-	0,000	0,000	0,052	0,000	0,014
KNN	7 dias	0,000	-	0,000	0,000	0,000	0,019
MLP	1 dia	0,000	0,000	-	0,000	0,000	0,000
RF	30 dias	0,052	0,000	0,000	-	0,000	0,303
SVM	30 dias	0,000	0,000	0,000	0,000	-	0,000
SVMp	1 dia	0,014	0,019	0,000	0,303	0,000	-

Tendo em vista os critérios adotados, os resultados na matriz de p-valores e os resultados médios de cada cenário (apresentados na Tabela 27), pode-se concluir que o melhor resultado para o cenário deste trabalho é obtido com o uso do KNN e os subconjuntos de 7 dias, pois é o cenário que apresenta as melhores medidas de avaliação. Os valores de precisão e sensibilidade acima de 97% indicam que o modelo foi capaz de lidar com o desbalanceamento do conjunto de dados de forma adequada.

Tabela 27. Resultados médios dos melhores cenários de cada algoritmo.

Cenário	Acurácia (%)		Precisão (%)		Sensibilidade (%)	
	Média	Desvio padrão	Média	Desvio padrão	Média	Desvio padrão
DT – 15 dias	93,16	9,69	95,16	6,42	93,16	9,69
KNN – 7 dias	97,97	2,96	97,39	4,69	97,97	2,96
MLP – 1 dia	71,96	27,59	59,59	36,22	71,96	27,59
RF – 30 dias	96,54	2,78	95,97	2,99	96,54	2,78
SVM – 30 dias	91,87	8,46	95,12	3,66	91,87	8,46
SVMp – 1 dia	90,75	15,60	93,25	14,03	90,75	15,60

O segundo melhor cenário seria com o uso da DT e os subconjuntos de 15 dias. Mesmo que as medidas de avaliação do RF tenham sido superiores, não houve diferenças significativas entre seus resultados e os da DT. Neste sentido, a decisão foi tomada com base no cenário que utiliza a menor quantidade de dados (ou seja, menos dias para treino), contribuindo para a redução do custo computacional.

Destaca-se que, apesar da natureza desbalanceada do conjunto de dados, a utilização de pesos no treinamento do SVM melhorou os resultados em apenas 1%, em média. Com isso, concluiu-se que, para este caso, o SVMp não é um algoritmo adequado para tentar compensar o desbalanceamento entre as classes. O desempenho da MLP frente aos demais algoritmos foi insatisfatório para este caso. Apesar de haver ocorrências na literatura com resultados ainda mais baixos do que o obtido neste trabalho (Jeoung *et al.*, 2022), acredita-se que seria possível obter melhorias ajustando os parâmetros iniciais da rede neural (mencionados na seção 3.3).

Por fim, não foi verificada a existência de tendências de aumento ou redução nos valores das medidas de avaliação com o aumento do intervalo de tempo. Este fato corrobora com o fato de que é necessário avaliar diferentes possibilidades a fim de identificar o mais adequado, pois os algoritmos podem ter desempenhos diferentes, mesmo utilizando conjuntos de dados semelhantes.

4.5. Otimização

Conforme exposto na seção 3.3.2, a etapa de otimização do algoritmo teve por objetivo verificar a possibilidade de utilizar menos dados para treinamento, reduzindo o tempo de processamento. Neste sentido, foram comparados os resultados obtidos a partir do treino e teste do KNN com os subconjuntos de 7 dias, utilizando diferentes dados de iluminância:

- Com os dados dos dois sensores instalados (como no teste inicial);
- Apenas com os dados do sensor do teto;
- Apenas com os dados do sensor posicionado na estação de coleta de dados.

Todos os grupos de resultados apresentaram distribuição não-normal, com p-valor menor do que 0,01. A comparação dos grupos pelo teste de Mann-Whitney resultou na matriz exposta na Tabela 28. Verificou-se que os resultados possuem diferenças significativas entre si, pois todos os p-valores estão abaixo de 0,05.

Tabela 28. Matriz de p-valores do teste de Mann-Whitney para comparação de medianas, para os resultados com os dados dos diferentes sensores de iluminância.

Sensor de iluminância utilizado	Estação de coleta de dados	Teto	Estação de coleta de dados + teto
Estação de coleta de dados	-	0,000	0,000
Teto	0,000	-	0,000
Estação de coleta de dados + teto	0,000	0,000	-

Os valores médios das medidas de avaliação obtidas nos diferentes testes estão apresentados na Tabela 29. Observa-se que, para o caso deste trabalho, o melhor resultado foi obtido utilizando os dados dos dois sensores de iluminância. Conforme esperado, os resultados utilizando apenas o sensor do teto foram inferiores. Acredita-se que isto esteja relacionado às variações de iluminância no sensor, que foram menores do que as registradas pelo sensor posicionado sobre o sistema de coleta de dados. Neste sentido, a referência da iluminância real na sala pode ter sido prejudicada, levando o algoritmo a cometer mais erros.

Tabela 29. Resultados dos testes com o KNN e os subconjuntos de 7 dias utilizando diferentes dados de iluminância.

Sensor de iluminância		Estação de coleta de dados	Teto	Estação de coleta de dados + teto
Acurácia (%)	Média	96,75	87,80	97,97
	Desvio padrão	3,76	8,89	2,96
Precisão (%)	Média	96,48	88,68	97,39
	Desvio padrão	4,87	8,92	4,69
Sensibilidade (%)	Média	96,75	87,80	97,97
	Desvio padrão	3,76	8,89	2,96

Ressalta-se, contudo, que a utilização de um subconjunto de dados menor favorece a redução do tempo de processamento do algoritmo. No caso deste trabalho, o tempo de processamento não foi considerado um fator limitante, o que levou a escolha do cenário com as melhores medidas de avaliação. Em outros casos, pode ser necessário optar por resultados inferiores, em favor da velocidade de processamento (Chaudhuri *et al.*, 2018a). É importante

salientar, também, que não foi cogitado reduzir a quantidade de usuários no treinamento do modelo. Ainda que alguns usuários tenham menor tempo de permanência no ambiente que outros, é importante que sejam considerados pelo algoritmo, pois isto pode ser alterado ao longo do tempo.

4.6. Simulação da atualização diária do conjunto de dados

A atualização do conjunto de dados levou em consideração a quantidade de dias de treino identificada como ideal para o algoritmo com melhor desempenho. Levou-se também em consideração a utilização dos dados de iluminância que proporcionaram os melhores resultados. No caso deste trabalho, o melhor resultado foi alcançado utilizando o KNN, 7 dias para treino e duas referências de iluminância.

O conjunto de dados para treinamento inicial continha amostras coletadas entre os dias 07/06/2022 e 14/06/2022. Tendo em vista que o objetivo deste teste é a simulação do funcionamento do algoritmo em um ambiente real, o primeiro dia de teste foi o dia 15/06/2022. O teste seguinte utilizou dados dos dias 08/06/2022 a 15/06/2022 para treino e o dia 16/06/2022 para teste. O procedimento foi repetido até o fim do conjunto completo de dados. A Figura 38 mostra as medidas de avaliação obtidas com a atualização diária do conjunto de dados. Ressalta-se que as linhas de acurácia e sensibilidade se sobrepõem, o que também foi observado em Cosma e Simha (2019) e Aparicio-Ruiz *et al.* (2023).

As quedas periódicas nos valores, observadas durante o período de testes, podem estar relacionadas com a natureza dos dados, isto é, algum padrão de comportamento dos usuários que é alterado. Ainda assim, no dia seguinte o modelo atualiza o conjunto de dados e recupera a qualidade das avaliações. O histograma apresentado na Figura 39 mostra que, dos 246 testes de atualização realizados, apenas 42 (cerca de 17% dos casos) obtiveram valores de acurácia, sensibilidade e precisão abaixo da média, que foi de 98%. Valores abaixo de 85% foram observados em apenas nove casos, o que corresponde a cerca de 3% do total. Por fim, reforça-se o que foi comentado anteriormente a respeito de utilizar apenas a acurácia como medida de avaliação. Neste caso, os baixos valores de sensibilidade e precisão refletiram na acurácia do modelo, mas sempre é importante observar o cenário em conjunto.

Figura 38. Resultado da atualização diária do conjunto de dados.


