

UNIVERSIDADE FEDERAL DE MINAS GERAIS
Instituto de Ciências Exatas
Programa de Pós-Graduação em Ciência da Computação

Álvaro Antônio Fonseca de Souza

Personalização de Conforto em Ambientes Inteligentes por Transferência de
Conhecimento em Aprendizado Profundo

Belo Horizonte
2023

Álvaro Antônio Fonseca de Souza

**Personalização de Conforto em Ambientes Inteligentes por Transferência de
Conhecimento em Aprendizado Profundo**

Versão Final

Dissertação apresentada ao Programa de Pós-Graduação em
Ciência da Computação da Universidade Federal de Minas
Gerais, como requisito parcial à obtenção do título de Mestre
em Ciência da Computação.

Orientador: Daniel Fernandes Macedo

Belo Horizonte
2023

2023, Álvaro Antônio Fonseca de Souza.
Todos os direitos reservados

Souza, Álvaro Antônio Fonseca de.

S729p

Personalização de conforto em ambientes inteligentes por transferência de conhecimento em aprendizado profundo [recurso eletrônico] / Álvaro Antônio Fonseca de Souza – 2023.

1 recurso online (100 f. il., color.) : pdf.

Orientador: Daniel Fernandes Macedo.

Dissertação (mestrado) - Universidade Federal de Minas Gerais, Instituto de Ciências Exatas, Departamento de Ciência da Computação.

Referências: f.90-96.

1. Computação – Teses. 2. Aprendizado do computador – Teses. 3. Redes neurais (Computação) – Teses. 4. Algoritmos de predição – Teses. 5. Transferência do conhecimento – Teses
I. Macedo, Daniel Fernandes. II. Universidade Federal de Minas Gerais, Instituto de Ciências Exatas, Departamento de Ciência da Computação. III. Título.

CDU 519.6*82(043)

Ficha catalográfica elaborada pela bibliotecária Irenquer Vismeg Lucas Cruz
CRB 6/819 - Universidade Federal de Minas Gerais – ICEX



UNIVERSIDADE FEDERAL DE MINAS GERAIS
INSTITUTO DE CIÊNCIAS EXATAS
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

FOLHA DE APROVAÇÃO

Personalização de Conforto em Ambientes Inteligentes por Transferência
de Conhecimento em Aprendizado Profundo

ÁLVARO ANTÔNIO FONSECA DE SOUZA

Dissertação defendida e aprovada pela banca examinadora constituída pelos Senhores:

PROF. DANIEL FERNANDES MACEDO - Orientador
Departamento de Ciência da Computação - UFMG

gov.br Documento assinado digitalmente
DANIEL FERNANDES MACEDO
Data: 29/01/2024 14:38:33-0300
Verifique em <https://validar.iti.gov.br>

PROF. JOSÉ MARCOS SILVA NOGUEIRA
Departamento de Ciência da Computação - UFMG

gov.br Documento assinado digitalmente
JOSE MARCOS SILVA NOGUEIRA
Data: 31/01/2024 17:30:58-0300
Verifique em <https://validar.iti.gov.br>

PROF. LUIZ HENRIQUE ANDRADE CORREIA
Departamento de Ciência da Computação - UFPA

gov.br Documento assinado digitalmente
LUIZ HENRIQUE ANDRADE CORREIA
Data: 29/01/2024 15:29:27-0300
Verifique em <https://validar.iti.gov.br>

PROF. ALEX BORGES VIEIRA
Departamento de Ciência da Computação - UFPA

gov.br Documento assinado digitalmente
ALEX BORGES VIEIRA
Data: 29/01/2024 15:09:25-0300
Verifique em <https://validar.iti.gov.br>

Belo Horizonte, 15 de dezembro de 2023.

A Deus, minha esposa Cláudia, minha mãe, meu irmão e meus amigos.

Agradecimentos

Inicialmente quero agradecer ao meu orientador Daniel por seus muitos anos de dedicação em me orientar desde a graduação. Com a sua ajuda pude compreender muito melhor os caminhos que me permitiram desenvolver este e outros trabalhos. Com isso consegui crescer tanto como pessoa quanto como profissional.

Agradeço aos amigos do Laboratório Winet (DCC-UFMG), em especial ao Guilherme e ao Marcos que me auxiliaram e participaram comigo nesta jornada de aprendizado que é o mestrado.

Agradeço a Deus e a minha esposa Cláudia que me deram forças e motivação para seguir com esse projeto mesmo após tanto tempo de batalha.

Agradeço aos meus amigos e melhores pessoas que me apoiaram e me deram forças durante esse grande período de trabalho.

Agradeço a minha mãe e meu irmão pela compreensão e apoio durante essa jornada.

Agradeço também aos amigos que fiz durante o mestrado que deixaram essa jornada mais leve, reestabelecendo minhas motivações a cada interação nas salas e corredores do ICEX.

Agradeço as agências de fomento científico, em especial à Fapemig, CNPq e CAPES, que possibilitaram minha dedicação à pesquisa com fomento financeiro, sem o qual não seria possível me dedicar integralmente ao mestrado e à pesquisa.

“Se eu consigo imaginar, por que não pode existir?”
(Álvaro Antônio Fonseca de Souza)

Resumo

A predição de conforto personalizado em ambientes inteligentes pode ser muito benéfica para seus usuários. A exemplo, escritórios inteligentes personalizados podem proporcionar um maior bem-estar e maior desempenho laboral ao otimizar a sensação de conforto dos usuários. No entanto, para a geração de modelos de predição de conforto, algoritmos de aprendizado de máquina tradicionais requerem uma quantidade de dados rotulados cara em termos de tempo e recursos. Ambientes inteligentes normalmente geram uma quantidade baixa de dados em um período aceitável de tempo, e este problema se agrava com a personalização do conforto. Esta requer coleta consciente de dados individuais do usuário, esbarrando em problemas de indisponibilidade e assiduidade do usuário em fornecer os dados solicitados. A nossa proposta aplica a transferência de conhecimento com ajuste fino para reduzir o tempo de aprendizado de um ambiente inteligente personalizado. Essa técnica permite que modelos pré-treinados em outras tarefas transfiram o conhecimento obtido para uma nova tarefa. Os resultados mostraram que a transferência de conhecimento melhora o desempenho inicial de um modelo em comparação com o treinamento sem a transferência de conhecimento. Os resultados mostraram uma melhoria na acurácia em relação aos modelos sem transferência de conhecimento. A melhoria variou de 2,24% a 14,82%, sendo a melhoria média de 7,93% em todas as combinações de usuários alvo e fonte.

Palavras-chave: Conforto Personalizado, Ambientes Inteligentes, Aprendizado de Máquina, Redes Neurais Artificiais, Algoritmo de Predição, Transferência de conhecimento, Ajuste Fino.

Abstract

Predicting personalized comfort in smart environments can be very beneficial for its users. For example, personalized smart offices can improve the well-being and work performance by optimizing the users' sense of comfort. However, in order to generate comfort prediction models, traditional machine learning algorithms require an amount of labeled data that is expensive in terms of time and financial resources. Smart environments typically generate a low amount of data in an acceptable period of time, and this problem becomes worse with the personalization of comfort. Personalization requires the collection of individual user data, facing problems of user availability and willingness to provide the requested data. Our proposal applies knowledge transfer with fine-tuning to reduce the learning time of a personalized intelligent environment. This technique allows models pre-trained on other tasks to transfer the knowledge obtained to a new task. Our evaluation we performed with three different data sets. The results showed that knowledge transfer improves the performance of a model when compared to training without knowledge transfer. The improvement ranged from 2.24% to 14.82%, with the average improvement being 7.93% across all combinations of target and source users.

Keywords: Personalized Comfort, Smart Environments, Machine Learning, Artificial Neural Networks, Prediction Algorithm, Knowledge Transfer, Fine-Tuning.

Lista de Figuras

1.1	Escritório inteligente implementado no DCC-UFMG.	16
2.1	Ilustração da composição de ambientes inteligentes.	21
2.2	Plataforma ManIoT: gerente local.	23
2.3	Plataforma ManIoT: gerente global.	24
2.4	Espaço de hipóteses de um aprendizado de máquinas.	25
2.5	Neurônio artificial.	26
2.6	Função Sigmoid.	28
2.7	Função tanh.	28
2.8	Função ReLU.	29
2.9	Função softmax, exemplo.	29
2.10	Rede neural artificial (ANN).	30
2.11	Efeito do tamanho da taxa de aprendizado.	32
2.12	Transferência de conhecimento com ajuste fino.	34
2.13	Ciclo da metodologia CRISP-DM.	35
3.1	Tela do software de coleta de informações.	44
4.1	<i>Hardware</i> multi sensor MultiSensor 6 Aeotec.	53
4.2	Tela de perguntas de conforto do <i>SmartHomeOffice</i>	53
4.3	Escritório residencial inteligente implementado em casa.	54
4.4	Matriz de correlação do conjunto de dados 1 não normalizado.	62
4.5	Matriz de correlação do conjunto de dados 2 não normalizado.	63
4.6	Matriz de correlação do conjunto de dados 3 não normalizado.	63
4.7	Ciclo de controle do ambiente.	66
4.8	Arquitetura de sistema do ciclo de predição e atuação.	67
5.1	Rede Neural Artificial densa com 5 neurônios de entrada e 7 neurônios de saída.	70
5.2	Rede Neural Artificial densa com 5 neurônios de entrada e 7 neurônios de saída e mais de uma camada oculta.	71
5.3	Exemplificação da estratificação.	75
5.4	Comparação das melhores acurácias obtidas no modelo de classificação.	79
5.5	Comparação das matrizes de confusão com e sem transferência de conhecimento do usuário 2 para o usuário 1 da modelagem de classificação.	82

5.6	Comparação das matrizes de confusão com e sem transferência de conhecimento do usuário 3 para o usuário 1 da modelagem de classificação.	83
5.7	Aumento das acurácias dos rótulos para cada par de dados alvo fonte.	84
5.8	Aumento médio da acurácia de cada rótulo.	85
5.9	Porcentagem de aproximações dos rótulos da diagonal principal por rótulo em valores absolutos.	86
A.1	Comparação das matrizes de confusão com e sem transferência de conhecimento do usuário 1 para o usuário 2 da modelagem de classificação.	98
A.2	Comparação das matrizes de confusão com e sem transferência de conhecimento do usuário 3 para o usuário 2 da modelagem de classificação.	98
A.3	Comparação das matrizes de confusão com e sem transferência de conhecimento do usuário 1 para o usuário 3 da modelagem de classificação.	99
A.4	Comparação das matrizes de confusão com e sem transferência de conhecimento do usuário 2 para o usuário 3 da modelagem de classificação.	99
A.5	Comparação das matrizes de confusão com e sem transferência de conhecimento do usuário 1 para o usuário 3 da modelagem de classificação com redução na quantidade de rótulos de conforto do conjunto de dados 3.	100
A.6	Comparação das matrizes de confusão com e sem transferência de conhecimento do usuário 2 para o usuário 3 da modelagem de classificação com redução na quantidade de rótulos de conforto do conjunto de dados 3.	100

Lista de Tabelas

3.1	Trabalhos relacionados e suas demandas de coletas de dados.	48
3.2	Comparação entre trabalhos relacionados e este trabalho.	48
4.1	Mapeamento da avaliação de valores categóricos de diferentes condições de luminosidade do ambiente.	51
4.2	Formalização do conjunto de dados.	52
4.3	Relação de coleta e perda de dados.	55
4.4	Relação de distribuição dos rótulos dos conjuntos de dados.	60
4.5	Métricas do conjunto de dados 1.	61
4.6	Métricas do conjunto de dados 2.	61
4.7	Métricas do conjunto de dados 3.	61
4.8	Tabela <i>P-values</i> do teste de <i>Kolmogorov-Smirnov</i>	65
5.1	Mapeamento da avaliação de valores categóricos de diferentes condições de luminosidade do ambiente e valores incrementados na intensidade luminosa das lâmpadas.	70
5.2	Tabela de valores de hiperparâmetros utilizados na busca em grade.	71
5.3	Hiperparâmetros do modelo de classificação das melhores acurácias dos usuários alvo.	78
5.4	Comparação do tempo necessário para coleta de dados com e sem a transferência de conhecimento.	80

Sumário

1	Introdução	14
1.1	Motivação	16
1.2	Objetivos	17
1.3	Contribuições	18
1.4	Organização do Documento	18
2	Conceitos básicos	20
2.1	Entendimento do negócio	20
2.2	ManIoT	22
2.3	Aprendizado de máquina	24
2.3.1	Redes Neurais Artificiais	26
2.3.1.1	Funções de ativação	27
2.3.1.2	Perceptron multi camadas	29
2.3.2	Como uma rede neural aprende?	31
2.3.3	Transferência de Conhecimento	31
2.3.4	Ajuste fino	33
2.3.5	Pesquisa em grade	33
2.4	Metodologia CRISP-DM	35
2.5	Conclusões	37
3	Trabalhos relacionados	38
3.1	Ambientes inteligentes	38
3.2	Ambientes inteligentes personalizados	41
3.3	Aprendizado de máquina com poucos dados	44
3.4	Conclusões	48
4	Entendimento, Preparação e Análise dos Dados	50
4.1	Entendimento e Preparação dos Dados	50
4.1.1	Características do ambiente	51
4.1.2	Condições e propriedades das coletas de dados	52
4.1.3	Dificuldades nas coletas dos dados	56
4.2	Preparação dos dados coletados	57
4.3	Análise dos dados	60
4.3.1	Correlação das Características	62

4.3.2	Análise de similaridade entre os conjuntos de dados	64
4.4	Ciclo de controle	65
4.5	Conclusões	66
5	Modelagem dos dados e Avaliação do Modelo	68
5.1	Modelagem dos dados	68
5.1.1	Seleção da técnica de modelagem	68
5.1.2	Transferência de conhecimento com ajuste fino	69
5.1.3	Número de neurônios de entrada e saída	69
5.1.4	Hiperparâmetros definidos para pesquisa em grade	71
5.2	Geração de projeto de teste	72
5.2.1	Acurácia	73
5.2.2	Matriz de Confusão	73
5.3	Construção do modelo	73
5.3.1	Linguagem de programação e bibliotecas	74
5.3.2	Construção da amostragem estratificada	74
5.3.3	<i>Early Stop e Dropout</i>	75
5.4	Avaliação dos resultados da modelagem	76
5.4.1	Análise de resultados dos hiperparâmetros	76
5.4.2	Análise de resultados das Acurácias	78
5.4.3	Análise de resultados das matrizes de confusão	81
5.5	Conclusões	86
6	Conclusões	87
6.1	Conclusões	87
6.2	Trabalhos Futuros	88
6.3	Dificuldades	88
	Referências	90
	Apêndice A Matrizes de confusão	97
A.1	Modelagem com redução do rótulo de confortável no conjunto de dados 3 .	97

Capítulo 1

Introdução

A Internet das Coisas (IoT) do inglês *Internet of Things* é um novo paradigma, cunhado por [5]. O paradigma vem se desenvolvendo com o surgimento de novas tecnologias móveis, como, por exemplo, o *smartphone* e o *smartwatch*. Uma IoT é composta por dispositivos com sensores e atuadores conectados a uma rede [6]. A principal característica de IoT é a inteligência atribuída aos dispositivos conectados à rede ou a um controlador central. Estes aparelhos fornecem informações a respeito de sua interação com o ambiente. A possibilidade de obter informações permite aos dispositivos ou ao controlador central poder tomar decisões inteligentes [2].

Os ambientes inteligentes são locais supervisionáveis que predizem as preferências do usuário de forma autônoma. O escritório inteligente é um ambiente inteligente em particular. Este é um local de trabalho com dispositivos sensores e atuadores conectados à rede. Estes dispositivos desempenham tarefas para tornar o escritório o mais adaptado possível às preferências de conforto do usuário.

Este trabalho se baseia no conceito de conforto, cujo objetivo é dar o máximo de conforto possível aos usuários, através do gerenciamento autônomo de um escritório inteligente. Pensando nesse objetivo, é necessário definir o que é conforto para ser possível empregar seu conceito neste trabalho.

[35] define que conforto é um estado de ter as necessidades de alívio, tranquilidade e transcendência satisfeitos em quatro contextos: físico, psicoespiritual, social e ambiental. O conforto é um conceito que vai além da ausência de dor ou outros desconfortos. Alívio é o estado de quem teve uma necessidade, específica, satisfeita. A tranquilidade é um estado de calma, sossego ou satisfação. Transcendência é o estado onde é possível superar problemas ou dor [53]. A sensação de conforto é individual e subjetiva, por depender das percepções pessoais de cada indivíduo [44]. Isso quer dizer que, em uma dada situação, uma pessoa pode se sentir mais ou menos confortável se comparado com outrem. Por ser algo subjetivo e individual, não há um padrão que abrange a sensação de conforto de todas as pessoas ao mesmo tempo.

Pelo fato do conforto ser um conceito pessoal, surgiu a necessidade de personalização de conforto nos escritórios inteligentes. A personalização do conforto nos escritórios inteligentes se resume no ajuste dos parâmetros do modelo de predição de conforto do

ambiente inteligente, de forma que o modelo realize previsões otimizadas para um único indivíduo ou um grupo específico de indivíduos. Para tanto, é necessário que um algoritmo adaptável seja instanciado no sistema de gerenciamento dos dispositivos. O algoritmo de um sistema personalizado requer que seus parâmetros sejam ajustados ao usuário, em um processo que chamamos de treinamento.

Para treinar a previsão de um ambiente inteligente, é necessário que haja interação dos usuários com o ambiente. Por causa dessa interação, o tempo de coleta de uma quantidade de dados úteis pode ser bem grande.