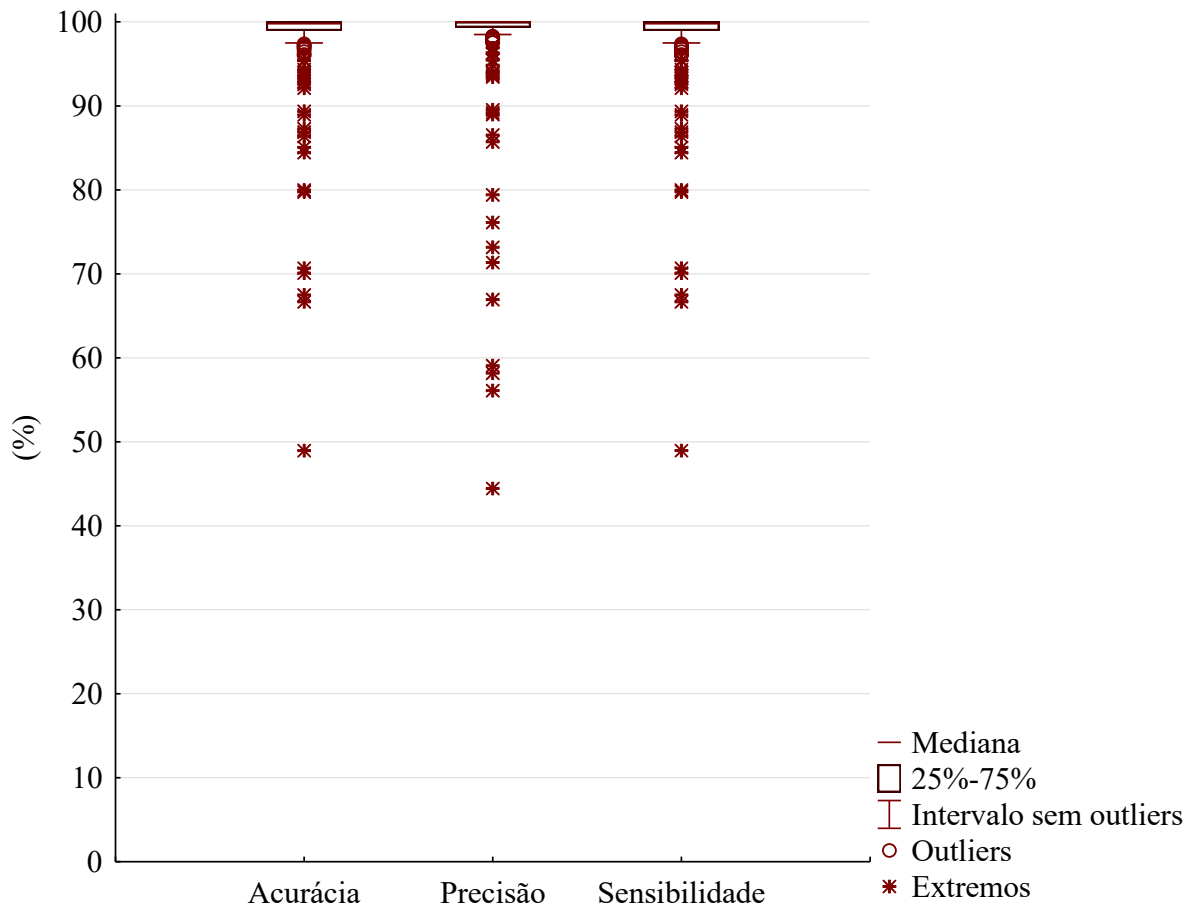


Figura 39. Distribuição dos resultados dos testes simulando um cenário realista com atualização dos dados de treino.



4.7. Importância da avaliação do algoritmo e do subconjunto ideal

Ao longo da análise dos resultados, foram realizadas algumas comparações entre os resultados obtidos neste trabalho e o que se encontra na literatura. É importante ressaltar que estas comparações possuem a finalidade de ilustrar que um mesmo algoritmo pode apresentar resultados distintos conforme o contexto em que é utilizado. Em outras palavras, tratam-se de dados diferentes, locais diferentes, usuários diferentes, outras medidas de comparação, entre outros fatores. Desta forma, optou-se por elencar, no Quadro 4, alguns resultados apresentados na literatura utilizando os algoritmos avaliados neste trabalho.

Quadro 4. Avaliação dos algoritmos em seus respectivos contextos.

Autor(es)	Algoritmo com melhor desempenho	Comparado aos algoritmos
Li, Menassa e Kamat (2017)	RF	SVM e KNN
Chaudhuri <i>et al.</i> (2019)	RF	SVM e RNA
Jung, Jazizadeh e Diller (2019) Ma e Pan (2021) Morresi <i>et al.</i> (2021)	RF	SVM
Cen, Cheng e Wong (2022) Aparicio-Ruiz <i>et al.</i> (2023)	RF	SVM, KNN e DT
Pigliautile <i>et al.</i> (2020)	SVM	RF, KNN, DT
Li <i>et al.</i> (2023a)	SVM	RF, RNA
Yang <i>et al.</i> (2022)	SVM	KNN e DT
Aryal e Becerik-Gerber (2019) Wang <i>et al.</i> (2023)	SVM	RF e KNN
Cosma e Simha (2019)	SVM e RF com desempenho semelhante	
Lu <i>et al.</i> (2019)	SVM	RF
Aryal e Becerik-Gerber (2020) Yu <i>et al.</i> (2022)	KNN	RF, SVM e DT
Peng, Nagy e Schlüter (2019)	MLP	SVM e DT
Jia <i>et al.</i> (2022)	RNA	RF e DT

Verifica-se que não há um algoritmo cujo desempenho seja superior aos demais em termos absolutos. Além da possível variação de parâmetros que pode influenciar nos resultados

obtidos, as características dos conjuntos de dados também podem implicar em resultados mais ou menos precisos. Neste sentido, pode-se mencionar não apenas a quantidade de dados no conjunto, mas o período de duração da coleta de informações.

Ao longo deste capítulo, foi possível observar que a quantidade de dados para treino dos algoritmos não faz, necessariamente, com que os resultados dos testes sejam mais precisos. Sob este aspecto, pode-se afirmar que o desenvolvimento deste trabalho ratificou o que se encontra na literatura. Além disso, fica evidente a necessidade realizar avaliações como a que se propõe neste trabalho. Desta forma, pode-se identificar o algoritmo e o subconjunto mais adequados para treinamento, otimizar a configuração escolhida e, ainda, observar (via simulação computacional) o desempenho do algoritmo em cenário realista.

5. Conclusão

O objetivo deste trabalho foi desenvolver um método que permite identificar a configuração mais adequada para um sistema de controle de iluminação centrado no usuário, em termos de algoritmo e conjunto de dados. Para alcançar este objetivo, quatro objetivos específicos foram traçados.

Inicialmente, um sistema de coleta de dados foi instalado em um laboratório de pesquisa da Universidade Federal de Santa Catarina. Entre junho de 2022 e fevereiro de 2023, o sistema coletou dados de iluminância, temperatura, ocupação, estado das janelas e portas, e estado do sistema de iluminação. Com base na revisão da literatura, optou-se por considerar que as preferências de iluminação dos usuários são representadas por suas interações com o sistema de iluminação. Além disso, a aplicação dos questionários mostrou que os usuários não possuíam reclamações de desconforto a respeito da iluminação no ambiente de trabalho. Portanto, pode-se dizer que o conjunto de dados continha as condições preferidas de iluminação dos usuários do ambiente.

A revisão da literatura mostrou que a abordagem mais utilizada para a identificação das condições de conforto dos usuários é a aprendizagem supervisionada, por conta das características das variáveis. Conforme proposto no segundo objetivo específico, foram selecionados os algoritmos mais utilizados na literatura para realizar os testes com o conjunto de dados obtido.

O conjunto de dados foi pré-processado e organizado em 253 subconjuntos de 1 dia, 241 subconjuntos de 7 dias, 225 subconjuntos de 15 dias e 195 subconjuntos de 30 dias. Os subconjuntos foram testados nos algoritmos *Decision Tree* (DT), *k-Nearest Neighbors* (KNN), *Multilayer Perceptron* (MLP), *Random Forest* (RF) e *Support Vector Machine* (SVM) sem e com ponderação de classes (SVMp). Esta etapa da avaliação visou identificar a capacidade dos algoritmos de prever corretamente os cenários nos quais as lâmpadas deveriam estar acesas, conforme identificado em cada subconjunto de dados. O desempenho de cada conjunto de testes (todos os testes de 1, 7, 15 e 30 dias) foi avaliado por meio de acurácia, precisão e sensibilidade. A verificação de diferenças estatisticamente significativas entre os grupos, juntamente com as medidas de avaliação, permitiu concluir que não há um período de tempo ideal para o treinamento de todos os algoritmos, mas que é possível identificar qual o período de tempo que resulta em melhores resultados. No caso dos dados utilizados neste trabalho, o desempenho ótimo dos algoritmos se deu: com subconjuntos de 15 dias para a DT, com subconjuntos de 7 dias para o KNN, com subconjuntos de 1 dia para a MLP e o SVMp, e com subconjuntos de 30 dias para o RF e o SVM.

Comparando os melhores casos de cada algoritmo a fim de responder ao terceiro objetivo específico, verificou-se que a configuração ideal para o caso deste trabalho seria alcançada utilizando o KNN e 7 dias para o treinamento do algoritmo. Os valores de acurácia, sensibilidade e precisão médias permaneceram em torno de 97%. O segundo melhor cenário seria com a utilização do algoritmo DT e 15 dias para treino. A rede neural, frequentemente utilizada na literatura, mostrou-se inferior aos demais algoritmos na resolução do problema deste trabalho. Salienta-se que, ainda que esta conclusão não possa ser generalizada para qualquer caso, o método utilizado para chegar neste resultado pode ser replicado, a fim de encontrar a configuração ideal para cada contexto.

O processo de otimização mostrou que reduzir a quantidade de dados de iluminância não levaria a melhores resultados para o caso em questão. Neste sentido, considerou-se que o modelo otimizado era o que continha as duas referências de iluminância no treinamento do algoritmo.

O procedimento de atualização dos dados simulou o desempenho do algoritmo em um cenário realista. Isto pode ser útil especialmente quando não há a possibilidade de realizar testes em campo, cenário em que as atualizações são constantes. Os valores médios de acurácia, precisão e sensibilidade, para este teste, foram de aproximadamente 98%. Apenas em 17% dos dias (42 casos) as medidas de avaliação ficaram abaixo dos valores médios. Somente nove casos (3% do total) tiveram resultado menor ou igual a 85%. Esta etapa visou responder ao quarto objetivo e indicou que a configuração otimizada apresentou resultados satisfatórios. Estima-se que as quedas no desempenho do algoritmo possam estar relacionadas com as características do conjunto de dados. Acredita-se que possa haver relação com o padrão de comportamento dos ocupantes, a realização de reuniões e afins. Mesmo assim, as medidas voltaram a níveis adequados nos dias seguintes, demonstrando a capacidade de adaptação do modelo.

O desenvolvimento deste trabalho permitiu identificar o algoritmo de aprendizagem de máquina mais adequado para a utilização em um sistema de controle de iluminação centrado no usuário em um laboratório de pesquisa. A comprovação da eficácia do método, avaliando diferentes algoritmos com vários subconjuntos de dados, visou fornecer meios de comparação para quaisquer algoritmos de aprendizagem supervisionada. Desta forma, pode-se dizer que este método pode ser utilizado para comparar diferentes algoritmos, com diferentes subconjuntos de dados e até mesmo em outros sistemas, como os de climatização. Ressalta-se que, neste trabalho, não foi possível avaliar o desempenho dos algoritmos para o controle da temperatura, pois os ajustes de temperatura não visavam necessariamente o conforto dos usuários, mas o funcionamento da impressora 3D.

A validação do método proposto neste trabalho pode amparar a escolha de algoritmos para uso em sistemas de controle centrados no conforto do usuário. A partir disso, espera-se que estas escolhas não sejam realizadas arbitrariamente, mas por meio de análises prévias e com medidas de avaliação adequadas.

5.1. Limitações da pesquisa

Alguns fatores podem ser mencionados como limitações deste trabalho:

- O sistema de coleta de dados foi confeccionado utilizando equipamentos geralmente utilizados para prototipação. A utilização de equipamentos profissionais poderia conferir maior precisão aos dados coletados e levar a interpretações diferentes dos resultados;
- A identificação da presença dos usuários dependeu da participação dos mesmos. Desta forma, considera-se a possibilidade de que tenham havido falhas (esquecimentos) neste quesito. A utilização de outras formas de identificação dos usuários também pode influenciar no resultado obtido;
- Algumas simplificações precisaram ser realizadas a fim de evitar a necessidade de muitas comparações na fase inicial do método. Em outras palavras, optou-se por utilizar os algoritmos com os parâmetros padrões das bibliotecas. A variação destes parâmetros na fase inicial poderia conduzir a resultados diferentes;
- Outra simplificação diz respeito à combinação de variáveis em cada etapa. Devido ao grande número de variáveis, realizou-se apenas a verificação da influência dos diferentes dados de iluminância no processo de otimização. Não foi estudada a possibilidade de não utilizar variáveis como temperatura ou estado das aberturas;
- Este estudo foi desenvolvido a partir de dados coletados em um único ambiente. Portanto, a configuração considerada ideal para este caso só é válida para a amostra em questão. O resultado obtido não pode ser generalizado para quaisquer situações sem avaliação prévia, conforme proposto no método apresentado.

5.2. Sugestões de trabalhos futuros

Com o desenvolvimento desta pesquisa, notou-se que, ainda que a literatura tenha avançado no sentido de utilizar a aprendizagem de máquina a favor do conforto dos usuários, não há consenso sobre como garantir que isso aconteça. Outros estudos poderiam contribuir para a continuidade das pesquisas neste âmbito, fornecendo embasamento para identificar fatores que podem ser determinantes para cada caso. Diante do exposto, sugere-se:

- A replicação deste método para outros conjuntos de dados, considerando também outras variáveis, subconjuntos de dados e algoritmos, bem como outros sistemas de controle, como o de climatização;
- A ampliação do conjunto de dados, incluindo votos de conforto e preferência obtidos de forma explícita, poderia levar a conclusões diferentes, gerando discussões interessantes a respeito da expectativa dos usuários e sua ação sobre o ambiente;
- A implementação de resultados obtidos a partir da aplicação deste método, em um sistema de controle real, avaliando também a satisfação dos usuários com o funcionamento do sistema de controle;
- A avaliação de diferentes combinações de variáveis na etapa inicial do método, visando identificar as que possuem maior influência sobre o modelo e, possivelmente, otimizar os resultados;
- A investigação de formas de comparar algoritmos de diferentes abordagens (como os de aprendizagem não-supervisionada e por reforço) tendo em vista que nem todas as medidas de avaliação são comuns a todas as abordagens.

Referências

- AGUILERA, J. J.; TOFTUM, J.; KAZANCI, O. B. Predicting personal thermal preferences based on data-driven methods. **E3S Web of Conferences**, v. 111, p. 05015, 13 Aug. 2019.
- AHMADI-KARVIGH, S.; BECERIK-GERBER, B.; SOIBELMAN, L. Intelligent adaptive Automation: A framework for an activity-driven and user-centered building automation. **Energy and Buildings**, v. 188–189, p. 184–199, 1 Apr. 2019.
- AHMADI-KARVIGH, S.; GHAHRAMANI, A.; BECERIK-GERBER, B.; SOIBELMAN, L. One size does not fit all: Understanding user preferences for building automation systems. **Energy and Buildings**, v. 145, p. 163–173, 15 Jun. 2017.
- ALA'RAJ, M.; RADI, M.; ABBOD, M. F.; MAJDALAWIEH, M.; PARODI, M. Data-driven based HVAC optimisation approaches: A Systematic Literature Review. **Journal of Building Engineering**, v. 46, p. 103678, 1 Apr. 2022.
- APARICIO-RUIZ, P.; BARBADILLA-MARTÍN, E.; GUADIX, J.; NEVADO, J. Analysis of Variables Affecting Indoor Thermal Comfort in Mediterranean Climates Using Machine Learning. **Buildings**, v. 13, n. 9, p. 2215, 30 Aug. 2023.
- ARAKAWA MARTINS, L.; SOEBARTO, V.; WILLIAMSON, T. A systematic review of personal thermal comfort models. **Building and Environment**, v. 207, p. 108502, 1 Jan. 2022.
- ARYAL, A.; BECERIK-GERBER, B. A comparative study of predicting individual thermal sensation and satisfaction using wrist-worn temperature sensor, thermal camera and ambient temperature sensor. **Building and Environment**, v. 160, p. 106223, 1 Aug. 2019.
- ARYAL, A.; BECERIK-GERBER, B. Thermal comfort modeling when personalized comfort systems are in use: Comparison of sensing and learning methods. **Building and Environment**, v. 185, p. 107316, 1 Nov. 2020.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR ISO/CIE 8995 - Iluminação de ambientes de trabalho**. [s.l.: s.n.].
- BAEK, J.; PARK, D. Y.; PARK, H.; LE, D. M.; CHANG, S. Vision-based personal thermal comfort prediction based on half-body thermal distribution. **Building and Environment**, v. 228, p. 109877, 15 Jan. 2023.
- BARRETT, E.; LINDER, S. **Autonomous hvac control, a reinforcement learning approach**. Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics). **Anais...** Springer Verlag, 2015. Disponível em: <<http://www.schneider-electric.com/>>. Acesso em: 3 jul. 2021
- BAVARESCO, M. V.; D'OCA, S.; GHISI, E.; LAMBERTS, R. Technological innovations to assess and include the human dimension in the building-performance loop: A review. **Energy and Buildings**, v. 202, p. 109365, 1 Nov. 2019.
- BONACCORSO, G. **Machine Learning Algorithms**. [s.l.] Packt Publishing Ltd, 2017.