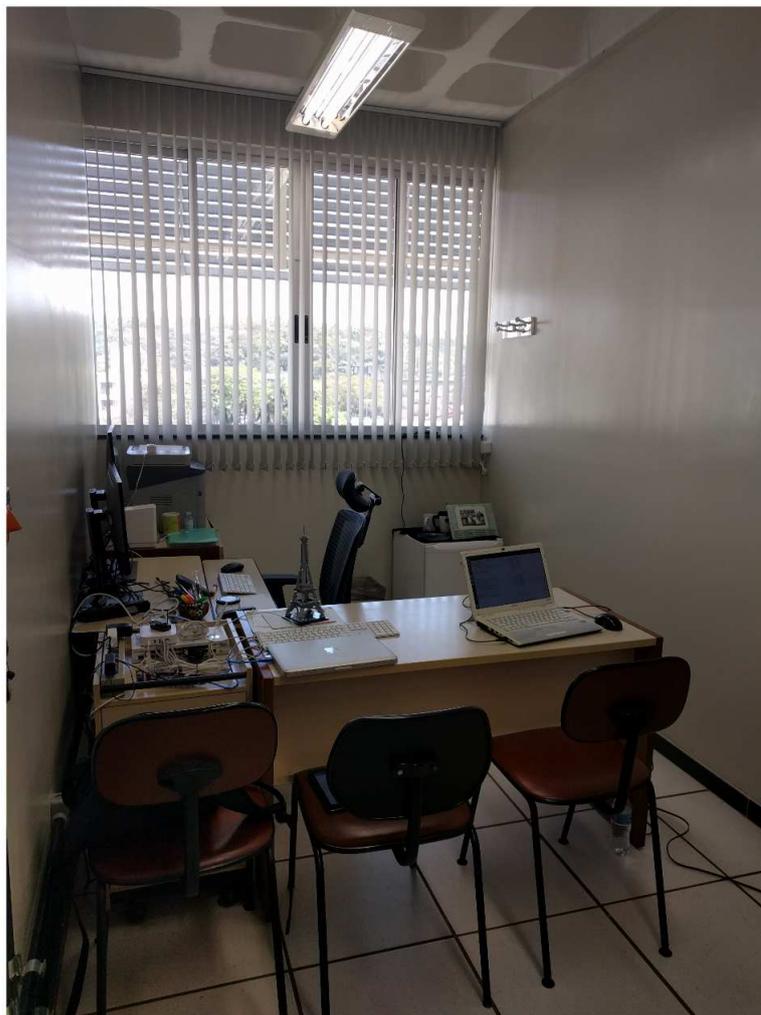
[13] implementou um ambiente inteligente de teste com coleta de dados de diversos sensores em um apartamento do dormitório do campus da WSU (*Washington State University*). A coleta de dados demorou 5 meses, este foi o tempo necessário para se obter uma quantidade de dados suficiente para aplicar um algoritmo de aprendizado de máquina. Em [13] a acurácia do *LogiBoost*, o melhor algoritmo aplicado, foi de 90%. Ao aplicar o algoritmo (SMO — *Sequential Minimal Optimization*) a acurácia foi de 70%. Isso nos mostra que o algoritmo adequado pode ter melhor desempenho em conjuntos de dados e tarefas diferentes independentes do tamanho do conjunto de dados.

No exemplo anterior, a quantidade de dados gerada era superior à quantidade de dados que geralmente se obtém em um escritório inteligente personalizado. Isso se deve pela maior quantidade de interações e pelo grande número de usuários. No nosso escritório, apenas uma pessoa interagiu diretamente com as funcionalidades do ambiente. Assim, um sistema personalizado não consegue capturar muitos dados de interação do usuário em um curto tempo. Em um trabalho relacionado a este projeto, o período de treinamento de um escritório inteligente personalizado foi de 25 dias [19].

No trabalho de [19], um escritório inteligente real foi montado na sala do professor Daniel Macedo no departamento de Ciência da Computação da UFMG (DCC), como mostra a Figura 1.1. Na sala do professor foram auferidas e controladas condições do ambiente como temperatura, luminosidade, ruído e outras propriedades. Com isso, o sistema inferia as condições do recinto quando o professor chegava em seu local de trabalho. O controlador autônomo ajustava a temperatura do ar-condicionado, a abertura das persianas, a luminosidade da sala, entre outros, através de atuadores. Tal ajuste era feito tendo em vista as preferências pessoais do usuário.

Com tudo o que foi dito anteriormente, percebe-se a necessidade de empregar métodos de aprendizado de máquina que permitam reduzir o tempo de treinamento de um ambiente inteligente. Como visto, é inviável a implementação do escritório inteligente personalizado real caso o treinamento deste demorar mais do que alguns poucos dias.

Figura 1.1: Escritório inteligente implementado no DCC-UFMG.



Fonte: [19], 2019.

1.1 Motivação

O correto funcionamento de um ambiente supervisionado requer alta acurácia de predição, dessa forma o aprendizado de máquina requer uma quantidade grande de dados para refinar o treinamento do preditor. Quanto maior a quantidade de dados maior será a precisão do preditor, dessa forma é necessário coletar a maior quantidade de dados possível. Porém, o tempo de coleta de uma quantidade de dados suficiente para treinar um sistema de aprendizado de máquina em ambientes inteligentes é inviável para implementação no mundo real. Atualmente o tempo de aprendizado de um ambiente inteligente personalizado é longo demais para o usuário, o que nos motiva a desenvolver este trabalho.

Um ambiente inteligente requer muito tempo para obter uma quantidade suficiente de dados, pois estes dependem da interação dos usuários com o ambiente para serem gerados. Como já exemplificado, o processo de coleta de dados pode levar meses para

obter uma quantidade de dados satisfatória em um ambiente com algumas unidades de usuários. O problema fica ainda maior em um escritório inteligente personalizado, este necessita de muito mais tempo para obter uma quantidade satisfatória de informações do usuário. Isto é devido aos fatos de ter apenas um usuário e o número de interações com o sistema ser bem menor que em um ambiente multiusuário.

Como veremos nos próximos capítulos, a obtenção de dados não é um problema exclusivo de aprendizado personalizado e sim do aprendizado de ambientes supervisionados, em geral. Como dito anteriormente, o problema fica mais nítido quando é implementado em ambientes personalizados.

1.2 Objetivos

O objetivo principal é reduzir o tempo necessário de aprendizado de máquina para predição de conforto personalizado em ambientes com poucos dados. Para isso, o projeto se propôs a empregar o método de transferência de conhecimento com ajuste fino na modelagem de aprendizado de máquina para personalizar a predição de conforto em um ambiente inteligente. Como experimentação para realizar a prova de conceito, foi implementado um ambiente inteligente que controla o conforto luminosos dos usuários. Este ambiente é composto por lâmpadas inteligentes, as quais são os atuadores do ambiente, sensores de luminosidade, temperatura e umidade e um sistema inteligente de controle dos atuadores. No ambiente implementado, a modelagem pode ser facilmente expandida para outros tipos de conforto como, por exemplo, os confortos térmico e sonoro. Para gerenciar o desenvolvimento do projeto foi utilizada a metodologia CRISP-DM, do inglês *Cross Industry Standard Process for Data Mining*, traduzido como Processo Padrão Inter-Indústrias para Mineração de Dados. Para alcançar os objetivos do projeto seguimos os seguintes passos:

- Recriamos um escritório inteligente em um ambiente residencial a partir de tecnologias utilizadas em um ambiente acadêmico.
- Aplicamos a metodologia de mineração de dados *CRISP-DM* para formalizar a obtenção, tratamento e utilização dos dados do projeto.
- Criamos um sistema de predição de conforto de luminosidade personalizado para escritórios inteligentes que necessita de pouco tempo e poucos dados para ser treinado.

- Avaliamos o sistema em um ambiente real de um escritório inteligente personalizado, comparando seu desempenho com diversas combinações de conjuntos de dados.
- Implementamos o conceito de conforto com a implementação da modelagem de dados para predição personalizada de conforto de luminosidade.

1.3 Contribuições

Com o desenvolvimento dessa proposta, o ambiente de trabalho pode se tornar mais produtivo e mais confortável. Além dos benefícios citados anteriormente, a realização desta proposta trouxe as seguintes contribuições:

- Instalação de um ambiente inteligente residencial personalizado usando tecnologias inovadoras recém-elaboradas no ambiente acadêmico.
- Implementação da modelagem de predição personalizada de conforto luminoso utilizando a transferência de conhecimento com ajuste fino.
- Redução do tempo de predição de preferências em um ambiente inteligente personalizado empregando algoritmos de aprendizado profundo.
- Verificação da viabilidade de implementação de escritórios e ambientes inteligentes, reduzindo o tempo de treinamento da predição de conforto de luminosidade personalizado.
- Avaliação das contribuições em um ambiente real por meio de experimentações com dados reais.

1.4 Organização do Documento

Este documento está organizado em seis capítulos. O capítulo 1 apresenta a introdução, motivação, objetivos e contribuições. O capítulo 2 discute os conceitos básicos do projeto para contextualizar a tecnologia utilizada. O capítulo 3 descreve os trabalhos relacionados. O capítulo 4 se dedica ao entendimento, preparação e análise dos dados. O

capítulo 5 detalha a solução proposta para o problema em que será explicitada a modelagem dos dados, a avaliação do modelo e os resultados alcançados. O capítulo 6 descreve a conclusão do projeto e exhibe os trabalhos futuros.

Capítulo 2

Conceitos básicos

Este projeto tem como foco a personalização de conforto em ambientes inteligentes. Essa tecnologia aborda um conjunto grande e plural de conceitos e técnicas que devem interagir entre si para construir o foco deste projeto. Alguns dos conceitos básicos que compõem um escritório inteligente personalizado estão representados na Figura 2.1. Estes conceitos devem ser compreendidos em sua essência para serem aplicados corretamente na elaboração da personalização do ambiente inteligente.

Na elaboração do projeto são utilizados os conceitos que mesclam a percepção subjetiva de conforto, conceitos de personalização, conexão de dispositivos sensores e atuadores. Além disso, também são aplicadas técnicas de inteligência artificial voltadas para dados como o aprendizado de máquina e o CRISP-DM. Estes conceitos e técnicas serão explicitados em detalhes neste capítulo.

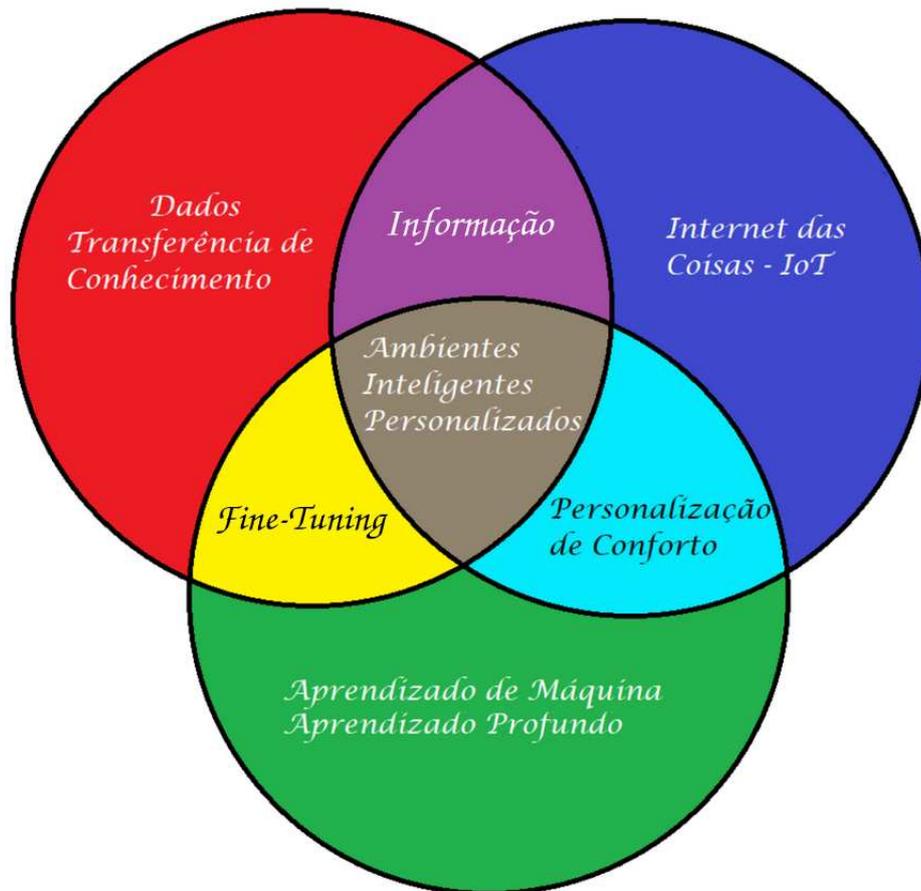
2.1 Entendimento do negócio

Nesta seção serão apresentados os conceitos relevantes para o negócio segundo a metodologia CRISP-DM. A composição básica do projeto envolve, principalmente, os conceitos de conforto, personalização, Internet das Coisas e ambientes inteligentes. Uma breve explicação de cada um deles será exibida a seguir.

- **Conforto.** Conforto é um estado de ter as necessidades de alívio, tranquilidade e transcendência satisfeitos em quatro contextos: físico, psicoespiritual, social e ambiental [36]. Alívio é o estado de quem teve alguma necessidade específica, satisfeita. A tranquilidade é um estado de calma, sossego ou satisfação. Transcendência é o estado onde é possível superar problemas ou dor [35].

O conforto é uma percepção subjetiva que depende do indivíduo [53]. A composição corporal de cada indivíduo pode influenciar na sensação de conforto, a exemplo a quantidade de gordura corporal que influencia na sensação térmica do ambiente

Figura 2.1: Ilustração da composição de ambientes inteligentes.



Fonte: Autor, 2023.

[80]. Isso nos diz que em um mesmo ambiente uma pessoa pode estar confortável, enquanto outra está desconfortável com as mesmas características do ambiente.

- **Personalização.** Personalizar é produzir, modificar ou adequar um serviço, ou um produto, atendendo aos gostos, necessidades ou exigências particulares de um cliente, ou usuário. Personalização trata de uma característica intangível, que é como as pessoas experimentam o mundo e definem suas preferências [46].

A personalização pode ter caráter individual ou de grupo [37]. A personalização individual tem a característica de aperfeiçoar e atender exclusivamente a um indivíduo. Esse tipo de personalização aproxima a característica do produto ao máximo das preferências ou necessidades do usuário [46].

- **Internet das Coisas.** O termo “Internet das Coisas” (ou IoT, do inglês “*Internet of Things*”) foi empregado pela primeira vez em 1999 por Kevin Ashton, pesquisador britânico do MIT (Massachusetts Institute of Technology). Ele o utilizou para descrever a interação humana com a Internet e a quantidade de dados gerados e manipulados pelas pessoas [5]. Posteriormente, o termo foi definido oficialmente em 2005 pela ITU (*International Telecommunications Union*) [73] como a interconexão

de dispositivos e objetos do dia a dia à Internet [6]. Esses dispositivos podem incluir desde eletrodomésticos, veículos e sensores industriais até dispositivos médicos e *wearables* que são dispositivos vestíveis como um relógio ou uma roupa. A IoT permite que esses dispositivos colem e compartilhem dados entre si, criando um ecossistema de informação e automação [70].

Além de ligar as “coisas” pela Internet, a IoT objetiva torná-las inteligentes, capazes de coletar e processar informações do ambiente ou das redes às quais estão conectadas. Com isso, a Internet das Coisas está mudando a forma como nos relacionamos com o mundo, as “coisas” que estão ao nosso redor, transformando segurança, energia, meio ambiente, trânsito, mobilidade e logística [54].

- **Ambiente inteligente.** Um ambiente inteligente é um mundo físico que é rico e invisivelmente composto com sensores, atuadores, monitores e elementos computacionais, embarcados nos objetos da nossa vida cotidiana. Estes objetos estão conectados por uma rede de comunicação [83]. A interligação desses objetos permite que um ambiente inteligente possa melhorar nossas atividades cotidianas [17]. Essa melhoria é provida pela atuação conjunta dos sensores e atuadores que tornam a vivência do dia a dia mais fácil e mais confortável para as pessoas [69]. A atuação, por sua parte, é controlada por algoritmos de aprendizado de máquina, que modificam o ambiente a partir do seu controle dos atuadores [24].

2.2 ManIoT

Diante do grande número de aparelhos conectados e dos novos conceitos de IoT, surge a necessidade de criar mecanismos que permitam conexão heterogênea, segurança, interoperabilidade de sistemas, gerenciamento dos dispositivos e escalabilidade. A plataforma chamada ManIoT (*Management for Internet of Things*) foi desenvolvida por [4] tendo em vista a solução dos problemas citados anteriormente.

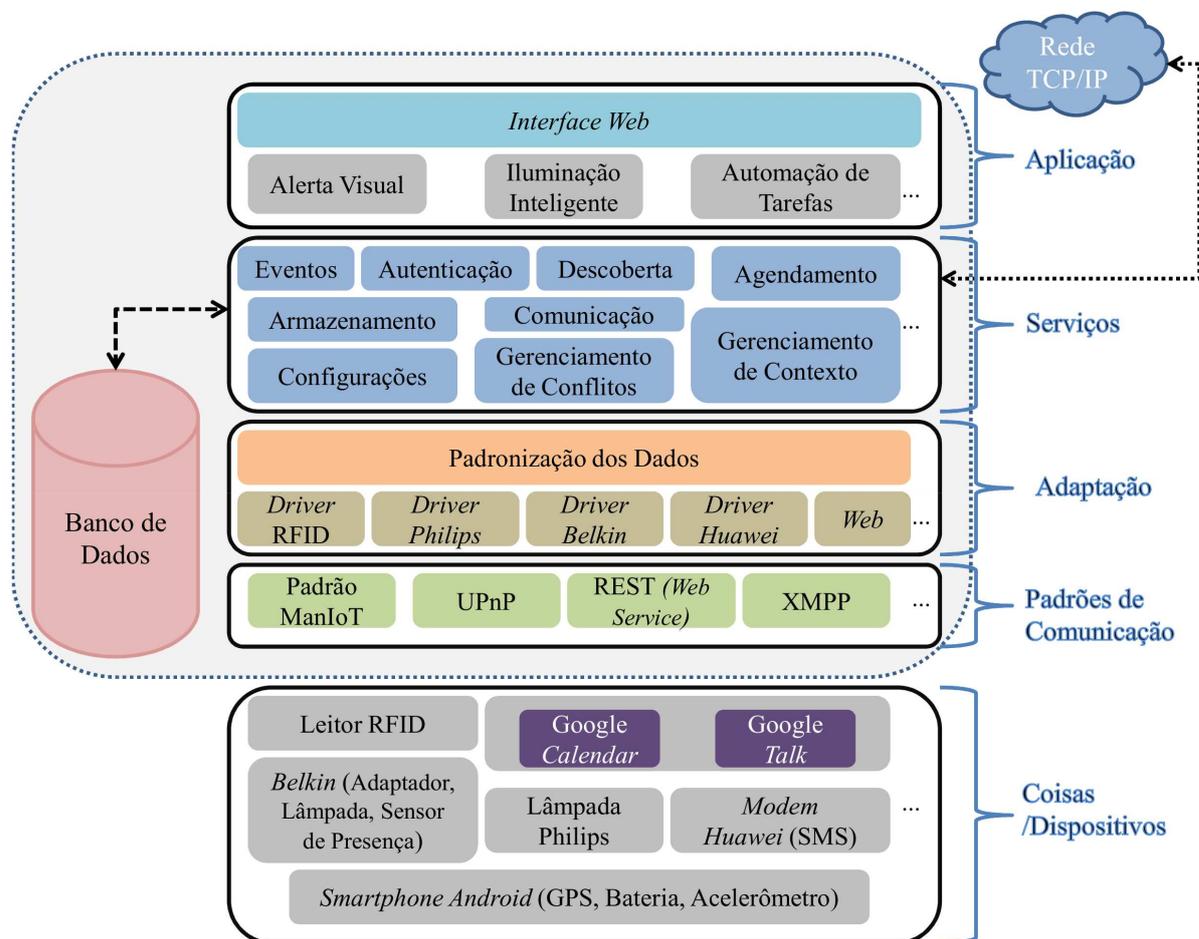
A plataforma do ManIoT é composta por uma gerência de dispositivos e das “coisas” conectadas ao ManIoT. Através desta plataforma podemos ter diversos tipos de “coisas” conectadas à rede, o que representa a extensibilidade ou conexão heterogênea. Com isso, o ManIoT permite a inclusão de novos *drivers* para adicionar novos dispositivos [4].