- BREIMAN, L. Random forests. **Machine Learning**, v. 45, n. 1, p. 5–32, Oct. 2001.
- CARREIRA, P.; COSTA, A. A.; MANSUR, V.; ARSÉNIO, A. Can HVAC really learn from users? A simulation-based study on the effectiveness of voting for comfort and energy use optimization. **Sustainable Cities and Society**, v. 41, p. 275–285, 1 Aug. 2018.
- CEN, C.; CHENG, S.; WONG, N. H. Physiological sensing of personal thermal comfort with wearable devices in fan-assisted cooling environments in the tropics. **Building and Environment**, v. 225, p. 109622, 1 Nov. 2022.
- CHANG, C. C.; LIN, C. J. LIBSVM. **ACM Transactions on Intelligent Systems and Technology (TIST)**, v. 2, n. 3, p. 27, 6 May 2011.
- CHAUDHURI, T.; SOH, Y. C.; LI, H.; XIE, L. A feedforward neural network based indoor-climate control framework for thermal comfort and energy saving in buildings. **Applied Energy**, v. 248, p. 44–53, 15 Aug. 2019.
- CHAUDHURI, T.; ZHAI, D.; SOH, Y. C.; LI, H.; XIE, L. Thermal comfort prediction using normalized skin temperature in a uniform built environment. **Energy and Buildings**, v. 159, p. 426–440, 15 Jan. 2018a.
- CHAUDHURI, T.; ZHAI, D.; SOH, Y. C.; LI, H.; XIE, L. Random forest based thermal comfort prediction from gender-specific physiological parameters using wearable sensing technology. **Energy and Buildings**, v. 166, p. 391–406, 1 May 2018b.
- CHEN, K.; XU, Q.; LEOW, B.; GHARAMANI, A. Personal thermal comfort models based on physiological measurements – A design of experiments based review. **Building and Environment**, v. 228, p. 109919, 15 Jan. 2023.
- CHENG, Z.; ZHAO, Q.; WANG, F.; JIANG, Y.; XIA, L.; DING, J. Satisfaction based Q-learning for integrated lighting and blind control. **Energy and Buildings**, v. 127, p. 43–55, 1 Sep. 2016.
- CHEW, I.; KARUNATILAKA, D.; TAN, C. P.; KALAVALLY, V. Smart lighting: The way forward? Reviewing the past to shape the future. **Energy and Buildings**, v. 149, p. 180–191, 15 Aug. 2017.
- CHOI, J. H.; YEOM, D. Development of the data-driven thermal satisfaction prediction model as a function of human physiological responses in a built environment. **Building and Environment**, v. 150, p. 206–218, 1 Mar. 2019.
- COSMA, A. C.; SIMHA, R. Machine learning method for real-time non-invasive prediction of individual thermal preference in transient conditions. **Building and Environment**, v. 148, p. 372–383, 15 Jan. 2019.
- DAI, X.; LIU, J.; ZHANG, X. **A review of studies applying machine learning models to predict occupancy and window-opening behaviours in smart buildings**. **Energy and Buildings** Elsevier Ltd, , 15 Sep. 2020.
- DAY, J. K. et al. A review of select human-building interfaces and their relationship to human behavior, energy use and occupant comfort. **Building and Environment**, v. 178, p. 106920, 1 Jul. 2020.

- DAY, J. K.; GUNDERSON, D. E. Understanding high performance buildings: The link between occupant knowledge of passive design systems, corresponding behaviors, occupant comfort and environmental satisfaction. **Building and Environment**, v. 84, p. 114–124, 1 Jan. 2015.
- DE VILLE, B. Decision trees. **Wiley Interdisciplinary Reviews: Computational Statistics**, v. 5, n. 6, p. 448–455, 1 Nov. 2013.
- DENG, Z.; CHEN, Q. Development and validation of a smart HVAC control system for multi-occupant offices by using occupants' physiological signals from wristband. **Energy and Buildings**, v. 214, p. 109872, 1 May 2020.
- DJENOURI, D.; LAIDI, R.; DJENOURI, Y.; BALASINGHAM, I. Machine Learning for Smart Building Applications. **ACM Computing Surveys**, v. 52, n. 2, p. 1–36, 27 Mar. 2019.
- GARDNER, M. W.; DORLING, S. R. Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences. **Atmospheric Environment**, v. 32, n. 14–15, p. 2627–2636, 1 Aug. 1998.
- GHAHRAMANI, A.; TANG, C.; BECERIK-GERBER, B. An online learning approach for quantifying personalized thermal comfort via adaptive stochastic modeling. **Building and Environment**, v. 92, p. 86–96, 1 Oct. 2015.
- GRASSI, B.; PIANA, E. A.; LEZZI, A. M.; PILOTELLI, M. A Review of Recent Literature on Systems and Methods for the Control of Thermal Comfort in Buildings. **Applied Sciences (Switzerland)**, v. 12, n. 11, p. 5473, 1 Jun. 2022.
- GUNAY, H. B.; O'BRIEN, W.; BEAUSOLEIL-MORRISON, I.; BURSILL, J. Development and implementation of a thermostat learning algorithm. **Science and Technology for the Built Environment**, v. 24, n. 1, p. 43–56, 2 Jan. 2018.
- GUNAY, H. B.; O'BRIEN, W.; BEAUSOLEIL-MORRISON, I.; GILANI, S. Development and implementation of an adaptive lighting and blinds control algorithm. **Building and Environment**, v. 113, p. 185–199, 15 Feb. 2017.
- GUNAY, H. B.; O'BRIEN, W.; BEAUSOLEIL-MORRISON, I.; HUCHUK, B. On adaptive occupant-learning window blind and lighting controls. **Building Research and Information**, v. 42, n. 6, p. 739–756, 1 Jan. 2014.
- HAIR, J. F.; BLACK, W. C.; BABIN, B. J.; ANDERSON, R. E.; TATHAM, R. L. **Análise multivariada de dados**. 6. ed. Porto Alegre: Bookman, 2009.
- HALHOUL MERABET, G.; ESSAAIDI, M.; BEN HADDOU, M.; QOLOMANY, B.; QADIR, J.; ANAN, M.; AL-FUQAHA, A.; ABID, M. R.; BENHADDOU, D. Intelligent building control systems for thermal comfort and energy-efficiency: A systematic review of artificial intelligence-assisted techniques. **Renewable and Sustainable Energy Reviews**, v. 144, p. 110969, 1 Jul. 2021.
- HAN, M.; MAY, R.; ZHANG, X.; WANG, X.; PAN, S.; YAN, D.; JIN, Y.; XU, L. A review of reinforcement learning methodologies for controlling occupant comfort in buildings. **Sustainable Cities and Society**, v. 51, p. 101748, 1 Nov. 2019.

HEGAZY, M.; YASUFUKU, K.; ABE, H. Evaluating and visualizing perceptual impressions of daylighting in immersive virtual environments. **Journal of Asian Architecture and Building Engineering**, 2020.

HELLWIG, R. T.; SCHWEIKER, M.; BOERSTRA, A. **The ambivalence of personal control over indoor climate - How much personal control is adequate?** E3S Web of Conferences. **Anais...EDP Sciences**, 30 Jun. 2020. Disponível em: <https://www.e3s-conferences.org/articles/e3sconf/abs/2020/32/e3sconf_nsb2020_06010/e3sconf_nsb2020_06010.html>. Acesso em: 24 may. 2021

HEYDARIAN, A.; PANTAZIS, E.; GERBER, D.; BECERIK-GERBER, B. **Defining Lighting Settings to Accommodate End-User Preferences while Reducing Energy Consumption in Buildings**. Construction Research Congress 2016: Old and New Construction Technologies Converge in Historic San Juan - Proceedings of the 2016 Construction Research Congress, CRC 2016. **Anais...American Society of Civil Engineers (ASCE)**, 2016.

HEYDARIAN, A.; PANTAZIS, E.; WANG, A.; GERBER, D.; BECERIK-GERBER, B. Towards user centered building design: Identifying end-user lighting preferences via immersive virtual environments. **Automation in Construction**, v. 81, p. 56–66, 1 Sep. 2017.

HONG, T.; WANG, Z.; LUO, X.; ZHANG, W. State-of-the-art on research and applications of machine learning in the building life cycle. **Energy and Buildings**, v. 212, p. 109831, 1 Apr. 2020.

IEA-EBC. **Annex 66 - Definition and Simulation of Occupant Behavior in Buildings**. Disponível em: <<https://annex66.iea-ebc.org/>>. Acesso em: 27 jan. 2020a.

IEA-EBC. **Annex 79 - Occupant Behaviour-Centric Building Design and Operation**. Disponível em: <<http://annex79.iea-ebc.org/>>. Acesso em: 27 jan. 2020b.

INTERNATIONAL ENERGY AGENCY. **Lighting**. Disponível em: <<https://www.iea.org/energy-system/buildings/lighting#tracking>>.

INTHARACHATHORN, K.; JAREEMIT, D.; WATCHARAPINCHAI, S. Potential use of an extended-distance thermal imaging camera for the assessment of thermal comfort in multi-occupant spaces. **Building and Environment**, v. 246, p. 110949, 1 Dec. 2023.

JAYATHISSA, P.; QUINTANA, M.; ABDELRAHMAN, M.; MILLER, C. Humans-as-a-Sensor for Buildings—Intensive Longitudinal Indoor Comfort Models. **Buildings**, v. 10, n. 10, p. 174, 1 Oct. 2020.

JEOUNG, J.; JUNG, S.; HONG, T.; CHOI, J.-K. Blockchain-based IoT system for personalized indoor temperature control. **Automation in Construction**, v. 140, p. 104339, 1 Aug. 2022.

JIA, M.; CHOI, J. H.; LIU, H.; SUSMAN, G. Development of facial-skin temperature driven thermal comfort and sensation modeling for a futuristic application. **Building and Environment**, v. 207, p. 108479, 1 Jan. 2022.

JIANG, L.; YAO, R. Modelling personal thermal sensations using C-Support Vector Classification (C-SVC) algorithm. **Building and Environment**, v. 99, p. 98–106, 1 Apr.

2016.

JUNG, S.; JEOUNG, J.; HONG, T. Occupant-centered real-time control of indoor temperature using deep learning algorithms. **Building and Environment**, v. 208, p. 108633, 15 Jan. 2022.

JUNG, W.; JAZIZADEH, F.; DILLER, T. E. Heat Flux Sensing for Machine-Learning-Based Personal Thermal Comfort Modeling. **Sensors**, v. 19, n. 17, p. 3691, 25 Aug. 2019.

KARJALAINEN, S. Should it be automatic or manual - The occupant's perspective on the design of domestic control systems. **Energy and Buildings**, v. 65, p. 119–126, 1 Oct. 2013.

KATIĆ, K.; LI, R.; VERHAART, J.; ZEILER, W. Neural network based predictive control of personalized heating systems. **Energy and Buildings**, v. 174, p. 199–213, 1 Sep. 2018.

KATIĆ, K.; LI, R.; ZEILER, W. Machine learning algorithms applied to a prediction of personal overall thermal comfort using skin temperatures and occupants' heating behavior. **Applied Ergonomics**, v. 85, p. 103078, 1 May 2020.

KHAN, D. S.; KOLARIK, J. Can occupant voting systems provide energy savings and improved occupant satisfaction in buildings?—a review. **Science and Technology for the Built Environment**, v. 28, n. 2, p. 221–239, 2022.

KHAN, D. S.; KOLARIK, J.; WEITZMANN, P. Design and application of occupant voting systems for collecting occupant feedback on indoor environmental quality of buildings – A review. **Building and Environment**, v. 183, p. 107192, 1 Oct. 2020.

KIM, J.; SCHIAVON, S.; BRAGER, G. Personal comfort models – A new paradigm in thermal comfort for occupant-centric environmental control. **Building and Environment**, v. 132, p. 114–124, 15 Mar. 2018.

KJÆRGAARD, M. B.; DONG, B.; CARLUCCI, S.; SALIM, F. D.; YANG, J.; ANDREWS, C. J.; ARDAKANIAN, O. **Data-driven occupant modeling strategies and digital tools enabled by IEA EBC annex 79**. Proceedings of the 5th Conference on Systems for Built Environments - BuildSys '18. **Anais...**New York, New York, USA: ACM Press, 2018. Disponível em: <<http://dl.acm.org/citation.cfm?doid=3276774.3281015>>. Acesso em: 6 nov. 2019

KOHAVI, R. **A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection**. International Joint Conference on Artificial Intelligence. **Anais...**1995. Disponível em: <<http://robotics.stanford.edu/~ronnyk>>. Acesso em: 12 oct. 2023

LAFTCHIEV, E.; ROMERES, D.; NIKOVSKI, D. Personalizing Individual Comfort in the Group Setting. **Proceedings of the AAAI Conference on Artificial Intelligence**, v. 35, n. 17, p. 15339–15346, 18 May 2021.

LAROSE, D. T.; LAROSE, C. D. k -Nearest Neighbor Algorithm . **Discovering Knowledge in Data**, p. 149–164, 23 Jun. 2014.

LATINI, A.; DI GIUSEPPE, E.; D’ORAZIO, M. Immersive virtual vs real office environments: A validation study for productivity, comfort and behavioural research. **Building and Environment**, v. 230, p. 109996, 15 Feb. 2023.

- LEE, S.; KARAVA, P. Towards smart buildings with self-tuned indoor thermal environments – A critical review. **Energy and Buildings**, v. 224, p. 110172, 1 Oct. 2020.
- LEI, Y.; ZHAN, S.; ONO, E.; PENG, Y.; ZHANG, Z.; HASAMA, T.; CHONG, A. A practical deep reinforcement learning framework for multivariate occupant-centric control in buildings. **Applied Energy**, v. 324, p. 119742, 15 Oct. 2022.
- LI, D.; MENASSA, C. C.; KAMAT, V. R. Personalized human comfort in indoor building environments under diverse conditioning modes. **Building and Environment**, v. 126, p. 304–317, 1 Dec. 2017.
- LI, D.; MENASSA, C. C.; KAMAT, V. R. Non-intrusive interpretation of human thermal comfort through analysis of facial infrared thermography. **Energy and Buildings**, v. 176, p. 246–261, 1 Oct. 2018.
- LI, K.; LI, W.; LIU, F.; XUE, W. Non-invasive human thermal comfort assessment based on multiple angle/distance facial key-region temperatures recognition. **Building and Environment**, v. 246, p. 110956, 1 Dec. 2023a.
- LI, S.; ZHANG, X.; LI, Y.; GAO, W.; XIAO, F.; XU, Y. A comprehensive review of impact assessment of indoor thermal environment on work and cognitive performance - Combined physiological measurements and machine learning. **Journal of Building Engineering**, v. 71, 15 Jul. 2023b.
- LI, W.; ZHANG, J.; ZHAO, T. Indoor thermal environment optimal control for thermal comfort and energy saving based on online monitoring of thermal sensation. **Energy and Buildings**, v. 197, p. 57–67, 15 Aug. 2019.
- LI, W.; ZHANG, J.; ZHAO, T.; LIANG, R. Experimental research of online monitoring and evaluation method of human thermal sensation in different active states based on wristband device. **Energy and Buildings**, v. 173, p. 613–622, 15 Aug. 2018.
- LI, W.; ZHANG, J.; ZHAO, T.; REN, J. Experimental study of an indoor temperature fuzzy control method for thermal comfort and energy saving using wristband device. **Building and Environment**, v. 187, p. 107432, 1 Jan. 2021.
- LIAN, X.; ZHU, H.; ZHANG, X.; JIN, Y.; ZHOU, H.; HE, B.; LI, Z. Recognition of typical environmental control behavior patterns of indoor occupants based on temporal series association analysis. **Building and Environment**, v. 234, p. 110170, 15 Apr. 2023.
- LÓPEZ-LOVILLO, R. M.; DOMÍNGUEZ-AMARILLO, S.; SENDRA, J. J.; ACOSTA, I. How can a daylighting and user-oriented control system be configured? A state-of-the-art critical review. **Journal of Building Engineering**, v. 64, p. 105704, 1 Apr. 2023.
- LU, S.; COCHRAN HAMEEN, E. An Interactive Task Conditioning System Featuring Personal Comfort Models and Non-Intrusive Sensing Techniques: A Field Study in Shanghai. **Technologies**, v. 9, n. 4, p. 90, 21 Nov. 2021.
- LU, S.; WANG, W.; WANG, S.; HAMEEN, E. C. Thermal Comfort-Based Personalized Models with Non-Intrusive Sensing Technique in Office Buildings. **Applied Sciences**, v. 9, n. 9, p. 1768, 28 Apr. 2019.

MA, G.; PAN, X. Research on a Visual Comfort Model Based on Individual Preference in China through Machine Learning Algorithm. **Sustainability**, v. 13, n. 14, p. 7602, 7 Jul. 2021.

MAHMOUDZADEH, P.; AFACAN, Y.; ADI, M. N. Analyzing occupants' control over lighting systems in office settings using immersive virtual environments. **Building and Environment**, v. 196, p. 107823, 1 Jun. 2021.

MALAVAZOS, C.; PAPANIKOLAOU, A.; TSATSAKIS, K.; HATZOPLAKI, E. **Combined Visual Comfort and Energy Efficiency through True Personalization of Automated Lighting Control**. Proceedings of the 4th International Conference on Smart Cities and Green ICT Systems. **Anais...SCITEPRESS - Science and Technology Publications**, 2015. Disponível em: <<http://www.scitepress.org/DigitalLibrary/Link.aspx?doi=10.5220/0005455602640270>>. Acesso em: 31 may. 2021

MANDARIC, K.; SKOCIR, P.; JEZIC, G. **Context-based System for User-Centric Smart Environment**. 2020 International Conference on Software, Telecommunications and Computer Networks (SoftCOM). **Anais...IEEE**, 17 Sep. 2020. Disponível em: <<https://ieeexplore.ieee.org/document/9238215/>>. Acesso em: 22 may. 2021

MORRESI, N.; CASACCIA, S.; SORCINELLI, M.; ARNESANO, M.; URIARTE, A.; TORRENS-GALDIZ, J. I.; REVEL, G. M. Sensing Physiological and Environmental Quantities to Measure Human Thermal Comfort Through Machine Learning Techniques. **IEEE Sensors Journal**, v. 21, n. 10, p. 12322–12337, 15 May 2021.

NAGY, Z.; YONG, F. Y.; FREI, M.; SCHLUETER, A. Occupant centered lighting control for comfort and energy efficient building operation. **Energy and Buildings**, v. 94, p. 100–108, 1 May 2015.

NAGY, Z.; YONG, F. Y.; SCHLUETER, A. Occupant centered lighting control: A user study on balancing comfort, acceptance, and energy consumption. **Energy and Buildings**, v. 126, p. 310–322, 15 Aug. 2016.

NAYLOR, S.; GILLOTT, M.; LAU, T. A review of occupant-centric building control strategies to reduce building energy use. **Renewable and Sustainable Energy Reviews**, v. 96, p. 1–10, 1 Nov. 2018.

NISE, N. S. **Engenharia de sistemas de controle**. 6. ed. Rio de Janeiro: LTC, 2012. v. xiv

O'BRIEN, W. et al. An international review of occupant-related aspects of building energy codes and standards. **Building and Environment**, v. 179, p. 106906, 15 Jul. 2020a.

O'BRIEN, W.; GAETANI, I.; CARLUCCI, S.; HOES, P.-J.; HENSEN, J. L. M. On occupant-centric building performance metrics. **Building and Environment**, v. 122, p. 373–385, 1 Sep. 2017.