A plataforma ManIoT estabelece dois escopos de gerenciamento, local e global. O gerente local atua em um cenário, gerenciando os dispositivos que compõem este cenário. O gerente global visa uniformizar as ações realizadas em diferentes cenários a partir de

diretivas de alto nível.

Os softwares que compõem o Gerente local possuem cinco camadas bem definidas como mostrado na Figura 2.2.

Figura 2.2: Plataforma ManIoT: gerente local.



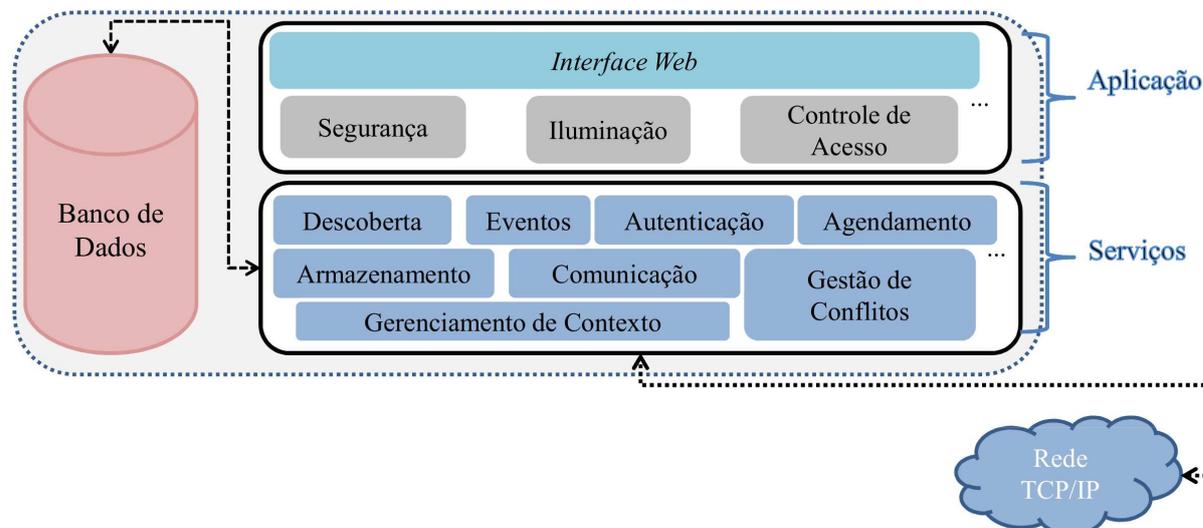
Fonte: [4], 2016.

A primeira camada é a de aplicação gerencia a interação das aplicações com os dispositivos conectados no ManIoT, controlando a ação da aplicação com os dispositivos. A segunda camada é a de serviços, formada pelos serviços que dão suporte às aplicações e utilizam abstrações implementadas pelos *drivers* para realizar a comunicação com os dispositivos. A terceira camada é a de adaptação, dividida em duas partes, a primeira é responsável pela padronização dos dados e a segunda que trata as especificidades de cada dispositivo. A quarta camada é a de comunicação, responsável pela aplicação dos diferentes protocolos de acesso aos dispositivos. A quinta camada é a de coisas/dispositivos, composta pelas coisas ou dispositivos sendo estes reais, ou virtuais.

O Gerente Global possui duas camadas, Aplicação e Serviços, como mostrado na Figura 2.3.

Os serviços implementados no escopo global possuem as mesmas funções daqueles implementados na segunda camada do escopo local, como mostrado na Figura 2.2.

Figura 2.3: Plataforma ManIoT: gerente global.



Fonte: [4], 2016.

2.3 Aprendizado de máquina

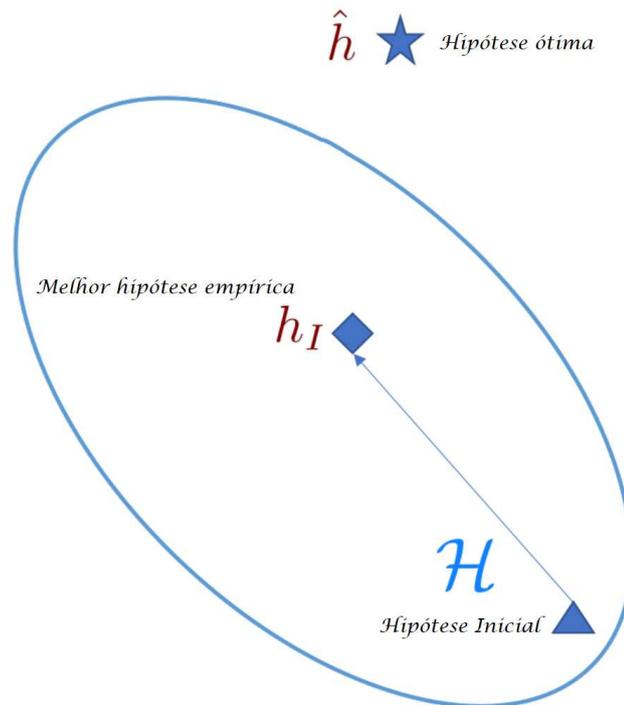
[27] define aprendizado de máquina como o estudo sistemático de algoritmos e sistemas que melhoram o conhecimento ou desempenho destes com experiência. A experiência significa treinamento a partir dos dados fornecidos pelo sistema no qual o aprendizado de máquina é aplicado.

O aprendizado de máquina é composto de atributos, tarefas e modelos. Atributos definem a linguagem que descreve os objetos relevantes do mundo real, e que são as entradas dos modelos de aprendizado de máquina. Tarefas são representações abstratas de um problema que queremos resolver, se resume a mapear dados pontuais para uma saída. Já o modelo é resultado do algoritmo de aprendizado de máquina aplicado aos dados de treinamento [27].

De modo geral, o objetivo de um modelo é determinar a relação entre uma variável aleatória $Y \in \mathbb{R}$, também conhecida como rótulo, e um vetor $\mathbf{x} = (x_1, \dots, x_d) \in \mathbb{R}^d$, também conhecido como atributos, [32]. Um modelo determina o espaço de hipóteses [82]. Com o treinamento do modelo obtemos hipóteses melhores para prever novas observações de \mathbf{x} [79]. O treinamento do modelo começa com uma hipótese inicial H que pode ser melhorada com a inserção de novas observações até que alcançamos uma melhor hipótese empírica como mostrado na Figura 2.4. A partir das afirmações anteriores podemos concluir que não atingiremos a hipótese ótima, como mostrado na Figura 2.4, por ser inviável obtermos todos os seus infinitos pares de relação (\mathbf{x}, Y) tal que $\mathbf{x} = (x_1, \dots, x_d) \in \mathbb{R}^d$ e $Y \in \mathbb{R}$.

O treinamento do aprendizado de máquina, segundo [25], pode ser do tipo super-

Figura 2.4: Espaço de hipóteses de um aprendizado de máquinas.



Fonte: Adaptada de [82], 2019.

visionado, não supervisionado e por reforço, como definidos a seguir:

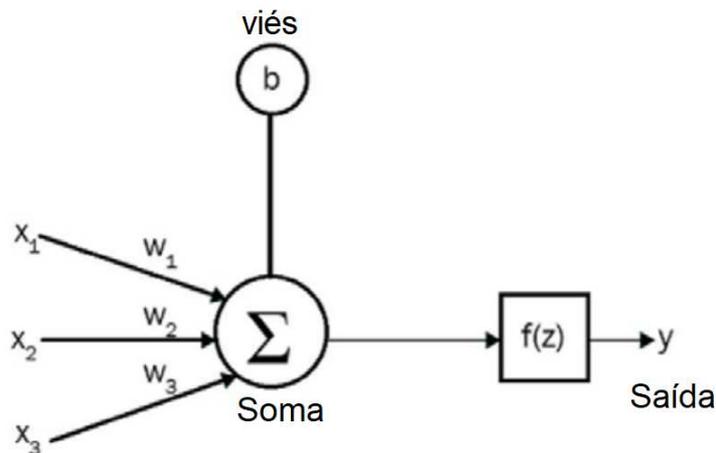
- No aprendizado supervisionado, temos os dados rotulados. Para cada entrada temos o resultado correto. Isso permite treinar um modelo e testar sua acurácia com os dados rotulados [25].
- No modelo não supervisionado não temos dados rotulados, e o modelo é criado encontrando padrões nos dados [25].
- No aprendizado por reforço temos o treinamento baseado no método de tentativa e erro, para maximizar o desempenho do sistema com dados não rotulados. Um aprendizado por reforço atribui recompensas ou punições ao sistema aprendiz com o intuito de montar um aprendizado que leve ao máximo de recompensas [76]. Aprendizado de máquina por reforço é como ter um crítico de ações, diferindo dos outros métodos que seriam como ter um professor. O crítico, ao contrário do professor, não te diz o que fazer, e sim se o seu desempenho está ruim ou bom, de acordo com uma avaliação [25].

2.3.1 Redes Neurais Artificiais

As redes neurais são baseadas no conceito biológico dos neurônios, onde uma rede interconectada de neurônios realizam o processamento massivo de dados. As redes neurais artificiais são compostas de um conjunto, interconectado, de unidades simples do neurônio, onde cada unidade pode ter um conjunto de entradas de valores reais [45].

Um tipo de rede neural artificial é baseada em uma unidade chamada de perceptron (ver Figura 2.5). Um perceptron recebe um vetor de valores reais como entrada, calcula uma combinação linear entre as entradas e então retorna uma dicotomia que define um limiar. Isso nos diz que os valores de saída determinam uma classificação binária para o resultado da combinação linear [45]. Os valores dessa dicotomia podem ser 1 e -1 ou 1 e 0 dependendo da representação que se deseja ter.

Figura 2.5: Neurônio artificial.



Fonte: Adaptado de [65], 2020.

Para vermos como o neurônio funciona suponhamos que temos três entradas x_1 , x_2 e x_3 para prever uma saída y . As entradas são multiplicadas, respectivamente, pelos pesos w_1 , w_2 e w_3 e então as parcelas são somadas [65], como a equação a seguir:

$$x_1.w_1 + x_2.w_2 + x_3.w_3 \quad (2.1)$$

Os pesos determinam qual a relevância das entradas sobre o valor da saída. Dessa forma podemos dizer que uma entrada tem maior importância que outra no cálculo da saída, uma vez que o peso reforça o valor das entradas. Após multiplicar as entradas pelos seus pesos e somar também é adicionado à equação de saída o viés, b também conhecido como bias:

$$z = (x_1.w_1 + x_2.w_2 + x_3.w_3) + b \quad (2.2)$$

O viés é um regulador da saída que pode definir, por exemplo, qual o limiar das equações [65]. Por exemplo, a Equação 2.2 possui a seguinte forma:

$$z = mx + b \quad (2.3)$$

Neste exemplo, m são os pesos ou coeficientes, x as entradas e b é o viés.

A saída da rede neural é multiplicada pelo peso de entrada do próximo neurônio e somado com o viés. Se todos os neurônios tiverem somente esta estrutura, então a rede será similar a uma regressão linear [64]. Essas redes neurais são geralmente chamadas de redes neurais lineares. Uma rede neural linear com múltiplas camadas é equivalente a uma rede neural de uma única camada [59]. Para resolvermos esse problema devemos introduzir não linearidade nas redes neurais. Para introduzir não linearidade nas redes neurais utilizamos as funções de ativação na saída de cada neurônio da rede vistas a seguir.

2.3.1.1 Funções de ativação

Nas redes neurais, a relação da entrada com a saída é regida por equações não lineares, chamadas funções de ativação [65]. O objetivo da função de ativação é introduzir uma transformação não linear para aprender os complexos padrões subjacentes nos dados [64]. Algumas das funções de ativação mais utilizadas são a **sigmoide**, **tangente hiperbólica (tanh)**, **Rectified Linear Unit (ReLU)**, **softmax**, entre outras. Apresentaremos a seguir as funções de ativação que utilizamos na pesquisa.

A sigmoide é a função de ativação mais comumente usada, ela escala os valores entre 0 e 1 como na Figura 2.6. A função sigmoide, mostrada na equação (2.4), pode ser definida da seguinte forma:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2.4)$$

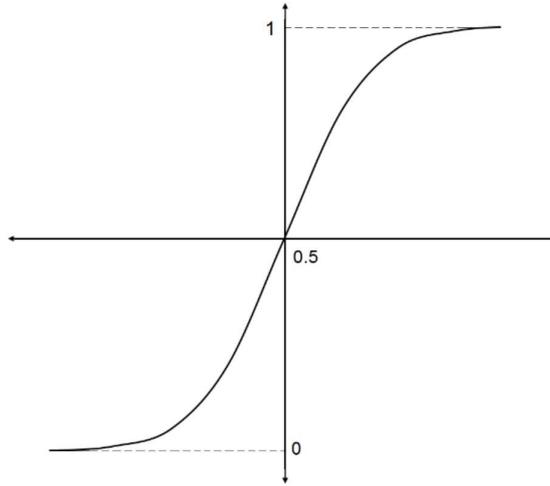
A função tangente hiperbólica (tanh) tem a saída entre -1 e 1 como mostra a Figura 2.7 sendo expressa da seguinte forma:

$$f(x) = \frac{1 - e^{-2x}}{1 + e^{-2x}} \quad (2.5)$$

A função *ReLU* é também uma das funções mais comumente utilizadas nas redes neurais como função de ativação. A *ReLU* é basicamente uma função definida por partes como na equação a seguir:

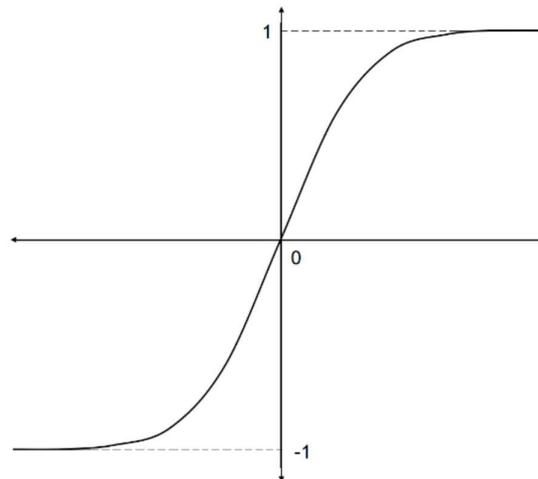
$$f(x) = \begin{cases} 0 & \text{para } x < 0 \\ x & \text{para } x \geq 0 \end{cases} \quad (2.6)$$

Figura 2.6: Função Sigmoid.



Fonte: [65], 2020.

Figura 2.7: Função tanh.



Fonte: [65], 2020.

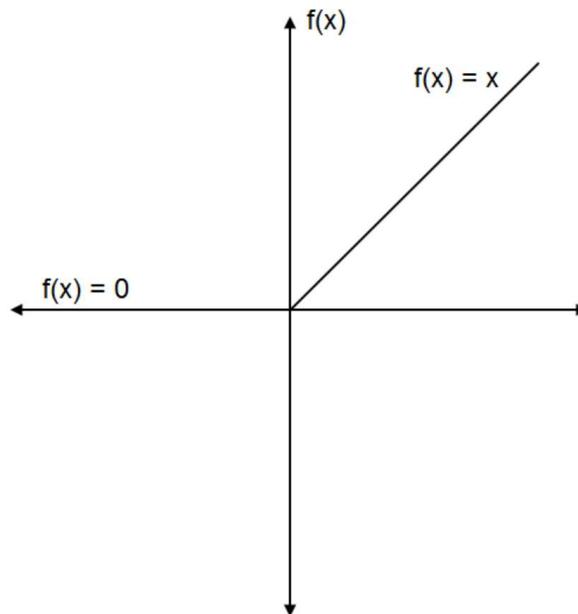
Essa função retorna zero quando o valor de x é menor do que zero e retorna o valor de x se $f(x)$ é maior do que zero como mostra a figura (2.8). Essa função também pode ser expressa como o máximo entre 0 e x .

$$f(x) = \max(0, x) \quad (2.7)$$

A função *softmax* é a generalização da função *sigmoid*. É usualmente aplicada na última camada da rede neural para desempenhar tarefas de classificação de múltiplas classes. A *softmax* retorna a probabilidade de cada classe ser o resultado da saída. A soma dos valores de saída da função *softmax* é sempre igual a 1 e ela pode ser representada conforme a equação (2.8) a seguir:

$$f(x_i) = \frac{e^{x_i}}{\sum_j e^{x_j}} \quad (2.8)$$

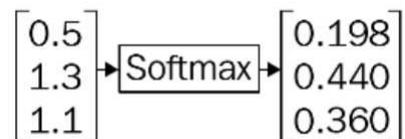
Figura 2.8: Função ReLU.



Fonte: [65], 2020.

A figura 2.9 mostra um exemplo do resultado da aplicação da função softmax.

Figura 2.9: Função softmax, exemplo.



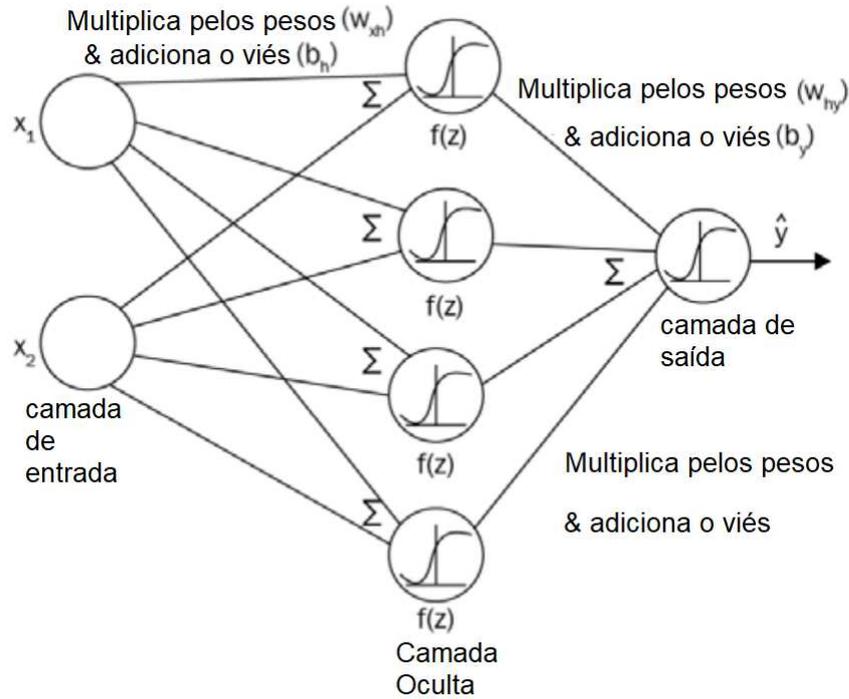
Fonte: [65], 2020.

2.3.1.2 Perceptron multi camadas

O perceptron simples consegue, apenas, expressar decisões lineares de superfícies, o que lhe confere uma capacidade limitada de representação. Essa deficiência é sanada com as redes neurais artificiais (ANN), do inglês Artificial Neural Network. Uma ANN é composta por uma camada de entrada, onde se recebe os dados de entrada, uma ou várias camadas ocultas, e uma camada de saída como mostrado na Figura 2.10 [65].

A entrada das camadas ocultas e da camada de saída é o somatório das saídas dos neurônios que se ligam a cada neurônio dessa nova camada. As saídas de cada camada funcionam como mostrado no perceptron exemplificado na Figura 2.5. A Figura 2.10 mostra a camada de entrada com dois neurônios e a saída com apenas um neurônio. A

Figura 2.10: Rede neural artificial (ANN).



Fonte: Adaptado de [65], 2020.

camada oculta possui uma camada com quatro neurônios e cada neurônio da camada oculta recebe a soma das saídas dos neurônios da camada de entrada. A camada oculta retorna a soma de suas entradas aplicada a uma função de ativação como no intervalo de Equações (2.9) — (2.12). A camada de saída recebe a soma das saídas da camada oculta e retorna essa soma aplicada a uma função de ativação. Esse fluxo de dados na ANN, indo da camada de entrada até a camada de saída, é conhecido como *forward propagation* [65].

$$Z_1 = XW_{xh} + b_h \quad (2.9)$$

$$a_1 = \sigma(Z_1) \quad (2.10)$$

$$Z_2 = a_1W_{hy} + b_y \quad (2.11)$$

$$\hat{y} = \sigma(Z_2) \quad (2.12)$$

2.3.2 Como uma rede neural aprende?

Para sabermos se a saída da rede neural está correta devemos utilizar a **função de custo** (J), também conhecida como **função de perda** (L), que irá nos dizer como a nossa rede neural está desempenhando. Há muitas formas diferentes de função de custo, sendo a mais utilizada a função do erro médio quadrático descrita na equação 2.13 a seguir:

$$J = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2.13)$$

Na equação 2.13 n é o número de amostras de treino, y é a saída ou rótulo para as amostras de treino e \hat{y} é a saída prevista pela rede neural [65].

A função de custo pode ser minimizada utilizando os conceitos de gradiente descendente. Esse conceito aproxima a função de custo de seu mínimo através do cálculo da derivação da função de custo em relação aos seus pesos para alcançar seu valor mínimo [65]. A atualização dos pesos da rede neural seguindo o gradiente descendente é realizado pelo método do *backpropagation*. Este método retro propaga os valores dos erros encontrados através da rede neural a partir da camada de saída da rede para a camada de entrada [65]. O *backpropagation* atualiza os pesos segundo a regra de atualização de pesos mostrada na Equação 2.14 a seguir:

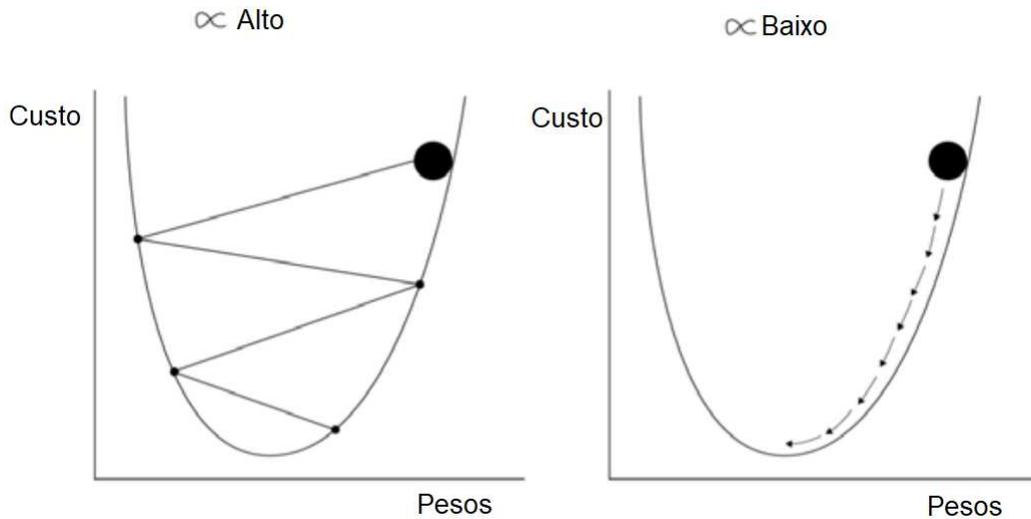
$$W = W - \alpha \frac{\partial J}{\partial W} \quad (2.14)$$

Na equação 2.14 α é chamado de taxa de aprendizado e define o tamanho dos saltos nos valores dos pesos W e J é a função de custo. A Figura 2.11 mostra a diferença no aprendizado para variações da taxa de aprendizado α utilizando o gradiente descendente. Uma taxa muita alta implica em saltos grandes e pode acarretar não alcançar o mínimo, em contrapartida, uma taxa muito baixa pode levar um tempo muito longo para alcançar o mínimo.

2.3.3 Transferência de Conhecimento

O surto de demandas por recursos de dados e recursos computacionais gerou um gargalo que limita o desenvolvimento de tecnologias de inteligência artificial [39]. Para resolver este problema foi proposto o método da transferência de conhecimento. Este método transfere conhecimento gerado em um domínio A para um domínio B [39], [56].

Figura 2.11: Efeito do tamanho da taxa de aprendizado.



Fonte: Adaptado de [65], 2020.

A transferência de conhecimento pode ajudar a melhorar a acurácia ou reduzir o tempo de treino de um novo modelo [67].

O tempo de treinamento de um ambiente mencionado neste projeto se refere ao período que compreende o início da coleta de novos dados do novo ambiente até o fim do treinamento do modelo. Porém, no contexto de ambientes inteligentes, entendemos que o período de modelagem e treinamento do modelo são insignificantes se comparados ao tempo de coleta de dados. Dessa forma, quando este trabalho se refere à redução do tempo de treinamento, esta redução está focada na necessidade de grandes períodos de coletas de dados. Mesmo havendo uma preocupação com o tempo de busca de hiperparâmetros e treinamento do modelo, este tempo não é o foco do trabalho e não é significativo diante do tempo de coleta.

Podemos entender a transferência de conhecimento com o seguinte exemplo. Uma pessoa tem conhecimento de música, mas nunca tocou piano. A pessoa poderia aprender a tocar piano mais rapidamente usando a experiência prévia de tarefas anteriores para completar uma tarefa relacionada mais rápido. No caso do músico, ele irá aprender a tocar piano mais rápido do que uma pessoa que não tem nenhuma experiência anterior com música [39].

A definição formal de transferência de conhecimento é a seguinte. Dado um domínio fonte \mathcal{D}_S e uma tarefa de aprendizado \mathcal{T}_S , um domínio objetivo \mathcal{D}_T e uma tarefa de aprendizado \mathcal{T}_T , a transferência de conhecimento objetiva ajudar a melhorar a tarefa de aprendizado da função de predição $f_T(\cdot)$ em \mathcal{D}_T usando o conhecimento de \mathcal{D}_S e \mathcal{T}_S , onde $\mathcal{D}_S \neq \mathcal{D}_T$ ou $\mathcal{T}_S \neq \mathcal{T}_T$.

Um domínio \mathcal{D} consiste em dois componentes: um conjunto de espaço de características \mathcal{X} e a distribuição de probabilidade marginal $P(X)$ em que $X = \{x_1, \dots, x_n\} \in$

\mathcal{X} . Por exemplo, se uma tarefa de aprendizado é uma classificação de documentos e cada termo é tomado como uma característica binária, então X é o espaço de vetores de todos os termos, x_i é o i -ésimo vetor de termos correspondente a algum documento e X é uma amostra particular de aprendizado. Se dois domínios são diferentes, então eles devem ter espaço de características diferentes ou distribuição de probabilidade marginal diferentes [55].

2.3.4 Ajuste fino

Em aprendizado profundo, as primeiras camadas de neurônios são treinadas para identificar características gerais de baixo nível das tarefas. As camadas finais identificam características específicas que são próprias do conjunto de dados [43]. Durante a transferência de conhecimento, podemos remover algumas das últimas camadas da rede treinada e retreinar a rede com novas camadas adicionadas para a tarefa alvo. Essa ação de treinar a rede alterando somente os pesos de um conjunto de camadas finais é chamado de Ajuste fino, do inglês *Fine-tuning*.

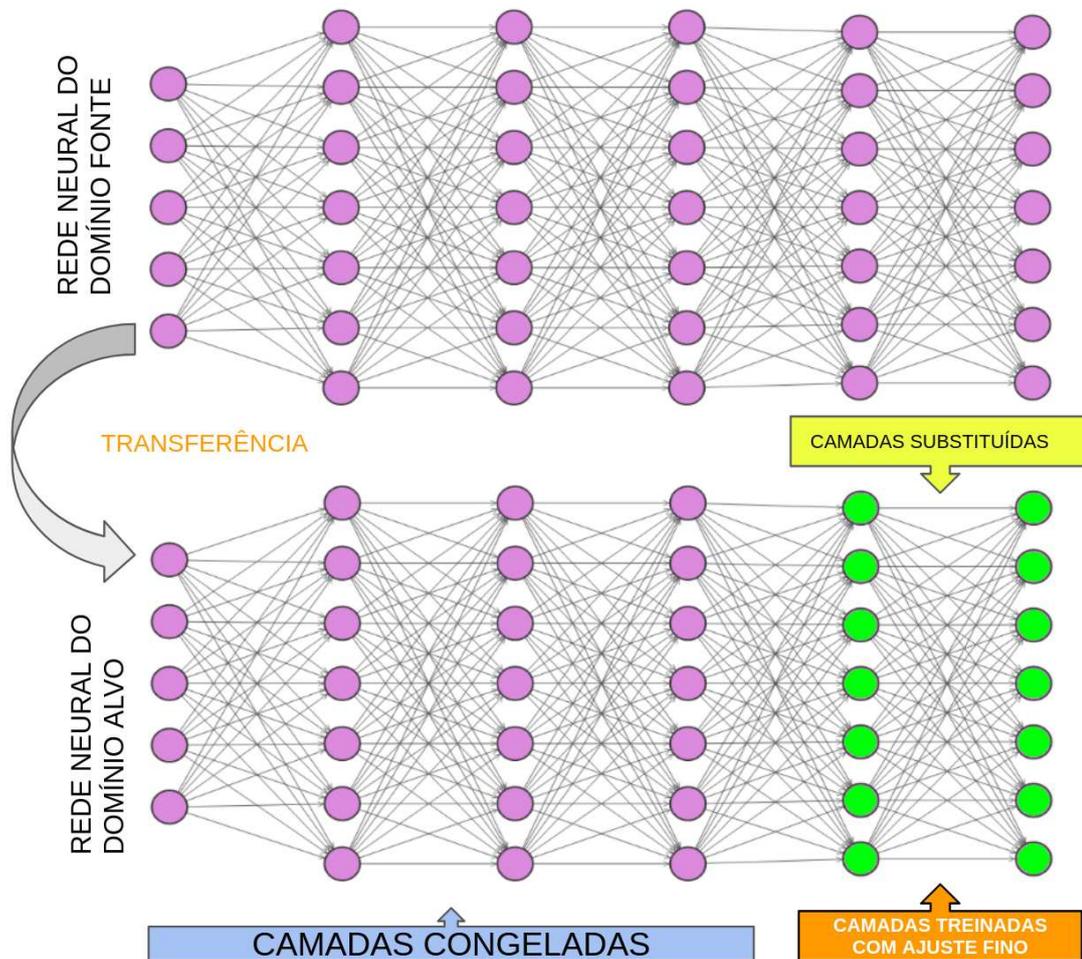
Para realizarmos o ajuste fino, primeiro trazemos o conhecimento de um modelo pré-treinado para uma nova tarefa similar à tarefa do modelo pré-treinado. Após isso, podemos substituir as últimas camadas do modelo pré-treinado por camadas com pesos iniciais novos e aleatórios. Após a substituição das últimas camadas, “congelamos” os pesos das camadas iniciais da rede neural do modelo pré-treinado e treinamos a rede neural novamente com os novos dados da nova tarefa, como exemplificado na Figura 2.12 [66]. Essa ação irá alterar apenas os pesos das camadas finais que não estão “congeladas”.

Experimentos de aprendizado com ajuste fino requerem uma considerável quantidade de treinamento, mas eles são bem mais rápidos do que o treinamento do início [48]. Isso quer dizer que os modelos treinados com ajuste fino possuem, em geral, uma maior acurácia do que os modelos treinados do início [78].

2.3.5 Pesquisa em grade

Os hiperparâmetros são um conjunto de valores intrínsecos de uma modelagem que parametrizam a distribuição dos parâmetros do modelo [52], como, por exemplo, a taxa de aprendizado de uma rede neural [9].

Figura 2.12: Transferência de conhecimento com ajuste fino.

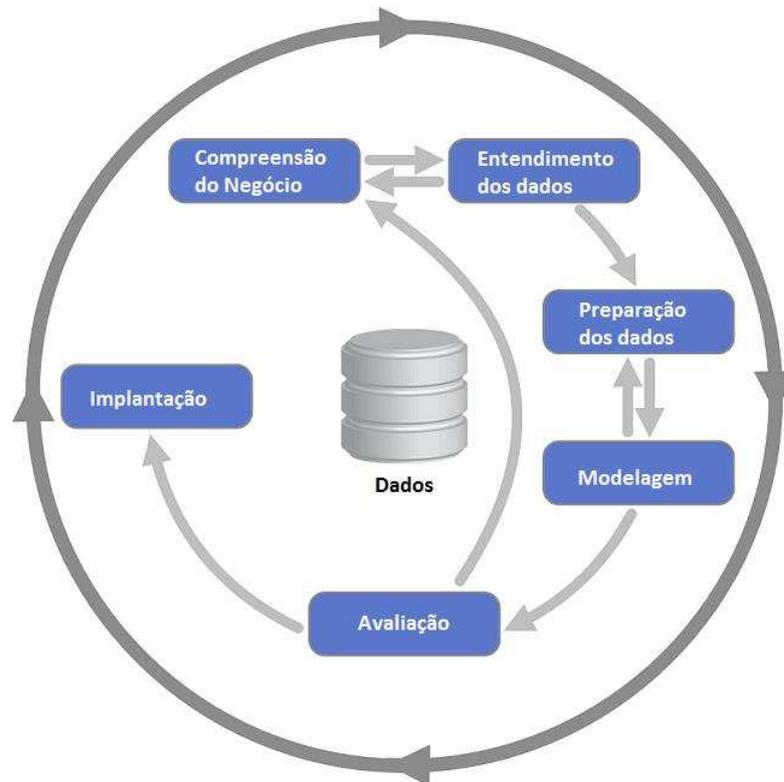


Fonte: Autor, 2023.

A pesquisa em grade, do inglês *Grid Search*, pode ser descrito como uma exploração exaustiva ou um método de força bruta que testa todas as combinações de hiperparâmetros dadas para a configuração da grade [8]. O *Grid Search* trabalha avaliando o produto cartesiano dos conjuntos de valores finitos que são subconjuntos do espaço de hiperparâmetros do algoritmo de treino definidos pelo usuário [75].

De acordo com [40], pelo fato do algoritmo de busca em grade usar a exploração exaustiva, ele pode gastar muito tempo para executar. De acordo com [8] a ordem de complexidade do *Grid Search* é de $O(n^k)$ em que k é o número de hiperparâmetros e n a quantidade de elementos nos hiperparâmetros. Assim, outros algoritmos são mais rápidos do que o *Grid Search*, porém ele retorna a combinação ótima de hiperparâmetros de um modelo no espaço de hiperparâmetros analisados.

Figura 2.13: Ciclo da metodologia CRISP-DM.



Fonte: [62], 2020.

2.4 Metodologia CRISP-DM

O nome CRISP-DM vem do inglês *Cross Industry Standard Process for Data Mining*, que em tradução livre para o português significa “Processo Padrão Inter-Indústrias para Mineração de Dados” [71]. O objetivo dessa metodologia é desenvolver modelos a partir da análise de informações e dados de um negócio para prever futuras falhas e soluções [14]. O modelo do CRISP-DM é dividido em seis fases que são: entendimento do negócio, compreensão dos dados, preparação dos dados, modelagem, avaliação e implantação [84], como mostra a Figura 2.13. Estas fases são descritas a seguir:

- **Entendimento do negócio** (*Business Understanding*)

É a etapa inicial que foca no entendimento dos objetivos e requisitos do projeto de uma perspectiva de negócios. Dessa forma, o conhecimento do entendimento dos objetivos e requisitos são convertidos em uma definição de problema de mineração de dados. Com isso, um plano preliminar de projeto é desenvolvido para alcançar os objetivos [84].

- **Entendimento dos dados** (*Data Understanding*)

A fase do entendimento dos dados começa com uma coleta inicial de dados. Após a coleta, ocorre análise dos dados para o desenvolvimento de familiaridade com os dados. O objetivo disso é identificar problemas de qualidade dos dados, descobrir as percepções iniciais sobre os dados e detectar possíveis subconjuntos de interesse para formar hipóteses sobre informações implícitas.