O'BRIEN, W.; WAGNER, A.; SCHWEIKER, M.; MAHDAVI, A.; DAY, J.; KJÆRGAARD, M. B.; CARLUCCI, S.; DONG, B.; TAHMASEBI, F.; YAN, D.; HONG, T.; GUNAY, H. B.; NAGY, Z.; MILLER, C.; BERGER, C. Introducing IEA EBC annex 79: Key challenges and opportunities in the field of occupant-centric building design and operation. **Building and Environment**, v. 178, p. 106738, 1 Jul. 2020b.

OUF, M. M.; PARK, J. Y.; GUNAY, H. B. A simulation-based method to investigate occupant-centric controls. **Building Simulation**, v. 14, n. 4, p. 1017–1030, 1 Aug. 2020.

PARK, J. Y.; DOUGHERTY, T.; FRITZ, H.; NAGY, Z. LightLearn: An adaptive and occupant centered controller for lighting based on reinforcement learning. **Building and Environment**, v. 147, p. 397–414, 1 Jan. 2019a.

PARK, J. Y.; NAGY, Z. **HVACLearn: A reinforcement learning based occupant-centric control for thermostat set-points**. e-Energy 2020 - Proceedings of the 11th ACM International Conference on Future Energy Systems. **Anais...Association for Computing Machinery, Inc**, 12 Jun. 2020. Disponível em: <<https://doi.org/10.1145/3396851.3402364>>. Acesso em: 25 may. 2021

PARK, J. Y.; OUF, M. M.; GUNAY, B.; PENG, Y.; O'BRIEN, W.; KJÆRGAARD, M. B.; NAGY, Z. A critical review of field implementations of occupant-centric building controls. **Building and Environment**, v. 165, p. 106351, 1 Nov. 2019b.

PEDREGOSA, F.; VAROQUAUX, G.; GRAMFORT, A.; MICHEL, V.; THIRION, B.; GRISEL, O.; BLONDEL, M.; PRETTENHOFER, P.; WEISS, R.; DUBOURG, V.; VANDERPLAS, J.; PASSOS, A.; COURNAPEAU, D.; BRUCHER, M.; PERROT, M.; DUCHESNAY, É. Scikit-learn: Machine Learning in Python. **Journal of Machine Learning Research**, v. 12, n. 85, p. 2825–2830, 2011.

PELLEGRINO, A.; LO VERSO, V. R. M.; BLASO, L.; ACQUAVIVA, A.; PATTI, E.; OSELLO, A. Lighting Control and Monitoring for Energy Efficiency: A Case Study Focused on the Interoperability of Building Management Systems. **IEEE Transactions on Industry Applications**, v. 52, n. 3, p. 2627–2637, 1 May 2016.

PENG, Y.; LEI, Y.; TEKLER, Z. D.; ANTANURI, N.; LAU, S. K.; CHONG, A. Hybrid system controls of natural ventilation and HVAC in mixed-mode buildings: A comprehensive review. **Energy and Buildings**, v. 276, p. 112509, 1 Dec. 2022.

PENG, Y.; NAGY, Z.; SCHLÜTER, A. Temperature-preference learning with neural networks for occupant-centric building indoor climate controls. **Building and Environment**, v. 154, p. 296–308, 1 May 2019.

PIGLIAUTILE, I.; CASACCIA, S.; MORRESI, N.; ARNESANO, M.; PISELLO, A. L.; REVEL, G. M. Assessing occupants' personal attributes in relation to human perception of environmental comfort: Measurement procedure and data analysis. **Building and Environment**, v. 177, p. 106901, 15 Jun. 2020.

PLÖRER, D.; HAMMES, S.; HAUER, M.; VAN KARSBERGEN, V.; PFLUGER, R. Control strategies for daylight and artificial lighting in office buildings-a bibliometrically assisted review. **Energies**, v. 14, n. 13, p. 3852, 1 Jul. 2021.

PUTRADA, A. G.; ABDUROHMAN, M.; PERDANA, D.; NUHA, H. H. Machine Learning Methods in Smart Lighting Toward Achieving User Comfort: A Survey. **IEEE Access**, v. 10, p. 45137–45178, 2022.

QAVIDEL FARD, Z.; ZOMORODIAN, Z. S.; KORSAVI, S. S. Application of machine learning in thermal comfort studies: A review of methods, performance and challenges. **Energy and Buildings**, v. 256, p. 111771, 1 Feb. 2022.

- RAJITH, A.; SOKI, S.; HIROSHI, M. **Real-time optimized HVAC control system on top of an IoT framework**. 2018 Third International Conference on Fog and Mobile Edge Computing (FMEC). *Anais...IEEE*, 23 Apr. 2018. Disponível em: <<https://ieeexplore.ieee.org/document/8364062/>>. Acesso em: 4 jul. 2021
- ROSA, A. S. DA. **Análise de agrupamentos aplicada à obtenção de modelos de referência para estudos de desempenho térmico de edificações**. Florianópolis: Universidade Federal de Santa Catarina, Feb. 2019.
- RUSSELL, S. J.; NORVIG, P. **Artificial Intelligence: a modern approach**. 3. ed. [s.l.] Prentice Hall, 2009.
- SADEGHI, S. A.; LEE, S.; KARAVA, P.; BILIONIS, I.; TZEMPELIKOS, A. Bayesian classification and inference of occupant visual preferences in daylight perimeter private offices. *Energy and Buildings*, v. 166, p. 505–524, 1 May 2018.
- SALEHI, B.; GHANBARAN, A. H.; MAEREFAT, M. Intelligent models to predict the indoor thermal sensation and thermal demand in steady state based on occupants' skin temperature. *Building and Environment*, v. 169, p. 106579, 1 Feb. 2020.
- SANSANIWAL, S. K.; KUMAR, S.; JAIN, N.; MATHUR, J.; MATHUR, S. Towards implementing an indoor environmental quality standard in buildings: A pilot study. <https://doi.org/10.1177/0143624421997989>, v. 42, n. 4, p. 449–483, 8 Mar. 2021.
- SARKAR, C.; NAMBI, A. U.; PRASAD, V. **iLTC: Achieving Individual Comfort in Shared Spaces**. Proceedings of the 2016 International Conference on Embedded Wireless Systems and Networks. *Anais...Jan.* 2016. Disponível em: <<https://dl.acm.org/doi/10.5555/2893711.2893723>>. Acesso em: 5 jul. 2021
- SHAN, C.; HU, J.; WU, J.; ZHANG, A.; DING, G.; XU, L. X. Towards non-intrusive and high accuracy prediction of personal thermal comfort using a few sensitive physiological parameters. *Energy and Buildings*, v. 207, p. 109594, 15 Jan. 2020.
- SUTTON, R. S.; BARTO, A. G. **Reinforcement Learning - An Introduction**. 2. ed. Cambridge: MIT Press, 2018.
- TABADKANI, A.; ROETZEL, A.; LI, H. X.; TSANGRASSOULIS, A. A review of occupant-centric control strategies for adaptive facades. *Automation in Construction*, v. 122, p. 103464, 1 Feb. 2021.
- WANG, L.; DALGO, D. A.; MATTISE, N.; ZHU, S.; SREBRIC, J. Physiological responses and data-driven thermal comfort models with personal conditioning devices (PCD). *Building and Environment*, v. 236, p. 110290, 15 May 2023.
- WANG, Z.; HONG, T. Learning occupants' indoor comfort temperature through a Bayesian inference approach for office buildings in United States. *Renewable and Sustainable Energy Reviews*, v. 119, p. 109593, 1 Mar. 2020.
- WU, Y.; CAO, B.; HU, M.; LV, G.; MENG, J.; ZHANG, H. Development of personal comfort model and its use in the control of air conditioner. *Energy and Buildings*, v. 285, p. 112900, 15 Apr. 2023.

- XIE, J.; LI, H.; LI, C.; ZHANG, J.; LUO, M. Review on occupant-centric thermal comfort sensing, predicting, and controlling. **Energy and Buildings**, v. 226, p. 110392, 1 Nov. 2020.
- XIONG, J.; AWALGAONKAR, N. M.; TZEMPELIKOS, A.; BILIONIS, I.; KARAVA, P. Efficient learning of personalized visual preferences in daylight offices: An online elicitation framework. **Building and Environment**, v. 181, p. 107013, 15 Aug. 2020.
- YANG, B.; LI, X.; LIU, Y.; CHEN, L.; GUO, R.; WANG, F.; YAN, K. Comparison of models for predicting winter individual thermal comfort based on machine learning algorithms. **Building and Environment**, v. 215, p. 108970, 1 May 2022.
- YU, C.; LI, B.; WU, Y.; CHEN, B.; KOSONEN, R.; KILPELAINEN, S.; LIU, H. Performances of machine learning algorithms for individual thermal comfort prediction based on data from professional and practical settings. **Journal of Building Engineering**, v. 61, p. 105278, 1 Dec. 2022.
- ZHANG, H.; TZEMPELIKOS, A. Thermal preference-based control studies: review and detailed classification. <https://doi.org/10.1080/23744731.2021.1877041>, v. 27, n. 8, p. 1031–1039, 2021.
- ZHANG, H.; TZEMPELIKOS, A.; LIU, X.; LEE, S.; CAPPELLETTI, F.; GASPARELLA, A. The impact of personal preference-based thermal control on energy use and thermal comfort: Field implementation. **Energy and Buildings**, v. 284, p. 112848, 1 Apr. 2023.
- ZHANG, K.; YU, H.; TANG, Y.; LUO, M.; SU, Z.; LI, C. Quantitative Investigation of Body Part Selection for Data-Driven Personal Overall Thermal Preference Prediction. **Buildings**, v. 12, n. 2, p. 170, 4 Feb. 2022.
- ZHANG, W.; WU, Y.; CALAUTIT, J. K. A review on occupancy prediction through machine learning for enhancing energy efficiency, air quality and thermal comfort in the built environment. **Renewable and Sustainable Energy Reviews**, v. 167, p. 112704, 1 Oct. 2022.
- ZHONG, C.; CHOI, J. H. **Development of a Data-Driven Approach for Human-Based Environmental Control**. Procedia Engineering. Anais...Elsevier Ltd, 1 Jan. 2017.
- ZHU, H.; LIAN, X.; LIU, Y.; ZHANG, Y.; LI, Z. Consideration of occupant preferences and habits during the establishment of occupant-centric buildings: A critical review. **Energy and Buildings**, v. 280, p. 112720, 1 Feb. 2023.
- ZHU, M.; PAN, Y.; WU, Z.; XIE, J.; HUANG, Z.; KOSONEN, R. An occupant-centric air-conditioning system for occupant thermal preference recognition control in personal micro-environment. **Building and Environment**, v. 196, p. 107749, 1 Jun. 2021.
- ZHU, Y.; SAEIDI, S.; RIZZUTO, T.; ROETZEL, A.; KOOIMA, R. Potential and challenges of immersive virtual environments for occupant energy behavior modeling and validation: A literature review. **Journal of Building Engineering**, v. 19, p. 302–319, 1 Sep. 2018.

Apêndice A

Quadro A1. Síntese das principais características dos sistemas de controle centrados na preferência do usuário.

Autor(es)	Inferência	Simulação	Controle	Duração do estudo	Indicação de preferência	Algoritmo(s)	Avaliação do sistema
Gunay <i>et al.</i> (2014)	-	Iluminação, persianas	-	1 ano	Interação com o sistema	FK	Número de interações e economia de energia
Ghahramani, Tang e Becerik-Gerber (2015)	Conforto térmico	-	-	5 – 90 dias	Voto	RB, KNN, RLog, DT, SVM	Acurácia, especificidade
Nagy <i>et al.</i> (2015)	-	-	Iluminação	6 semanas	Interação com o sistema	análise estatística dinâmica	Economia de energia
Cheng <i>et al.</i> (2016)	-	-	Iluminação	10 dias	Voto	<i>Q-Learning</i>	Satisfação do usuário e economia de energia
Jiang e Yao (2016)	Sensação térmica	-	-	90 minutos por usuário	Voto	C-SVC	Acurácia
Nagy, Yong e Schlueter (2016)	-	-	Iluminação	12 semanas	Interação com o sistema	análise estatística dinâmica	Número de interações e satisfação dos usuários

Quadro A1 (continuação). Síntese das principais características dos sistemas de controle centrados na preferência do usuário.

Autor(es)	Inferência	Simulação	Controle	Duração do estudo	Indicação de preferência	Algoritmo(s)	Avaliação do sistema
Sarkar, Nambi e Prasad (2016)	-	-	Iluminação, climatização	1 ano	Voto	<i>clusterização</i>	Satisfação do usuário e potencial de economia de energia
Gunay <i>et al.</i> (2017)	-	-	Iluminação, persianas	1 ano	Interação com o sistema	RLog	Número de interações
Li, Menassa e Kamat (2017)	-	-	Climatização	3 semanas	Voto	RLog, KNN, RF, SVM	Acurácia
Zhong e Choi (2017)	Conforto térmico	-	-	65 minutos por usuário	Voto	RNA	Acurácia, probabilidade de conforto, sensibilidade
Carreira <i>et al.</i> (2018)	-	Climatização	-	1 mês (inverno)	Voto	<i>k-means</i>	Economia de energia e conforto
Chaudhuri <i>et al.</i> (2018a)	Conforto térmico	-	-	1 hora por usuário	Voto	SVM, ELM	Acurácia

Quadro A1 (continuação). Síntese das principais características dos sistemas de controle centrados na preferência do usuário.

Autor(es)	Inferência	Simulação	Controle	Duração do estudo	Indicação de preferência	Algoritmo(s)	Avaliação do sistema
Chaudhuri <i>et al.</i> (2018b)	Conforto térmico	-	-	40 minutos por usuário	Voto	RF	Acurácia, sensibilidade, precisão
Gunay <i>et al.</i> (2018)	-	-	Climatização	1 ano	Interação com o sistema	RLog	Número de interações
Katic <i>et al.</i> c	Conforto térmico	-	-	14 dias	Voto	NARX, NAR, SVR, GPR, <i>Boosted Trees</i> , <i>Bagged Trees</i>	MSE, RMSE
Li <i>et al.</i> (2018)	Sensação térmica	-	-	7 horas	Voto	RL	R ²
Li, Menassa e Kamat (2018)	Conforto térmico	-	-	3 horas por usuário	Voto	RF	Acurácia
Rajith, Soki e Hiroshi (2018)	-	-	Climatização	~ 3 meses (verão)	Voto	RNA	Economia de energia e conforto

Quadro A1 (continuação). Síntese das principais características dos sistemas de controle centrados na preferência do usuário.

Autor(es)	Inferência	Simulação	Controle	Duração do estudo	Indicação de preferência	Algoritmo(s)	Avaliação do sistema
Sadeghi <i>et al.</i> (2018)	Preferência visual	-	-	1 dia/ usuário	Voto	Classificação Bayesiana + <i>clusterização</i>	Acurácia
Aguilera, Toftum e Kazanci (2019)	Preferência térmica	-	-	13 dias	Voto	RNA, NB, <i>Fuzzy</i>	AUC
Aryal e Becerik-Gerber (2019)	Sensação e satisfação térmica	-	-	3 meses	Voto	RF, SVM, KNN, S-LD	Acurácia
Chaudhuri <i>et al.</i> (2019)	Conforto térmico	-	-	100 minutos	Voto	SVM, RF, CNN, RNA	Acurácia
Choi e Yeom (2019)	Satisfação térmica	-	-	100 minutos	Voto	J48 (DT)	Acurácia
Cosma e Simha (2019)	Conforto térmico	-	-	27 minutos por usuário	Voto	SVM, KNC, GPC, RFC	Acurácia, precisão, sensibilidade

Quadro A1 (continuação). Síntese das principais características dos sistemas de controle centrados na preferência do usuário.

Autor(es)	Inferência	Simulação	Controle	Duração do estudo	Indicação de preferência	Algoritmo(s)	Avaliação do sistema
Jung, Jazizadeh e Diller (2019)	Preferência térmica	-	-	120 minutos por usuário	Voto	RF, SVM, RLog	Acurácia, F1-score
Li, Zhang e Zhao (2019)	-	-	Climatização	6 dias	Voto	RL	Satisfação do usuário e economia de energia
Lu <i>et al.</i> (2019)	Conforto térmico	-	-	6 dias	Voto	SVM, RF	Precisão, sensibilidade, F1-score
Park <i>et al.</i> (2019a)	-	-	Iluminação	2 meses	Interação com o sistema	<i>Q-Learning</i>	LUR, UNC, LCR ² , satisfação dos usuários
Peng, Nagy e Schlüter (2019)	-	-	Climatização	5 meses	Interação com o sistema	GNB, DT, C-SVC, MLP	Acurácia e número de interações
Aryal e Becerik-Gerber (2020)	Sensação e satisfação térmica	-	-	6 horas	Voto	RF, KNN, SVM, DT	Acurácia

² Light Utilization Ratio, Unmet Comfort Ratio, Lights to Comfort Ratio

Quadro A1 (continuação). Síntese das principais características dos sistemas de controle centrados na preferência do usuário.

Autor(es)	Inferência	Simulação	Controle	Duração do estudo	Indicação de preferência	Algoritmo(s)	Avaliação do sistema
Deng e Chen (2020)	-	Climatização	-	3 semanas	Voto	RNA	R ² , satisfação do usuário e economia de energia
Hu <i>et al.</i> (2020)	Conforto térmico	-	-	15 horas por usuário	Voto	RNA	Acurácia, MAE, MSE
Jayathissa <i>et al.</i> (2020)	Preferência térmica, visual e acústica	-	-	2 semanas	Voto	k-means + RF	Acurácia, F1-score
Katic, Li, Zeiler (2020)	Conforto térmico	-	-	14 dias	Voto	SVM, RUS- <i>Boosted Trees</i> , <i>Boosted Trees</i> , <i>Bagged Trees</i>	Acurácia, AUC
Mandaric, Skocir e Jezic (2020)	-	-	Iluminação	1 dia	Voto	RNA	Acurácia e satisfação dos usuários
Ouf, Park e Gunay (2020)	-	Iluminação, climatização, persianas	-	3 anos	Interação com o sistema	análise estatística dinâmica, RLog	Número de interações e economia de energia

Quadro A1 (continuação). Síntese das principais características dos sistemas de controle centrados na preferência do usuário.