A fase de entendimento dos dados envolve quatro passos que são a coleta dos dados, a descrição dos dados, a exploração dos dados e a verificação da qualidade dos dados. Na fase de coleta de dados o analista de dados adquire os dados necessários. Na fase de descrição dos dados, o analista examina de forma “superficial” as propriedades dos dados adquiridos, como problemas com o formato dos dados, a quantidade dos dados, o número de registros, os campos das tabelas e outras características superficiais dos dados e as reporta nos resultados. A exploração dos dados aborda questões de mineração de dados que podem ser analisadas usando questionamentos, visualização e relatórios. Na verificação da qualidade dos dados o analista verifica se os dados estão completos, falta de valores, período de coleta dos dados, falta de atributos, campos em branco entre outros [74].

- **Preparação dos dados** (*Data Preparation*)

A preparação dos dados envolve as atividades ligadas ao tratamento dos dados, incluindo a seleção do que será realmente usado como conjunto de dados, limpeza e transformação dos dados caso seja necessário [14]. A preparação dos dados é um dos aspectos mais importantes e muitas vezes é o que exige mais tempo em mineração de dados. Há estimativa de que esta etapa gasta entre 50% a 70% do tempo e esforço de um projeto [14]. A dedicação de recursos adequados para as fases iniciais de entendimento de negócio e entendimento de dados pode minimizar a sobrecarga relacionada a preparação dos dados, mas ainda será necessário muito esforço para preparar os dados [62].

- **Modelagem** (*Modeling*)

A modelagem de dados consiste em selecionar a técnica de modelagem dos dados e construir os casos de testes e o modelo, podendo se utilizar diversas técnicas de mineração de dados. A escolha da técnica de modelagem dos dados depende do problema de negócio e dos dados, pois ela define como é abordada a solução do problema de negócio.

A modelagem é geralmente executada em várias iterações, de forma que parâmetros específicos devem ser ajustados no modelo para gerar os melhores resultados. Os analistas de dados executam vários modelos e variam os valores dos parâmetros até que se alcance resultados otimizados. Também é comum retornar à fase de preparação de dados para manipulações dos dados exigidas pelo modelo [71].

- **Avaliação** (*Evaluation*)

Antes de implantar o modelo é importante avaliar o modelo e revisar a sua construção para ter certeza de que o modelo alcançou os objetivos do negócio. Um objetivo da avaliação chave é determinar se existe algum problema importante do negócio que não foi suficientemente considerado. Caso os resultados não se mostrem satisfatórios, há a possibilidade de retorno à etapa de entendimento do negócio, como mostra a Figura 2.13 [84].

- **Implantação** (*Deployment*)

Segundo [14], geralmente a criação do modelo não é o fim do projeto. Isso por que o conhecimento ganho terá necessidade de ser organizado e apresentado de alguma forma que o cliente possa usar. Isso geralmente envolve aplicar modelos “vivos”, ou seja, que estão em constante evolução, em uma organização para realizar processos de tomada de decisão. A exemplo, a personalização de predição de conforto em tempo real em ambientes inteligentes. A fase de implantação pode ser tão simples quanto gerar um relatório ou tão complexo quanto implementar um processo repetitivo de mineração de dados em toda a empresa.

Em muitos casos é o consumidor do sistema quem realiza o processo de implementação. Embora em muitos casos o analista não realize o esforço de implementação do modelo, é importante para o consumidor entender antecipadamente quais ações devem ser realizadas para usar os modelos criados [14].

2.5 Conclusões

Com este capítulo foi possível compreender a extensão da complexidade de elaboração da personalização de conforto de um ambiente inteligente. Isso se deve ao vasto número de conceitos e técnicas que compõem o tema de conforto personalizado em ambientes inteligentes. Estes conceitos devem ser compreendidos em sua essência para serem aplicados corretamente na elaboração da personalização do ambiente inteligente.

Para a elaboração do projeto, foram abordados os conceitos que dizem respeito à percepção subjetiva de conforto, à personalização, à conexão de dispositivos sensores e atuadores, além de técnicas de aprendizado da máquina. Além das técnicas e conceitos compreendidos e implementados, trabalhos relacionados ao tema foram consultados para obter informações do estado da arte do tema deste projeto. Estes trabalhos consultados são abordados no capítulo seguinte.

Capítulo 3

Trabalhos relacionados

Esta seção faz a análise dos trabalhos acadêmicos que possuem relação com o tema abordado. Muitos trabalhos são desenvolvidos na área de aprendizado de máquina personalizado e na área de internet das coisas voltados para ambientes inteligentes, vistos a seguir.

3.1 Ambientes inteligentes

Como definido anteriormente, um ambiente inteligente é um ambiente físico que possui sensores e atuadores que realizam a gestão de um sistema. Diversos objetivos regem um ambiente inteligente, desde controle energético de uma edificação até o conforto personalizado de indivíduos.

De acordo com [15], construir um modelo de ambiente inteligente é caro em termos de tempo e dados se o dado para o treino do modelo deve ser coletado desde o início. Isso se deve porque o processo de coletar dados, além de ser demorado e estar propício a erros, também pode gerar distúrbio na vida cotidiana dos usuários que participam do fornecimento dos dados.

A necessidade de coleta e rotulação de uma grande quantidade de dados para cada novo ambiente é um dos desafios da modelagem de reconhecimento de atividades. [63] propôs um novo método de transferência de conhecimento para reconhecimento de atividades para um novo espaço físico para aproveitar o processo de aprendizado no novo ambiente. Os autores criaram um modelo de coleta de dados que formata as informações obtidas como uma tupla que pode ser usada em qualquer ambiente de reconhecimento de atividades. A formatação das informações permite aos autores converterem dados não tratados em um modelo de atividades adequado para mapeamento.

Para avaliar o desempenho do método desenvolvido, os autores usaram dados coletados por um período de três meses em três diferentes apartamentos. Cada apartamento era equipado com sensores de movimento e sensores de contato que monitoravam o estado

de abertura e fechamento de portas e armários. A configuração dos apartamentos ainda incluíam sensores de posição e etiquetas de localização. Cada um dos três conjuntos de dados era registrado com atividades de interesse para os residentes correspondentes do apartamento. Um total de 11 atividades foram notadas em cada caso que incluía banho, transição entre banheiro e cama, comer, entrar em casa, faxina, sair de casa, preparação de refeição, higiene pessoal, dormir na cama, dormir em outro lugar que não na cama (relaxamento) e tomar remédio.

Os autores executaram o algoritmo de transferência em cada par de apartamentos cujos dados foram coletados, resultando em seis diferentes problemas de transferência de conhecimento. Em cada conjunto foi utilizado 3 meses de dados rotulados fonte e 1 a 14 dias de dados não rotulados do alvo e 0 a 1 dias de dados rotulados do alvo.

Como próximo passo do experimento, os autores mapearam as atividades do fonte para as atividades do alvo. Os resultados concluíram que transferir os dados do apartamento com maior quantidade de espaço e atividades teve melhor desempenho ao transferir dados para apartamento de menor quantidade de espaço.

Os autores utilizaram os algoritmos *Nearest Neighborhood* e *Hidden Markov Model* para testar dois algoritmos de reconhecimento de atividades nos dados rotulados transferidos. Os resultados mostraram que apesar de usarem um pequeno conjunto de dados não rotulados, ambos os algoritmos conseguiram realizar o reconhecimento no espaço alvo usando dados do espaço fonte.

[13] treinou um modelo de aprendizado de máquina de um ambiente inteligente para reconhecimento de atividades no ambiente. As atividades a serem identificadas eram cozinhar, assistir TV, usar o computador, arrumação, dormir e ir da cama para o banheiro. Após a extração das características e reconhecimento das atividades, foram utilizadas algumas das características que poderiam ser úteis para realizar a predição do consumo de energia da moradia. O ambiente inteligente implementado realizava coleta de dados de diversos sensores de movimento no teto de um apartamento do dormitório do campus da WSU (*Washington State University*). Também foram instalados sensores de temperatura, de uso da água quente e fria, uso do fogão e um medidor de energia foi usado para aferir usos instantâneos e total de energia. A partir dos dados brutos dos sensores eram extraídas as características a serem usadas para o treinamento do aprendizado de máquina.

Os métodos de aprendizado de máquina utilizados foram *Bayes Belief Networks*, *Artificial Neural Network*, *Sequential Minimal Optimization (SMO)* e *LogitBoost*. Os autores usaram o método de classificação com validação cruzada com 10 *Folds*. Além disso, utilizaram 2 seletores de características para selecionar as melhores delas. Os seletores de características utilizados foram o *Minimal Redundance Maximal Relevance (mRMR)* e *J48 Decision Tree Classifier*. Os autores combinaram os três modelos com os dois seletores de características mais um teste sem o uso de seletores de características.

A maioria dos algoritmos teve bom desempenho, *LogitBoost* alcançou 90% de acurácia para os dois conjuntos de dados utilizados e todos os seletores de características. O *SMO* alcançou a menor acurácia no valor de 70% com o *J48 Decision Tree Classifier*, os demais algoritmos alcançaram acurácias que ficaram dentro de 80% em média para todos os seletores de características.

[7] implementou um ambiente inteligente com um sistema de predição para prever o movimento de um usuário de um apartamento. O sistema tenta prever o movimento do usuário e prever quando deve ligar a luz do banheiro. Foram instalados dois grupos de sensores chamados de zona local (área próxima ao banheiro) e zona global (restante do apartamento). Na zona local foram instalados 7 sensores e na zona global foram instalados 86 sensores. O objetivo do experimento era captar informações dos sensores para treinar um preditor que iria dizer quando acender a luz, pois, segundo o padrão de movimento da pessoa, esta iria entrar no banheiro. Foram testados algoritmos classificadores separados e combinados. Os algoritmos testados separadamente foram *Naive Bayes* (NB), *Support Vector Machine* (SVM) e *Neural Network* (NN). Os algoritmos testados separadamente foram combinados entre si e com outros como o *Random Forest* (RF). Os algoritmos tiveram seu tempo de execução e acurácia medidos. O experimento contou com um mês de coleta de dados para treinar os classificadores, seguido de uma semana de dados usados para teste. Neste experimento podemos perceber que o tempo de coleta de dados para treinar o sistema é bem grande. Isso pode ser atribuído ao fato do experimento ter um único usuário e ao objetivo de obter padrões de movimentos. Para se entender os padrões é necessário que a combinação de sensores ativados permitam inferir quando o usuário vai ao banheiro. Como as informações dos sensores são bem simples, indicando apenas presença ou ausência, é necessário um número maior de dados para entender um padrão com alta acurácia. O ambiente projetado por [7] possui um sistema para executar uma única tarefa de atuação sem ênfase de personalização. Como resultado do experimento na zona local, a acurácia e o tempo de predição do SVM teve o melhor resultado com 99% de acurácia e demorando 0,89 segundos para realizar a predição. No experimento da zona global a melhor acurácia foi do algoritmo de redes neurais, com acurácia de 90%, porém, este algoritmo gastou o tempo de 6,5 segundos, o que é muito lento para o mundo real, segundo o autor. Esses resultados são baseados em todos os experimentos englobando algoritmos combinados e separados.

3.2 Ambientes inteligentes personalizados

A personalização de ambientes inteligente refina as tarefas do ambiente em prol de atender a um indivíduo. O trabalho desenvolvido por [30] é um ambiente inteligente que realiza o conforto térmico coletivo e individual usando redes neurais artificiais. Nesse ambiente foram analisados os dados para criar um preditor individual e um preditor coletivo. O preditor individual usa os dados de cada indivíduo para modelar um preditor de temperatura personalizada para cada pessoa. O preditor coletivo utiliza um sistema de votação de conforto do inglês *Predicted Mean Vote* (PMV) para prever uma temperatura que minimize o desconforto térmico de todos os ocupantes do ambiente. Os autores usaram Transferência de conhecimento profundo para melhorar o PMV. Os experimentos conduziram uma coleta de dados por 5 meses para construir o conjunto de dados. Os autores compararam o desempenho do algoritmo PMV com o algoritmo de transferências de conhecimento profundo baseado em aprendizado profundo. A melhoria obtida do aprendizado com transferência de conhecimento profundo sobre o algoritmo PMV foi de 73,9% alcançando uma acurácia de 63,08% contra a acurácia de 36,27% do PMV. Os autores compararam a modelagem de aprendizado por reforço profundo com outros modelos, inclusive com uma rede neural artificial que performou em 62,19%.

Uma rede neural profunda consiste em uma rede neural artificial (ANN) com múltiplas camadas ocultas. Não há um consenso sobre o número de camadas ocultas para ser considerada rede neural profunda. Alguns autores consultados citam que pode ser considerada rede profunda uma ANN com pelo menos 2 camadas ocultas além da camada de entrada e da camada de saída [38], [68], [21], [31].

O ambiente inteligente proposto por [42], realiza o controle térmico personalizado para pessoas com idade superior a 65 anos. O objetivo desse controle é otimizar a temperatura do ambiente residencial conforme as características individuais e preferências de cada pessoa.

No experimento foram instalados registradores de dados no ambiente interno da casa dos participantes. Um *tablet* solicitava um questionário a ser respondido, pelo menos uma vez por semana. O questionário continha perguntas sobre temperatura do ambiente, a preferência e sensação térmica dos participantes. A coleta de dados ocorreu durante um período de 9 meses. O artigo aferiu a composição corporal de cada participante do experimento como peso, altura e índice de massa corporal.

[42] utilizaram redes neurais artificiais para desenvolver um modelo de conforto personalizado para um subconjunto de participantes envolvidos no monitoramento do estudo. O modelo foi desenvolvido para realizar uma tarefa de classificação multi classe da preferência termal dos ocupantes em 3 pontos de escala (preferindo estar mais frio, preferindo não ter mudança e preferindo estar mais quente). O questionário termal foi

utilizado como base para treinar o modelo e depois verificar os valores preditos.

O estudo mostrou que a precisão da predição de conforto personalizado é superior à predição de conforto com voto e temperatura média. A precisão de conforto para a temperatura média por voto é de 46,1% contra os 78,1% do modelo personalizado.

No ambiente inteligente desenvolvido por [34] foi desenvolvido um sistema de conforto de luminosidade. Este sistema foi elaborado de forma que o controle da luminosidade do ambiente realize o conforto luminoso do usuário, mas também realize o controle de consumo energético da edificação. Esse ambiente é composto por luminosidade da sala como lâmpadas no teto, bem como uma luminosidade individual como lâmpadas individuais nas áreas de trabalhos dos indivíduos. Dessa forma, o sistema inteligente pode controlar tanto a luminosidade de cada estação de trabalho quanto a luminosidade da sala. Isso pode ser feito considerando a ocupação da sala e a preferência individual de luminosidade de cada ocupante do ambiente. Esse ambiente inteligente objetiva tanto o conforto de luminosidade individual quanto a eficiência de consumo energético da edificação.

O ambiente de experimentação ocorreu no laboratório chamado *Electrical Machines and Drives Laboratory (EM DL)* no departamento de engenharia elétrica e computacional na *National University of Singapore (NUS)* em Singapura. No laboratório há 24 estações de trabalho equipadas com um computador pessoal, iluminação personalizada (luminária da mesa) e sensor de luminosidade sobre as áreas de trabalho. Cada usuário do ambiente podia controlar a intensidade luminosa do seu ambiente por um software de controle de intensidade luminosa com interface gráfica.

O sistema coletava as preferências do usuário a medida que o usuário ajusta a luminosidade com o software de controle de intensidade luminosa. O sistema detectava a ocupação do ambiente por meio de um sensor de infravermelho que detectava a radiação infravermelha das pessoas. As recomendações de luminosidade do sistema eram geralmente feitas com base no histórico do usuário ou similaridade entre múltiplos usuários. O algoritmo de predição e gerenciamento era baseado no cálculo da distância de Manhattan, baseado na preferência do usuário e no consumo de energia, que eram calculadas separadamente. Então estas eram normalizadas para combinarem juntas para derivarem o valor final de recomendação. Este era enviado ao atuador para ajustar a intensidade luminosa.

Depois de um mês de operação manual da luminosidade do ambiente, o sistema de predição começou a operar e controlar as luzes automaticamente. Os resultados da experimentação mostraram pelo menos 72% de redução no consumo de energia por dia em comparação com sistemas convencionais.

Em [41] foi desenvolvido um ambiente inteligente de controle de luminosidade personalizada que considera a luminosidade externa para realizar o controle da luminosidade interna do ambiente. O ambiente é dotado de grandes janelas que permitem a entrada de luz. Isso por que em muitas edificações atuais a luminosidade que provém de luz natural externa, a partir de grandes janelas, é importante para a economia e eficiência energética

das edificações. Dessa forma, esse ambiente realiza a predição de luminosidade interna baseado na preferência de cada usuário sobre a luminosidade interna e luminosidade externa. O controle da luminosidade externa nesse ambiente é feita manualmente, pois esse ambiente não possui um sistema de fechamento automático das persianas da janela. Isso torna necessário que o usuário feche as persianas de acordo com seu conforto luminoso.

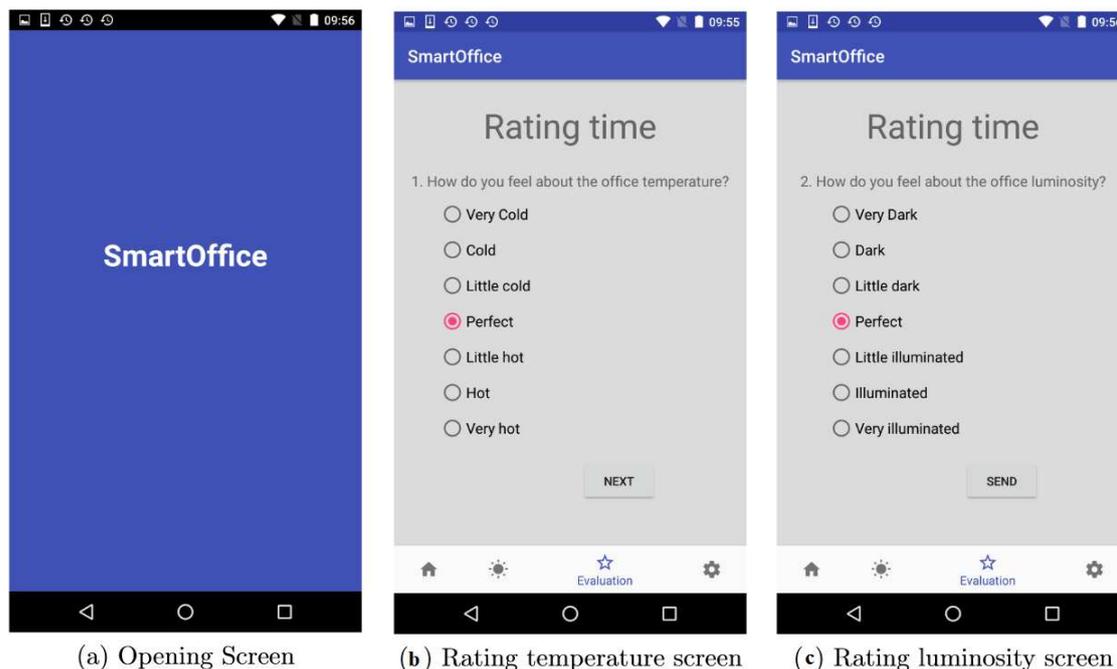
O estudo conduziu o experimento de predição de conforto utilizando quatro métodos diferentes de aprendizado de máquinas que são: Núcleo de Máquina de vetor suporte — *Kernel Support Vector Machine* (SVM), Floresta Aleatória — *Random Forest* (RF), Modelo Misto Gaussiano — *Gaussian Mixed Model* (GMM), Árvore de Classificação — *Classification Tree* (CTree). Estes modelos foram escolhidos pelo experimento por necessitarem de poucos dados para serem treinados.

O ambiente criado por [41] coletou dados por 6 meses, sendo obtido um total de 1274 conjuntos de dados dos 6 participantes com uma média de dados coletados de 212 por participante.

Em [19] foi implementado um ambiente inteligente para escritório inteligente, utilizando a plataforma ManIoT. O ambiente conta com atuação de controle de temperatura e controle de luminosidade personalizado, podendo ser expandido para outros tipos de conforto personalizados como o conforto sonoro, por exemplo. Esse ambiente foi desenvolvido a partir de coleta de dados do usuário e teve um conjunto de técnicas de aprendizado de máquinas testados. Na modelagem do ambiente foi aplicada a técnica de regressão para alcançar o modelo de predição do ambiente. Esse ambiente é dotado de sensores de temperatura, umidade, pressão, luminosidade e outros. O ambiente também pode contar com atuadores como controle de luminosidade e controle de temperatura do ar condicionado do ambiente.

O sistema objetiva prever as preferências do usuário conforme as respostas de satisfação no software de questionamento do usuário, como mostrado na Figura 3.1. O software questiona como o usuário se sente com relação à temperatura do ambiente e com relação à luminosidade do ambiente e guarda estas informações em um banco de dados. [19] demorou 25 dias para coletar 205 avaliações de seu usuário, o que é muito pouca informação em um período muito grande. Isso torna moroso o treinamento do sistema para personalizá-lo, pois, além da quantidade pequena de dados o tempo para coleta, torna inviável a personalização de um escritório inteligente. O autor enfrentou o problema no tempo de coleta e na quantidade de dados a serem obtidos. Esse problema torna inviável a implementação de um ambiente inteligente personalizado, pois um usuário demoraria um mês ou mais para ter seu ambiente funcionando.

Figura 3.1: Tela do software de coleta de informações.



Fonte: [19], 2019.

3.3 Aprendizado de máquina com poucos dados

O processo de coletar dados é demorado e propício a erros, além de gerar distúrbios no cotidiano dos participantes do fornecimento dos dados [15]. O custo de coletar dados para ambientes inteligentes é muito grande e pode tornar inviável a implementação do ambiente. Fatores como falta de tempo disponível para interação e impaciência limitam a coleta dos dados para ambientes inteligentes [13]. Dessa forma, modelagens de predição como em [15] utilizam dados já rotulados em experimentos anteriores. Os dados destes experimentos necessitaram de meses para serem obtidos, para realizarem a experimentação de prova de conceito.

O objetivo do trabalho de [51] é criar um modelo de regressão que prediz o conforto térmico pessoal no ambiente inteligente e assim poder realizar o controle da temperatura do ambiente de forma personalizada. O arcabouço do experimento consiste em 5 participantes em salas inteligentes individuais com sensores e atuadores, que foram expostos em uma variedade de condições de altas e baixas temperaturas e altas e baixas umidades. No arcabouço do experimento, foram medidos, usando o *Microsoft Band*, batimentos cardíacos, temperatura da pele, calorias consumidas, taxa metabólica, altímetro, barômetro, passos realizados e elevação. Os dados providos com o *Microsoft Band* são rotulados com as classificações de conforto térmico fornecidas pelo usuário. O retorno do

usuário é provido por meio de resposta por voz do conforto atual entre os possíveis níveis de conforto que são muito frio (-3), frio(-2), pouco frio(-1), confortável(0), morno(1), quente(2) e muito quente(-2). A partir dos dados colhidos, um modelo de regressão foi implementado para prever qual a preferência térmica pessoal de cada indivíduo participante do experimento.

De acordo com [51] o treinamento de modelos de conforto térmico personalizado requer muitos dados rotulados para serem treinados. Dessa forma, o artigo de [51] se propõe a resolver esse desafio através da proposta da transferência de conhecimento e aprendizado ativo para predição de conforto termal. Isso irá reduzir a dificuldade da tarefa de coletar uma grande quantidade de dados rotulados para cada usuário. O objetivo do trabalho de [51] é criar um modelo de predição do conforto termal pessoal, mas que não requer uma grande quantidade de dados rotulados por usuário. O resultado do estudo mostrou ser possível reduzir o número de dados rotulados necessários em 70% em média sobre todos os usuários do experimento. O *framework* desenvolvido atingiu um erro médio quadrático (RMSE), do inglês *Root-Mean-Square Error*, de 0,818 com padrão de erro de $\pm 0,05$ com apenas 25 exemplos amostrados em comparação com o RMSE de 0,845 com padrão de erro de $\pm 0,04$ quando usado 82 exemplos amostrados. Isso quer dizer que o *framework* pode atingir desempenho similar com menos recursos de dados. Os 5 participantes, três homens e duas mulheres participaram do estudo por duas semanas, cada um em uma sala individual onde foram coletados os dados. Os participantes foram expostos à coleta de dados de 9 horas da manhã até às 17 horas da tarde. Foram obtidos um total de 1337 dados, dentre os quais 1017 foram úteis para o treinamento do ambiente.

A transferência de conhecimento aplicada em [30] foi realizada para o treinamento de um ambiente supervisionado para modelar o conforto térmico utilizando redes neurais artificiais de classificação. O trabalho utilizou como base de dados para transferência de conhecimento a base *ASHRAE Global Thermal Comfort Database II* da ASHRAE, do inglês *American Society of Heating, Refrigerating and Air-Conditioning Engineers*. Essa é a maior base de dados disponível e de código aberto relacionado com o problema do ambiente inteligente do artigo, contendo 81486 amostras. Além da base de dados da ASHRAE, o projeto contou com a coleta de dados de 5 meses, gerando um total de 6257 dados coletados. Dos dez algoritmos testados, a transferência de conhecimento em redes neurais obteve o segundo melhor desempenho, obtendo 63,08% de acurácia, enquanto o *Random Forest* foi o algoritmo com melhor desempenho com acurácia de 66,32%. Os resultados mostraram que a transferência de conhecimento pode melhorar o preditor, pois a rede neural sem a transferência de conhecimento obteve acurácia de 62,19%.

[3] investigam o potencial de comunicação e transferência de aprendizagem entre ambientes inteligentes. Isso objetiva capacitar um ambiente para transferência de serviços e modelos de aprendizado de máquina.

[3] implementam um sistema para detecção de ocupação de um ambiente inteligente

baseado apenas na quantidade de CO_2 (gás carbônico) do ambiente. Para demonstrar o funcionamento e eficácia da transferência de conhecimento em ambientes inteligentes, o artigo realiza um experimento de caso de uso. O caso de uso trabalha um importante papel na aplicação de eficiência energética em ambientes inteligentes que é a verificação de ocupação do ambiente. O trabalho implementa uma predição de ocupação em ambientes inteligentes ao realizar a contagem de usuários no recinto através da taxa de CO_2 no ambiente. A modelagem foi implementada utilizando dados coletados de 3 ambientes, tendo sido utilizado um algoritmo de regressão logística para criar um modelo de predição. Foram realizadas várias combinações dos dados dos ambientes. Isso objetiva auferir a eficiência da transferência de conhecimento para prever a contagem do número de usuários presentes utilizando apenas a quantidade de CO_2 do ambiente. A conclusão do experimento é que a desempenho da transferência de conhecimento com ajuste fino foi o melhor cenário de resposta da experimentação ao obter o menor *Mean Absolute Error* (MAE) — Erro médio absoluto. Isso mostra que a transferência de conhecimento tem um bom potencial para treinamento de aprendizado de máquina que não possui muitos dados à sua disposição no início da implantação.

[3] aplicaram diferentes combinações de treinamento de aprendizado de máquinas que incluem treinamento, reuso e transferência de conhecimento. No primeiro caso, dados de treino e testes são do mesmo espaço e originam-se do mesmo conjunto de dados coletados dos sensores. Este modelo oferece geralmente o melhor desempenho, mas requer tempo para coleta de dados. No reuso, o modelo é adotado da forma que foi obtido e a base de teste utilizada é baseada nos dados do ambiente alvo ou ambiente de destino. A premissa é que os espaços de origem e destino do modelo tem características similares e esse método produz resultados com baixo custo. Isso quer dizer que não tem custo de treino e usa um conjunto de dados pequeno para avaliação. Na transferência de conhecimento, o modelo original é novamente treinado em um pequeno conjunto de dados providos pelo ambiente alvo ou destino. Isso provê melhores resultados se comparado com o modelo original puro sem a aplicação da transferência. Em dois dos três cenários de teste do projeto, a transferência de conhecimento obteve melhor resultado de teste do que o treinamento do ambiente com apenas dados do próprio ambiente. No ambiente onde os dados locais resultaram em um modelo melhor do que o de transferência, o ajuste fino (*fine-tuning*) melhorou o erro de predição da transferência de conhecimento. Para aplicar a transferência de conhecimento, foi implementada a técnica de ajuste fino (*fine-tuning*). Essa técnica utiliza o fato de que os dados gerados nas primeiras camadas de uma *ANN* são mais genéricos e os das últimas camadas são mais específicos. Assim, o *Fine-tuning* se propõe apenas a treinar as últimas camadas da rede neural para reduzir o tempo de treinamento e aproveitar o conhecimento genérico obtido pela rede.

[12] trata da melhoria da Qualidade de experiência de jogo em jogos online (*QoE*) do inglês *Quality of Experience*. Os autores descrevem que muitos contextos ligados a

serviços de jogos em redes obtêm melhorias a partir de aprendizado de máquina, do inglês *Machine Learning* (ML) e são necessárias uma grande quantidade de dados para treino de modelos de ML.

[12] descrevem que o método de treinamento supervisionado de ML, é muito usado para avaliação subjetiva de *QoE*, porém, é muito caro em termos de tempo e recursos obter dados rotulados dos humanos (Jogadores). Além disso, a principal limitação dos algoritmos de ML é sua limitada capacidade de generalização para outros cenários. Isso se dá por que ML assume que os dados de treino e teste tem a mesma distribuição dos dados. Os autores afirmam que as técnicas de transferência de conhecimento do inglês *Transfer Learning* (TL), adapta modelos para diferentes cenários enquanto decresce a necessidade por uma grande quantidade de dados. Especificamente, TL pode transferir conhecimento prévio de um modelo pré-treinado (modelo fonte) para criar um novo modelo em um ambiente destino. Este demandará menos tempo e dados para alcançar um desempenho que demandaria muito tempo e dados se fosse treinado do início. Os autores alcançaram uma redução de 53% do erro médio do modelo considerando um novo jogador em um jogo bem conhecido. Para um jogador conhecido em um novo jogo, a redução do erro foi de 41,6%. Para um grupo distinto de jogadores, a redução foi em torno de 72%. Em termos de quantidade de dados rotulados foi alcançada a redução de 81,1% dos dados. Os resultados obtidos na pesquisa obteve um intervalo de confiança de 95%. Dessa forma, os autores concluíram que a utilização de transferência de conhecimento reduz a demanda por inúmeros dados rotulados. Além disso, a transferência de conhecimento pode melhorar a estimativa de qualidade de experiência dos jogadores em diferentes contextos.

Durante a experimentação, [12] coletou uma quantidade de 2169 conjuntos de dados apenas, divididos em 3 tipos de jogos. Desses 3 jogos, um primeiro jogo foi jogado por 3 pessoas, gerando um total de 1765 instancias de dados. Um segundo jogo foi jogado por apenas uma pessoa durante um período que gerou 302 instância de dados. Um terceiro jogo foi jogado por 42 duas pessoas, realizando um total de 102 instâncias de dados. Essa coleta de dados permite dimensionar a dificuldade de obter dados com a participação de pessoas nos experimentos, mesmo que sejam divertidos como jogos digitais. O ambiente de coleta era uma universidade com milhares de jovens estudantes em que apenas 45 se dispuseram a jogar jogos de videogame online. Isso gerou um total de 2169 instâncias de dados durante o período de coleta [12].

A comparação do tempo e do resultado da coleta de dados para alguns dos trabalhos relacionados podem ser vistos na Tabela 3.1. A Tabela 3.1 mostra que apesar de longos períodos empregados na coleta dos dados, a quantidade de dados coletados é pequena devido à necessidade de abundância de dados para treinamento de modelagem de aprendizado de máquina.

A Tabela 3.2 compara os trabalhos relacionados e mostra as tecnologias utilizadas para implementação de seus trabalhos. A Tabela 3.2 apresenta o número de usuários que

Tabela 3.1: Trabalhos relacionados e suas demandas de coletas de dados.

Autor	Tempo	N.º de rótulos	N.º de usuários	Aplicação
[19]	25 dias	205	1	Ambientes inteligentes
[30]	5 meses	6257	—	Ambientes inteligentes
[51]	2 semanas	1017	5	Ambientes inteligentes
[41]	6 meses	1274	6	Ambientes inteligentes
[11]	2 anos	2169	45	Jogos em nuvem

Fonte: Autor, 2023.

participaram da coleta de dados, se houve otimização de hiperparâmetros, se foi aplicada transferência de conhecimento, se foi aplicada personalização no projeto, se a aplicação era em ambientes inteligentes, se o ambiente aplicado era real ou não e o tipo de coleta de dados. Comparando as pesquisas na Tabela 3.2, os únicos trabalhos que encontramos que aplicam as mesmas tecnologias que este trabalho são [51] e [11]. Porém, apesar de possuírem as mesmas tecnologias, [51] não aplicam as mesmas técnicas em cada tecnologia e [11] aplica as mesmas técnicas em cada tecnologia, porém em outro contexto que é o de Jogos Digitais.

Tabela 3.2: Comparação entre trabalhos relacionados e este trabalho.

Trabalhos	N.º de Usuários	Otim. de hiperp.	Transf. Conhec.	Person.	Aplicação	Ambiente real	Fonte de Dados
[63]	—	não	sim	não	Ambientes	não	BD
[13]	—	não	não	não	Ambientes	não	BD
[7]	1	não	não	não	Ambientes	sim	sensores
[19]	1	não	não	sim	Ambientes	sim	peessoas
[30]	—	não	sim	sim	Ambientes	não	BD
[51]	5	sim	sim	sim	Ambientes	sim	peessoas
[34]	24	não	não	sim	Ambientes	sim	sensores
[42]	—	sim	não	sim	Ambientes	sim	sensores
[41]	6	não	não	sim	Ambientes	sim	sensores
[11]	45	sim	sim	sim	Jogos digit.	sim	peessoas
Este trabalho	3	sim	sim	sim	Ambientes	sim	peessoas

Fonte: Autor, 2023.

3.4 Conclusões

Com a evolução do aprendizado de máquinas, ambiente inteligentes estão sendo desenvolvidos para muitos propósitos. Estes propósitos são desde economia de energia até a personalização de conforto de pessoas nos ambientes supervisionados. Os ambientes personalizados visam otimizar o conforto dos ocupantes de um ambiente inteligente.

Em ambientes inteligentes, a necessidade de coleta de dados de forma consciente por parte das pessoas geram empecilhos que dificultam a obtenção de quantidades de dados necessários à modelagem de aprendizado de máquina. A dificuldade de obtenção dos dados leva à necessidade de técnicas de aprendizado de máquina que permitam alcançar

um bom desempenho do modelo mesmo com tempo e condições limitados para a obtenção de dados. Dessa forma, as técnicas como transferência de conhecimento e ajuste fino em redes neurais artificiais são contempladas neste projeto para a solução dos problemas de coleta de dados para personalização de conforto.

Capítulo 4

Entendimento, Preparação e Análise dos Dados

Neste capítulo serão apresentadas a motivação, a estruturação, formas de obtenção, tratamento, aplicação, problemas enfrentados e as soluções alcançadas para lidar com os dados deste projeto.

4.1 Entendimento e Preparação dos Dados

Os dados obtidos neste projeto seguem algumas das propriedades utilizadas no projeto de [19] para prever o conforto de um indivíduo em um ambiente inteligente. Em [19], o autor utilizou as seguintes propriedades para predição de conforto luminoso e de temperatura:

- luminosidade interna;
- luminosidade externa;
- qualidade do ar;
- umidade;
- ruído;
- pressão;
- temperatura da sala;
- porta aberta ou fechada;
- janela aberta ou fechada;
- hora.

Neste projeto foram utilizadas apenas algumas das características mencionadas anteriormente. As motivações para o uso de apenas algumas características serão explicadas nas próximas seções.

Tabela 4.1: Mapeamento da avaliação de valores categóricos de diferentes condições de luminosidade do ambiente.

Valor da avaliação	Avaliação da luminosidade
0	Escuro Demais
1	Muito Escuro
2	Pouco Escuro
3	Confortável
4	Pouco Claro
5	Muito Claro
6	Claro Demais

Fonte: Autor, 2023.

4.1.1 Características do ambiente

Esta dissertação focou exclusivamente no conforto de luminosidade de um ambiente inteligente e utilizou as propriedades disponíveis no sensor cuja utilização em um ambiente residencial foi viável. Foram utilizadas as características do ambiente mensuradas pelo sensor que julgou-se serem pertinentes ao problema de predição personalizada de conforto de luminosidade em ambientes supervisionados.