Autor(es)	Inferência	Simulação	Controle	Duração do estudo	Indicação de preferência	Algoritmo(s)	Avaliação do sistema
Park e Nagy (2020)	-	Climatização	-	1 ano	Interação com o sistema	<i>Q-Learning</i>	Número de interações
Pigliautile <i>et al.</i> (2020)	Sensação térmica	-	-	40 – 105 minutos por usuário	Voto	LDA, KNN, DT, NB, SVM, RF	Acurácia
Salehi, Ghanbaran e Maerefat (2020)	Sensação térmica	-	-	3 horas	Voto	RNA, DT, GPR, FR	Acurácia, R ² , MAE
Xiong <i>et al.</i> (2020)	Preferência de iluminação	-	-	2 dias por usuário	Voto e interação	Inferência Bayesiana	Análise qualitativa
Laftchiev, Romeres e Nikovski (2021)	-	Climatização	-	10 dias	Interação com o Sistema	RNA	MAE, RMSE
Li <i>et al.</i> (2021)	-	-	Climatização	9 dias	Voto	RL	Satisfação dos usuários e economia de energia

Quadro A1 (continuação). Síntese das principais características dos sistemas de controle centrados na preferência do usuário.

Autor(es)	Inferência	Simulação	Controle	Duração do estudo	Indicação de preferência	Algoritmo(s)	Avaliação do sistema
Lu e Hameen (2021)	Sensação e satisfação térmica	-	-	2 dias por usuário	Voto e interação	SVM	Sensibilidade, número de interações
Ma e Pan (2021)	Conforto visual	-	-	6 meses	Voto	CT, RF, SVM, GMM	Acurácia, precisão, sensibilidade, F1-score, AUC
Morresi <i>et al.</i> (2021)	Conforto térmico	-	-	100 minutos por usuário	Voto	SVM, RF, ETC	Acurácia
Zhu <i>et al.</i> (2021)	-	-	Climatização	4 meses	Interação com o sistema	MLP	MSE
Cen, Cheng e Wong (2022)	Sensação térmica, temperatura e velocidade do ar preferidas	-	-	4 dias	Voto	RLog, SVM, KNN, DT, RF, XGB, LGBM	Acurácia, AUC
Jeoung <i>et al.</i> (2022)	-	-	Climatização	16 dias	Voto	RF, SVM, DT, GB, RNA	Acurácia, satisfação dos usuários e economia de energia

Quadro A1 (continuação). Síntese das principais características dos sistemas de controle centrados na preferência do usuário.

Autor(es)	Inferência	Simulação	Controle	Duração do estudo	Indicação de preferência	Algoritmo(s)	Avaliação do sistema
<i>Jia et al. c</i>	Sensação e conforto térmico	-	-	90 minutos por usuário	Voto	GB, RF, RLog, DT, RNA	Acurácia
Jung, Jeoung e Hong (2022)	-	-	Climatização	21 dias	Voto	<i>Reinforcement Learning-based</i>	Satisfação dos usuários e economia de energia
<i>Lei et al. (2022)</i>	-	-	Climatização	2 semanas	Voto	<i>Branching Dueling Q-Network</i>	Satisfação dos usuários e economia de energia
<i>Yang et al. (2022)</i>	Sensação. preferência e conforto térmico	-	-	18 horas por usuário	Voto	DT, KNN, SVM, EL	Acurácia, sensibilidade, precisão, F1-score
<i>Yu et al. (2022)</i>	Sensação térmica	-	-	150 minutos	Voto	SVM, DT, KNN, DA, BT, RF, RUS-BT, S-KNN	Acurácia, sensibilidade, precisão, AUC
<i>Zhang et al. (2022)</i>	Preferência térmica	-	-	3 meses	Voto	RF	Acurácia, precisão, sensibilidade, AUC, Cohen's Kappa

Quadro A1 (continuação). Síntese das principais características dos sistemas de controle centrados na preferência do usuário.

Autor(es)	Inferência	Simulação	Controle	Duração do estudo	Indicação de preferência	Algoritmo(s)	Avaliação do sistema
Baek <i>et al.</i> (2023)	Conforto térmico	-	-	2 dias por usuário	Voto	CNN	Acurácia, F1-score
Wang <i>et al.</i> (2023)	Conforto térmico	-	-	100 minutos por usuário	Voto e interação	SVM, KNN, RF	Acurácia, F1-score, AUC
Wu <i>et al.</i> (2023)	-	-	Climatização	90 minutos por usuário	Voto	RF	Acurácia e satisfação dos usuários
Zhang <i>et al.</i> (2023)	-	-	Climatização	8 dias	Voto	RLog multinomial	Satisfação dos usuários e economia de energia
Intharachathorn <i>et al.</i> (2023)	Sensação térmica	-	-	120 minutos por usuário	Voto	DT	Acurácia
Li <i>et al.</i> (2023a)	Conforto e sensação térmica	-	-	195 minutos por usuário	Voto	RF, ELM, SVM	Acurácia

Quadro A1 (continuação). Síntese das principais características dos sistemas de controle centrados na preferência do usuário.

Autor(es)	Inferência	Simulação	Controle	Duração do estudo	Indicação de preferência	Algoritmo(s)	Avaliação do sistema
Aparicio-Ruiz <i>et al.</i> (2023)	Sensação térmica	-	-	1 ano	Voto	RF, DT, SVM, KNN, NB	Acurácia, sensibilidade, precisão, F1-score

Apêndice B

Legenda: (-2) Discordo totalmente, (-1) Discordo, (0) Neutro, (1) Concordo, (2) Concordo totalmente

Tabela B1. Respostas obtidas por meio dos questionários

Digite o código do seu cartão RFID (sem os pontos):	A95BBE99	69A3D498	99E3C399	6934C599	39D1CE99	7995C199	821759b4	D14D523F	E26A2B13	A98C9898	F2AF4513	C25c5313	22AF5713	D21C79B4	D2B265b4	E2E86513	624a6cb4	59f6cd99
Quantas horas por semana, em média, você permanece no escritório/laboratório?	11h - 20h	11h - 20h	mais de 40h	até 10h	até 10h	até 10h	11h - 20h	até 10h	até 10h	até 10h	11h - 20h	até 10h	até 10h	11h - 20h	até 10h	11h - 20h	até 10h	até 10h
Sua principal tarefa é realizada no computador	0	0	0	1	0	-1	1	1	1	-2	2	1	1	2	1	0	0	1
Sua principal tarefa é de leitura e escrita em papel	-1	0	-1	-1	0	-1	0	0	1	0	2	0	-1	1	-1	2	0	0
Você tem interesse em tecnologias de automação e controle dos sistemas das edificações	1	1	2	2	2	1	1	2	1	1	2	1	1	1	1	0	1	1
Você faz esforço para economizar energia, sempre que possível	0	1	-2	1	1	2	1	2	2	1	2	1	1	2	2	-1	1	-1
Você sacrifica seu conforto para economizar energia	-1	0	-2	0	0	2	0	0	0	1	0	-1	1	1	0	-1	0	-2
Você prefere iluminação natural do que artificial	1	0	-1	-1	-1	1	0	2	1	2	0	0	2	1	-2	0	1	2
Você aciona a iluminação artificial apenas quando considera que não há luz natural o suficiente para desempenhar o seu trabalho	0	1	-1	-1	1	2	1	2	2	2	1	1	1	2	1	1	1	1
Você desliga a iluminação artificial quando está muito claro	1	1	-2	1	1	1	1	2	2	2	2	2	1	1	1	-1	1	2

Tabela B1 (continuação). Respostas obtidas por meio dos questionários

Digite o código do seu cartão RFID (sem os pontos):	A95BBE99	69A3D498	99E3C399	6934C599	39D1CE99	7995C199	821759b4	D14D523F	E26A2B13	A98C9898	F2AF4513	C25c5313	22AF5713	D21C79B4	D2B265b4	E2E86513	624a6cb4	59f6cd99
Você está satisfeito com as condições térmicas do seu ambiente de trabalho	0	1	1	1	0	1	1	0	1	0	1	1	-1	2	1	0	0	1
Você está satisfeito com a qualidade da ventilação natural no seu ambiente de trabalho	0	1	2	-1	0	1	1	0	1	0	1	-1	1	1	2	-1	1	1
Você está satisfeito com a qualidade da climatização artificial do seu ambiente de trabalho	-1	1	-2	1	0	1	1	0	1	0	1	1	-1	1	1	1	0	0
A incidência de radiação solar direta no seu ambiente de trabalho lhe incomoda	-2	-2	-1	-1	0	-1	0	0	-1	1	0	0	-1	0	0	-1	0	0
Você se sente confortável sob as condições de climatização do seu ambiente de trabalho	0	1	1	0	1	1	1	0	1	0	1	1	0	1	1	1	1	0
Você considera importante ter controle sobre a iluminação no seu ambiente de trabalho	1	2	1	2	1	2	1	2	2	2	0	2	2	2	1	2	0	2
Você sente que tem controle sobre a iluminação no seu ambiente de trabalho	0	2	1	0	0	1	1	1	0	1	0	0	1	1	1	1	1	1
Você considera importante ter controle sobre a climatização no seu ambiente de trabalho	1	2	2	1	1	1	1	2	1	2	0	2	2	2	-1	1	1	2
Você sente que tem controle sobre a climatização no seu ambiente de trabalho	-1	1	2	1	1	1	1	0	1	0	0	2	-1	0	-1	-1	0	0