Para a elaboração do projeto foi utilizado um hardware multi sensor, o *MultiSensor 6 AEOTEC*, que pode ser visto na Figura 4.1, que media 6 características do ambiente em que dessas 6 propriedades, 3 foram utilizadas para criar um preditor de conforto personalizado neste projeto. As propriedades utilizadas foram as de temperatura, luminosidade e umidade, sendo que dois sensores foram utilizados para obter a luminosidade interna e luminosidade externa. Estas características foram escolhidas por serem pertinentes ao nosso problema, por serem as possíveis de medir no ambiente residencial e por terem semelhanças com as características do ambiente de [19]. A umidade, temperatura e luminosidade interna foram obtidas pelo *MultiSensor 6 AEOTEC* que ficava sobre a mesa do usuário, a luminosidade externa era medida pelo *MultiSensor 6 AEOTEC* que ficava na janela do escritório. Outro fator que influencia na luminosidade de um local é a hora do dia, esta também foi uma propriedade obtida durante a coleta de dados no escritório inteligente. A hora era obtida pelo software ManIoT que contabilizava a hora quando ocorria uma alteração no estado do ambiente, como mudança na temperatura, nas luminosidades interna ou externa, ou na umidade do ambiente.

Para realizar a coleta dos dados dos rótulos, foi desenvolvido um software, que era executado a cada alteração no estado do ambiente. Isso quer dizer que a cada alteração de temperatura, luminosidade externa, luminosidade interna e umidade, o sistema realizava a chamada do software. Essa chamada questionava o usuário sobre qual era o seu nível

Tabela 4.2: Formalização do conjunto de dados.

Característica	Descrição	Faixa de valores	Pre-processamento
luminosidade interna	Descreve o valor em lux da luminosidade no sensor sobre a mesa do escritório	0 a 966 LUX ± 2 LUX	Análise, higienização e normalização
luminosidade externa	Descreve o valor em lux da luminosidade no sensor da janela do escritório	1 a 3529 LUX ± 2 LUX	Análise, higienização e normalização
temperatura	Descreve o valor em °C da temperatura no sensor sobre a mesa do escritório	20,9 a 31,1 °C $\pm 0,1$ °C	normalização
umidade	Descreve o valor em % da umidade do ar no sensor sobre a mesa do escritório	32 a 88% ± 3 %	normalização
hora	Marca as horas e os minutos em que o conjunto de valores foram medidos pelos sensores, no formato HH,MM	08,13 a 19,00 HH,MM	normalização

Fonte: Autor, 2023.

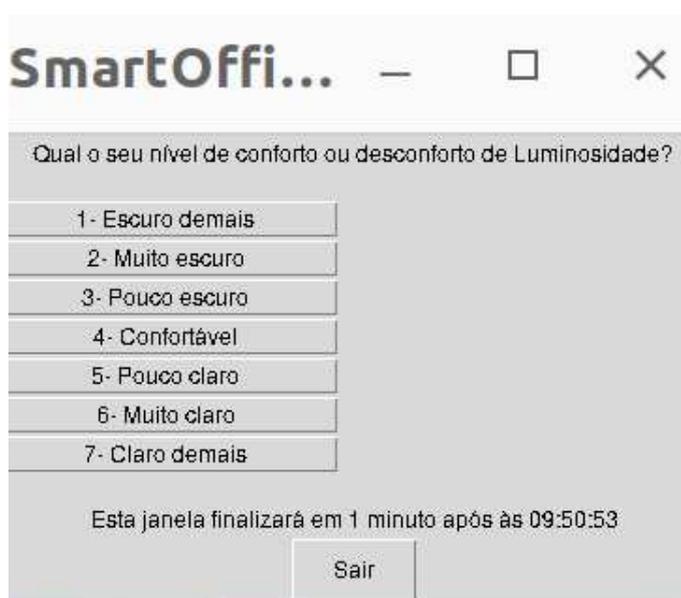
de conforto com o novo estado do ambiente, como pode ser visto na Figura 4.2. Caso o usuário não respondesse, o software entendia que o usuário estava confortável e retornava o valor correspondente a confortável. As possíveis respostas para o software era Escuro demais, Muito escuro, Pouco escuro, Confortável, Pouco claro, Muito claro, Claro demais representados respectivamente por números no intervalo de 0 a 6 como pode ser visto na Tabela 4.1. Estes valores foram interpretados como rótulos para treinamento do preditor de conforto personalizado. Dessa forma, a composição do banco de dados era rótulo, luminosidade interna, luminosidade externa, umidade, temperatura e hora. Os valores e propriedades das características podem ser vistos na Tabela 4.2.

4.1.2 Condições e propriedades das coletas de dados

O projeto almeja mostrar a eficiência e a eficácia da proposta para o aprimoramento de treinamento personalizados de ambientes supervisionados. Para isso, era preciso ter um ambiente fonte previamente treinado e com boa acurácia de predição para realizarmos a transferência de conhecimento com maior acurácia de predição do ambiente destino.

Figura 4.1: *Hardware* multi sensor MultiSensor 6 Aeotec.

Fonte: [1], 2023.

Figura 4.2: Tela de perguntas de conforto do *SmartHomeOffice*.

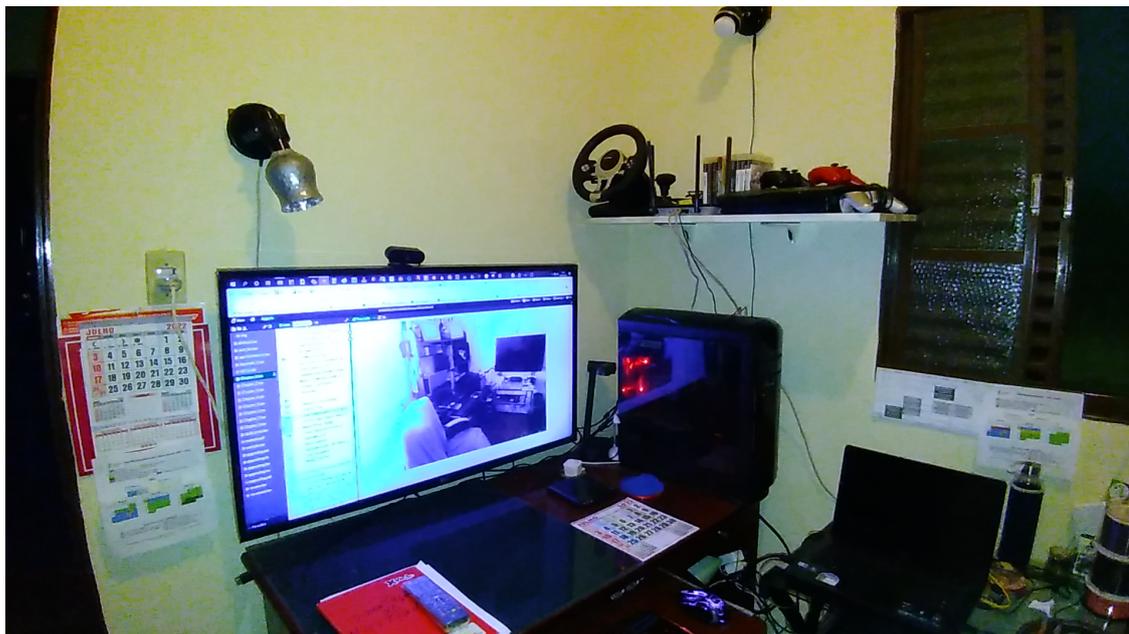
Fonte: Autor, 2023.

Também foi necessário obter dados de usuários em um ambiente destino em que seria aplicada a transferência de conhecimento com o ajuste fino.

Para o experimento do projeto, foram utilizados três coletas de dados em que duas coletas foram feitas no mesmo ambiente por duas pessoas em momentos distintos. O terceiro conjunto de dados foi importado dos experimentos de [19]. Os três conjuntos de dados são descritos a seguir:

- **Conjunto de dados 1:** O conjunto de dados 1 foi obtido no escritório inteligente residencial como o mostrado na Figura 4.3 implementado pelo autor. Os dados foram coletados em um período de 31 dias não consecutivos no intervalo de 15 de setembro de 2022 a 13 de janeiro de 2023. O usuário 1 realizou a coleta em

Figura 4.3: Escritório residencial inteligente implementado em casa.



Fonte: Autor, 2023.

dias intercalados devido à indisponibilidade de coleta em diversos dias consecutivos. Foram coletados um total de 1019 instâncias de dados que após a higienização dos dados restaram 946 instâncias de dados como pode ser visto na tabela 4.3. Os dados foram coletados através do questionamento direto do usuário por um software, criado pelo autor, que era ativado quando o estado do ambiente era alterado. Isso quer dizer que quando ocorria pelo menos uma das alterações de luminosidade interna, luminosidade externa, temperatura da sala ou umidade do ambiente, o questionário era executado. O software executava uma janela flutuante no monitor do usuário, como mostra a Figura 4.2, com o questionário e exibindo as possíveis opções de conforto que o usuário deveria escolher. As respostas eram armazenadas em um banco de dados, no formato *CSV*, do inglês *Comma-Separated Values*, em que cada entrada do banco de dados era composta pelo rótulo de dados e pelo estado do ambiente. Este era composto pelos valores das propriedades do ambiente no instante do questionamento.

- **Conjunto de dados 2:** O conjunto de dados 2 foi coletado por um segundo usuário no mesmo ambiente do usuário 1. A coleta de dados do usuário 2 ocorreu no período de 11 dias consecutivos nos dias compreendidos entre 10 de abril de 2023 a 20 de abril de 2023. O período inicial para a coleta de dados era de duas semanas, porém o sistema do *Smarthings* que gerenciava e gerava os dados dos sensores foi descontinuado pela Samsung no 11º de coleta de dados. A descontinuação do sistema da *Smarthings* impediu que novos conjuntos de dados fossem coletados em tempo hábil para a conclusão deste projeto.

O usuário 2 foi instruído para ser mais criterioso na sua resposta de conforto. Isso quer dizer que o usuário foi instruído a observar o ambiente no momento do questionamento e avaliar por alguns segundos qual o seu nível de conforto naquele instante. Essa instrução teve o propósito de termos uma maior precisão no conforto real do usuário dadas as condições do ambiente. A instrução surtiu efeito, pois o usuário 2 teve a melhor distribuição dos rótulos entre os 3 conjuntos de dados como pode ser visto na Tabela 4.4. O armazenamento dos dados ocorreu da mesma forma que no conjunto de dados 1 sendo armazenado em um arquivo *CSV* utilizando o mesmo formato de dados. A coleta do conjunto de dados 2 resultou em um total de 402 conjuntos de dados e restando 330 conjuntos após a higienização dos dados.

- **Conjunto de dados 3:** Os dados de [19] foram coletados no gabinete do professor Daniel Macedo que fica no departamento de Ciência da Computação da UFMG. Esse ambiente inteligente utilizava outros sensores, além dos que foram utilizados nos conjuntos de dados 1 e 2, que coletavam dados de outras propriedades do ambiente. Essas propriedades incluíam ruído do ambiente, abertura e fechamento de portas, janelas e cortinas do escritório, pressão atmosférica, qualidade do ar, além de presença e ausência do usuário no ambiente inteligente. Os dados armazenados, eram o resultado de coleta dos dados dos últimos 30 dias, devido à natureza de seus experimentos e objetivos de pesquisa.

O conjunto de dados 3 somam um total de 184 entradas no período de 25 dias, como mostrado na Tabela 4.3 obtidos de novembro de 2018 a janeiro de 2019. Como estes dados foram importados de outros experimentos, não houve necessidade de higienização dos dados. Apesar de não precisar de higienização, o conjunto de dados 3 teve que ser adaptado ao novo ambiente, pois possuía mais características mensuradas do que o novo ambiente. Dessa forma, a adaptação ocorreu ao se remover as características que não fossem em comum com o novo ambiente.

Tabela 4.3: Relação de coleta e perda de dados.

Conjunto	Dados Coletados	Dados Restantes	Dias de Coleta
1	1019	946	31
2	402	330	11
3	-	184	25

Fonte: Autor, 2023.

4.1.3 Dificuldades nas coletas dos dados

Em todas as três coletas de dados, a quantidade de dados é pouco expressiva dada a quantidade de dias disponibilizados para a coleta dos dados. Essa pouca quantidade de dados obtidas é devido a diversos fatores que dificultaram a coleta de dados durante os períodos dos experimentos. Os fatores que mais dificultaram a coleta de dados foram, incoerência de leitura dos sensores, indisponibilidade, subjetividade e imprecisão dos participantes, interferências externas imprevistas, problemas de indisponibilidade do sistema de leitura de sensores.

Durante os experimentos, muitas leituras dos dados obtidas pelos sensores eram incoerentes com a condição do ambiente. A exemplo, ter luminosidade zero no sensor de janela que fica exposto em uma janela translúcida e ter valor de luminosidade no sensor de mesa maior que zero. Este fato gera incoerência dos dados, pois os sensores dependem tanto da luminosidade que vem da janela quanto da luminosidade interna. Assim, em teoria, o sensor da mesa deveria ter luminosidade igual ou inferior ao da janela, exceto em uma situação manipulada.

A indisponibilidade dos usuários é um fator que interferiu bastante nos experimentos. Isso quer dizer que os usuários não podiam participar da coleta de informações a qualquer momento por motivos diversos. A indisponibilidade aumentou o tempo de coleta dos dados e não permitiu gerar uma frequência constante de coleta dos dados.

A subjetividade do usuário aparece quando este, em uma condição semelhante a outra já vivida, contabiliza grau de conforto muito divergente do que foi auferido anteriormente. Outra subjetividade observada no experimento é o fato do usuário estar confortável com muita frequência, mesmo com alterações consideráveis da intensidade luminosa do ambiente. Um possível motivo para isso é o fato do usuário se adaptar ao ambiente com o controle de entrada de luz pelas pupilas. Os usuários também não alteravam seu nível de conforto luminoso a partir de determinado horário, pois a luminosidade do ambiente era artificial e constante. Essa condição de luminosidade constante não alterava o nível de conforto luminoso do participante.

As interferências externas geram valores incoerentes nos sensores, principalmente nos luminosos. Um exemplo de interferência seria o sombreamento ou luminosidade excessiva nos sensores durante a leitura das informações, causando anomalias no estado do ambiente. O sombreamento pode ser causado por um pássaro que passou na janela, pelo usuário que passou a mão ou algum objeto sobre o sensor, entre outras causas. A luminosidade excessiva ocorre com algum evento de iluminação artificial, como, por exemplo, algum tipo de reflexo dos raios de luz que geram uma leitura incorreta da intensidade luminosa. Esses eventos podem ocorrer no momento em que alguém acende alguma fonte luminosa sobre o sensor, como uma luminária, por exemplo, ou pelo reflexo de raios sola-

res refletidos por algum objeto sobre o sensor. Foi observado que o sombreamento é um fator muito mais frequente do que a iluminação excessiva. Outros fatores de interferência externa não foram percebidos mesmo que o tenham ocorrido, devido à menor relevância para a aferição da informação de conforto luminoso.

A indisponibilidade dos sensores também foi um problema na coleta de dados. A dependência de sistemas externos é um fator importante, pois muitas vezes estes sistemas podem falhar ou até descontinuar o serviço. Esse foi o caso deste projeto em que o sistema de coleta de dados da *Samsung Smartthings* gerou algum tipo de problema que descontinuou o sistema em abril de 2023. Alguns fatores geraram, por diversas vezes e por fim em definitivo, a indisponibilidade de coleta de dados pelo *Samsung Smartthings*. Alguns desses fatores foram: A troca de ambientes do experimento, a troca de *tokens* por parte do sistema e por fim a descontinuidade da aplicação *REST*, do inglês *Representational State Transfer*, hospedada no sistema da *Smartthings*.

4.2 Preparação dos dados coletados

Com os problemas citados anteriormente, foram gerados muitos dados com diversos tipos de problemas como dados incoerentes, desbalanceamento de rótulos, valores discrepantes (*outliers*), entradas replicadas e escala dos dados. Para solucionar esses problemas foi realizada a higienização e a normalização dos dados. Como explicado anteriormente, a higienização consiste na identificação e remoção de valores incoerentes, valores discrepantes (*outliers*) e entradas repetidas da base de dados. Para a normalização dos dados foram utilizados os métodos Logaritmo e Min-Max [61] para remover a diferença de escala entre características. O método Min-Max coloca os valores normalizados em um intervalo entre 0 e 1. O método Logaritmo aplica o cálculo de logaritmo em uma base escolhida, para este projeto foi utilizada a base 10.

Para um bom desempenho no treinamento de redes neurais, mesmo com poucos dados, devemos seguir a recomendação da regra de *Foley* [28]. De acordo com [61] a regra de *Foley*, também conhecida como a regra do dedão, diz que a proporção do número de amostras por classe (S) para o número de características (N) deve exceder em 3 para obter desempenho ótimo, ou seja,

$$\frac{S}{N} > 3. \quad (4.1)$$

Foley mostrou que quando a equação (4.1) é satisfeita, o erro do conjunto de treino deve se aproximar do erro do conjunto de teste e que o erro resultante deve se aproximar ao do classificador ótimo de Bayes. Por exemplo, se o número de características $N = 5$, então

o número de amostras (S) por classe deve ser $S > 5 \times 3$ o que implica que $S > 15$. Isso indica que cada rótulo deve ter pelo menos 15 exemplares no banco de dados.

Visando reduzir o desbalanceamento dos rótulos, foi solicitado que o segundo participante do ambiente fosse mais criterioso na coleta dos dados. Para isso, foi solicitado ao participante que, no momento de questionamento, observasse o ambiente por alguns segundos e se virasse para a posição da janela e então realizasse a resposta de conforto. Para obter todos os rótulos do intervalo, algumas condições extremas como luminosidade baixa foi executada no ambiente ao cair da tarde. Essa parte da experimentação foi realizada reduzindo a luminosidade do ambiente até que o participante se sentisse em condições de desconforto de escuridão demasiada. Os rótulos para as condições de luminosidade extrema foram obtidos com aferição da luminosidade externa do horário da manhã e com variação das intensidades das lâmpadas do ambiente até que o usuário se sentisse em condição de desconforto luminoso extremo. Dessa forma, os rótulos do conjunto de dados 2 teve uma melhor distribuição dos dados e abrangeu todos os rótulos em quantidades acima dos valores mínimos aceitáveis conforme a regra de *Foley*.

A preparação dos dados envolveu as seguintes tarefas:

- **Análise:** A análise dos dados foi realizada através da inspeção visual dos dados. O objetivo dessa análise era a de auferir as condições dos dados obtidos e verificar se havia alguma necessidade de remoção ou algum tratamento dos dados. Dessa forma os dados foram minuciosamente inspecionados visando encontrar alguma anomalia como valores discrepantes (*outliers*), incoerência de dados, dados replicados entre outras possibilidades. Para realizar a análise por inspeção, os dados foram ordenados no arquivo *csv* para possibilitar a percepção de alterações. A ordenação dos dados foi realizada primeiramente pelo rótulo, depois pelas características de luminosidades interna e externa que são as características mais influentes no objetivo do projeto. As demais características foram ordenadas seguindo seus valores de forma crescente e no critério de desempate de ordenação do próprio editor de planilhas do *LibreOffice*.
- **Higienização:** Após ordenar os dados, foi realizada a inspeção visual para realizar a higienização do banco de dados. Dessa forma, os dados repetidos, valores discrepantes (*outliers*) e valores incoerentes, foram removidos do banco de dados.

Foram considerados valores repetidos as entradas de dados nas quais as luminosidades internas e externas eram iguais e se mais 2 das outras 3 características fossem iguais. Dessa forma, os dados replicados eram removidos da base de dados para evitar problemas com a modelagem.

Os valores discrepantes (*outliers*) foram extirpados do banco de dados. Foram considerados *outliers*, os valores que visivelmente extrapolavam a mediana observada dos valores em 10 vezes ou mais. Estes ocorreram exclusivamente na medida de

luminosidade externa cuja medição estava sujeita a fatores externos. Estes fatores podem ser eventos desconhecidos e aleatórios como alta intensidade de raios solares direto nos sensores ou reflexão de luz por algum objeto incidindo no sensor.

Foram considerados valores incoerentes aqueles cuja configuração não fazia sentido, como, por exemplo, o sensor da mesa possuir um valor de luminosidade diferente de zero e o sensor da janela possuir um valor igual a zero. Esse tipo de situação é incoerente, pois os dois sensores estavam sujeitos à luminosidade interna e o sensor da janela estava sujeito a maioria da luminosidade externa. Dessa forma, só faria sentido o sensor da janela ser zero se o sensor da mesa também o fosse. Os conjuntos com valores incoerentes foram removidos do banco de dados.

- **Normalização:** Os valores das características dos dados possuíam escalas diferente, dessa forma foi necessário realizar a normalização dos dados. A aplicação da normalização dos dados é feita para evitar que características com valores e escalas muito grandes tenham mais influência na modelagem. Dessa forma, a normalização mudou os valores das colunas numéricas no conjunto de dados para usar uma escala em comum.

Os valores de luminosidade interna e externa foram normalizados para a escala logarítmica na base 10, pois a variância e a média dos dados são muito acentuadas entre cada conjunto de dados como mostrado nas Tabelas 4.5, 4.6 e 4.7. O objetivo da normalização logarítmica foi o de melhorar a precisão dos modelos, tendo em vista que a escala era muito diferente das outras grandezas.

Os demais valores do banco de dados foram normalizados na escala *Min-max* [61], pois os dados não sofreram uma diferença acentuada entre as propriedades de variância e média dos dados como exibido nas Tabelas 4.5, 4.6 e 4.7. A normalização *Min-Max* coloca todos os valores relacionados dos conjuntos de dados em um intervalo de valores de 0 a 1. Dessa forma mantemos a proporcionalidade dos dados e amenizamos a influência nos modelos pela discrepância dos valores dos dados.

A normalização interfere, positivamente, no treinamento do modelo, pois o erro para a correção dos pesos da rede neural estão na mesma escala como veremos nas seções adiante.

Tabela 4.4: Relação de distribuição dos rótulos dos conjuntos de dados.

Usuário	Rótulo	0	1	2	3	4	5	6	Total
1	Quantidade	16	15	23	626	160	58	48	946
1	%	1,69	1,59	2,43	66,17	16,91	6,13	5,08	100
2	Quantidade	43	47	63	109	27	25	16	330
2	%	13,03	14,24	19,09	33,03	8,18	7,58	4,85	100
3	Quantidade	0	6	3	152	2	16	5	184
3	%	0,00	3,26	1,63	82,61	1,09	8,70	2,72	100

Fonte: Autor, 2023.

4.3 Análise dos dados

Um grande problema ocasionado pela subjetividade do usuário e também pela coleta de dados ser em ambientes fechados é o fato das respostas do usuário estarem poucas vezes nos extremos dos rótulos. Isso ocasionou um desbalanceamento dos dados devido à subamostragem de rótulos no extremo do intervalo de valores de rótulos e sobreamostragem do rótulo de confortável. Com isso, foram gerados muitos valores que indicam que o participante está confortável e poucos valores que o usuário está extremamente desconfortável, indicando excesso ou falta extrema de luminosidade. A quantidade de valores no centro da distribuição dos dados, ou seja, rótulos que indicam que o usuário está confortável, variou de 33,03% a 82,61%. Porém, os valores dos extremos variaram de 0,00% a 13,03% para rótulos de muita luminosidade e variaram de 2,72% a 4,85% para escolhas de pouca luminosidade extrema, como pode ser visto na Tabela 4.4. Há casos em que determinado rótulo não é alcançado na coleta dos dados como pode ser visto na Tabela 4.4 em que o rótulo 0 ocorre zero vezes.

O número de características usados neste projeto foram 5, o que nos dá a necessidade de pelo menos 15 exemplos de cada rótulo, segundo a regra de *Foley*, para que o erro do conjunto de treino se aproxime do erro do conjunto de teste. Os três conjuntos de dados obtidos tiveram amostragens e proporções diferentes, como pode ser visto na Tabela 4.4, devido à disponibilidade de tempo, dificuldades e metodologia para coleta.

O conjunto de dados 1 mostrado na Tabela 4.4, satisfaz a regra de *Foley* em todos os rótulos, apesar dos dois primeiros rótulos estarem com valores iguais. O conjunto de dados 2 foi o que teve a melhor distribuição, em que todos os rótulos satisfizeram a regra de *Foley*, como pode ser visto na Tabela 4.4. O conjunto de dados 3 foi o que menos satisfaz a regra de *Foley*, como pode ser visto na Tabela 4.4, ao ter apenas 1 rótulo satisfazendo a Equação (4.1) e se tornando assim o conjunto de dados mais desbalanceado.

As Tabelas 4.5, 4.6 e 4.7 mostram as médias, medianas, variância, desvio padrão e a normalização dos três conjuntos de dados.

Podemos perceber que o conjunto de dados 2, com exceção da característica de

Tabela 4.5: Métricas do conjunto de dados 1.

métrica	luminos. interna	luminos. externa	umidade	temper.	hora
média	10,42	89,59	66,72	27,13	14,33
mediana	10,00	57,00	71,00	27,00	14,00
variância	70,41	8171,29	189,96	3,22	13,00
desvio	8,39	90,35	13,78	1,77	3,40

Fonte: Autor, 2023.

Tabela 4.6: Métricas do conjunto de dados 2.

métrica	luminos. interna	luminos. externa	umidade	temper.	hora
média	13,13	265,44	75,54	26,63	13,08
mediana	11,00	96,5	76,00	26,60	14,16
variância	92,05	198240,92	44,20	1,26	7,16
desvio	9,58	444,57	6,64	1,12	2,67

Fonte: Autor, 2023.

Tabela 4.7: Métricas do conjunto de dados 3.

métrica	lumin. interna	lumin. externa	umidade	temper.	hora
média	907,09	953,31	51,30	24,86	12,64
mediana	931,00	983,00	52,00	25,0	11,50
variância	6577,36	9279,18	20,32	1,60	7,67
desvio	80,88	96,07	4,50	1,26	2,71

Fonte: Autor, 2023.

luminosidade externa, tem a média das características próxima da mediana das características e possuem uma distribuição dos dados mais uniforme que os demais conjuntos de dados, como pode ser visto pela Tabela 4.4.

A dispersão dos dados indica a abrangência de informação do ambiente que foi coletada e como o ambiente pode variar suas características. Dessa forma, a variância e o desvio padrão podem nos informar a respeito da dispersão dos dados. Nas Tabelas 4.5 e 4.6, é possível notar que os conjuntos de dados 1 e 2 têm uma grande abrangência de informação sobre o ambiente.

Nas Tabelas 4.5, 4.6 e 4.7 é possível perceber que a luminosidade externa é uma característica que possui variância muito grande quando olhamos para os dados não normalizados.

A luminosidade interna possui variância relativamente pequena nos conjuntos de dados 1 e conjuntos de dados 2 quando comparada com a luminosidade externa. Isso mostra que a variação da luminosidade interna não fica longe da média destes dois conjuntos de dados.

O conjunto de dados 3 foi obtido em um ambiente diferente com possibilidade de

Figura 4.4: Matriz de correlação do conjunto de dados 1 não normalizado.



Fonte: Autor, 2023.

luminosidade diferentes, influenciando na variância da luminosidade interna. Isso torna a variância da luminosidade interna mais distante da média quando comparada como a luminosidade interna dos conjuntos de dados 1 e conjuntos de dados 2.

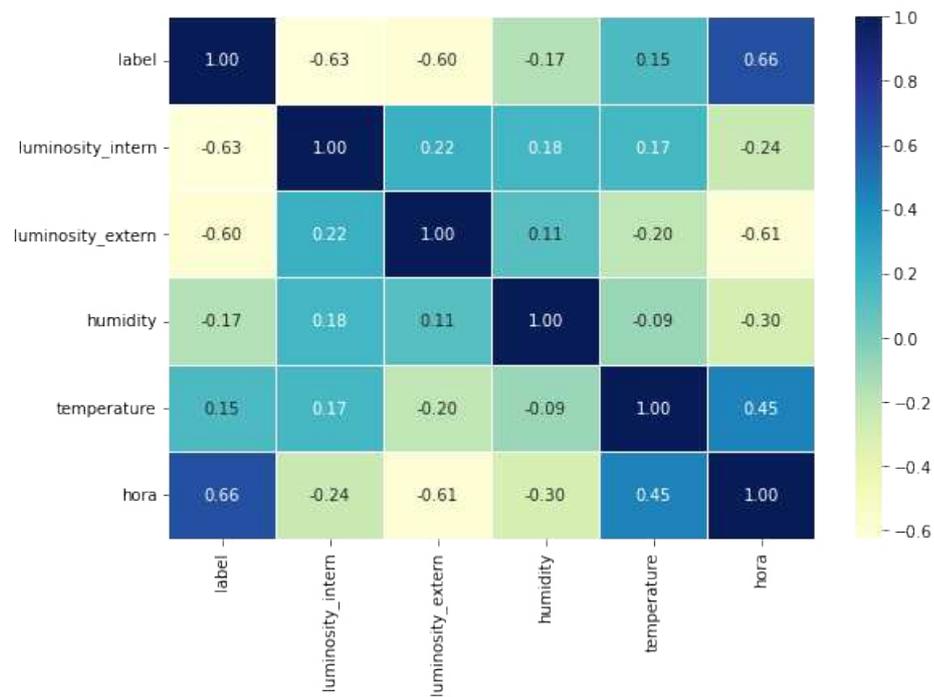
4.3.1 Correlação das Características

As matrizes de correlação das Figuras 4.4, 4.5 e 4.6 mostram a correlação das características com os rótulos e com as outras características. De acordo com [10], relações abaixo de 0,3 são consideradas relações fracas, relações acima de 0,6 são consideradas relações fortes e os casos contrários são considerados relações regulares.

O fato das características ter baixa correlação entre si indica que estas são independentes entre si. Dessa forma, as características contribuem para o treinamento do modelo de forma independente. Isso quer dizer que a remoção de uma das características pode afetar o poder preditivo do modelo [49]. O que pode não ocorrer quando características do modelo de dados tem alto valor de correlação entre si. Isso se dá porque a contribuição de informação para o modelo é similar entre características com alto valor de correlação [32].

Ao analisarmos as matrizes de correlação dos conjuntos de dados 1 e 2, representa-

Figura 4.5: Matriz de correlação do conjunto de dados 2 não normalizado.



Fonte: Autor, 2023.

Figura 4.6: Matriz de correlação do conjunto de dados 3 não normalizado.



Fonte: Autor, 2023.

das pelas Figuras 4.4 e 4.5, é perceptível que a luminosidade interna tem alta correlação positiva com o rótulo (*label*). Isso indica que a variação do conforto luminoso do usuário está correlacionada com a luminosidade interna.

A correlação de luminosidade externa e hora também possui valor elevado, mostrando uma correlação alta dessas duas variáveis, como podemos ver nas Figuras 4.4, 4.5 e 4.6. O valor elevado da correlação entre a hora e a luminosidade externa é esperado, pois a luminosidade do dia varia conforme as horas. Para este caso, uma correlação alta entre essas características é aceitável e até bem desejável, ao servir como redundância de informação para tornar o sistema de atuação e predição mais robusto. Isso se deve ao fato de que há sensores e atuadores no ambiente e no caso de falha e equívoco de algum deles a redundância pode ajudar a minimizar o erro na resposta do modelo. Dessa forma, os atuadores têm menos possibilidade de receber informações erradas do preditor.

Como podemos ver nas Figuras 4.4, 4.5 e 4.6, há uma baixa correlação entre às características de umidade e rótulo e também entre temperatura e rótulo. Com isso podemos concluir que os valores dos rótulos não se relacionam com a variação da umidade e da temperatura. Porém, estas duas características podem trazer informações para o modelo que expressam o padrão subjetivo das escolhas do usuário do ambiente.

O conjunto de dados 3 foi obtido de outro experimento, dessa forma, as condições dos dados e a correlação das características ficaram bem diferentes dos dois primeiros conjuntos de dados. Como podemos ver na Figura 4.6, a pesar da luminosidade interna e a hora possuírem as maiores relações com o conforto do usuário, estas são correlações fracas. Mas neste ambiente, podemos perceber que o conforto do usuário está mais relacionado com as características de hora e luminosidade interna do que com as demais.

4.3.2 Análise de similaridade entre os conjuntos de dados

O teste de *kolmogorov-Smirnov* [23] (KS) pode ser utilizado para avaliar a diferença da distribuição dos conjuntos de dados fonte e conjuntos de dados alvo a partir do teste *two-sample ks* em um problema de transferência de conhecimento [11]. O teste *two-sample ks* é um teste não paramétrico que compara a distribuição cumulativa de dois conjuntos de dados. Este teste pode ser aplicado para testar a hipótese nula que diz que dois conjuntos de dados tem a mesma distribuição. Isso significa que valores pequenos do *p-valor*, o qual é um valor que varia de 0 a 1 retornado pelo teste *two-sample*, evidenciam que devemos rejeitar a hipótese nula. Dessa forma temos que *p-valor* próximo de zero indica que a distribuição dos dados do ambiente fonte difere da distribuição dos dados do usuário alvo [11].

Tabela 4.8: Tabela *P-values* do teste de *Kolmogorov-Smirnov*.

Fonte-Alvo	label	lum. interna	lum. externa	umidade	temperatura	hora
1-2	8,830959e-37	1,401233e-05	2,597833e-09	5,779153e-44	4,944368e-05	0,115433
1-3	0,000853	1,545344e-213	8,885883e-218	1,203639e-60	1,302605e-45	0,326816
2-1	8,830959e-37	1,401233e-05	2,597833e-09	5,779153e-44	4,944368e-05	0,115433
2-3	2,406675e-18	4,931070e-145	4,720041e-89	8,632481e-119	1,828918e-49	0,272973
3-1	0,000853	1,545344e-213	8,885883e-218	1,203639e-60	1,302605e-45	0,326816
3-2	2,406675e-18	4,931070e-145	4,720041e-89	8,632481e-119	1,828918e-49	0,272973

Fonte: Autor, 2023.

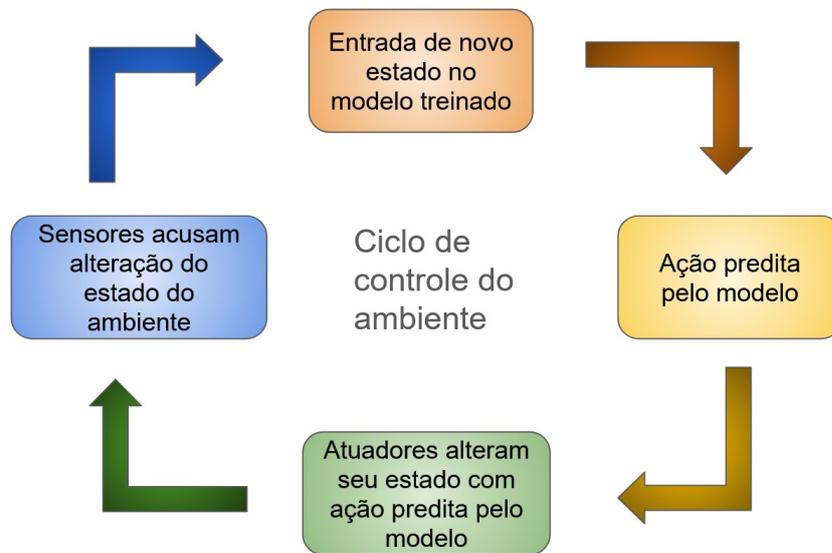
A Tabela 4.8 mostra o resultado dos *p-valores* calculados pelo teste de *Kolmogorov-Smirnov* [23] aplicado nas combinações dos três conjuntos de dados como usuários fontes e alvo. O teste foi aplicado para cada característica de dados (propriedades do ambiente) comparando a distribuição das características do usuário fonte com as distribuições do conjunto de dados alvo. A análise da percepção de conforto dos usuários nos ambientes inteligentes tem alta diferença de distribuição das preferências de conforto do ambiente. Essa conclusão pode ser percebida pelo *p-valor* próximo de zero na maioria das características do ambiente entre dois usuários fonte e alvo. Isso pode ser compreendido como resultado das características diversas de preferências dos usuários e da subjetividade da percepção de conforto.

Podemos perceber na Tabela 4.8 que com exceção da característica hora, as demais características tiveram seu *p-valor* menor do que 1%. Isso indica que as distribuições das características do ambiente e dos rótulos dos dados não são iguais, logo não proveem de um mesmo conjunto de dados.

4.4 Ciclo de controle

Após a obtenção do melhor modelo de predição do ambiente inteligente personalizado, o modelo é colocado para atuar no ambiente na etapa de implantação da metodologia *CRISP-DM*. A execução do modelo no ambiente ocorre em um ciclo infinito que se inicia ao ocorrer uma alteração do estado do ambiente. Esta é uma alteração nas propriedades do ambiente que são luminosidade interna, luminosidade externa, umidade ou temperatura. Ao ocorrer uma alteração no estado do ambiente, os sensores computam os novos valores das propriedades do ambiente, gerando assim, um novo estado do ambiente. Este estado é repassado para o modelo treinado, que retorna a predição da ação a ser realizada pelos atuadores, que no nosso caso são lâmpadas inteligentes *Philips Bulb Hue*. Após obter a ação predita, os atuadores recebem e executam a ação predita pelo modelo. Esta ação pode alterar o estado do ambiente que desencadeará o início do ciclo de controle como mostra a Figura 4.7.

Figura 4.7: Ciclo de controle do ambiente.



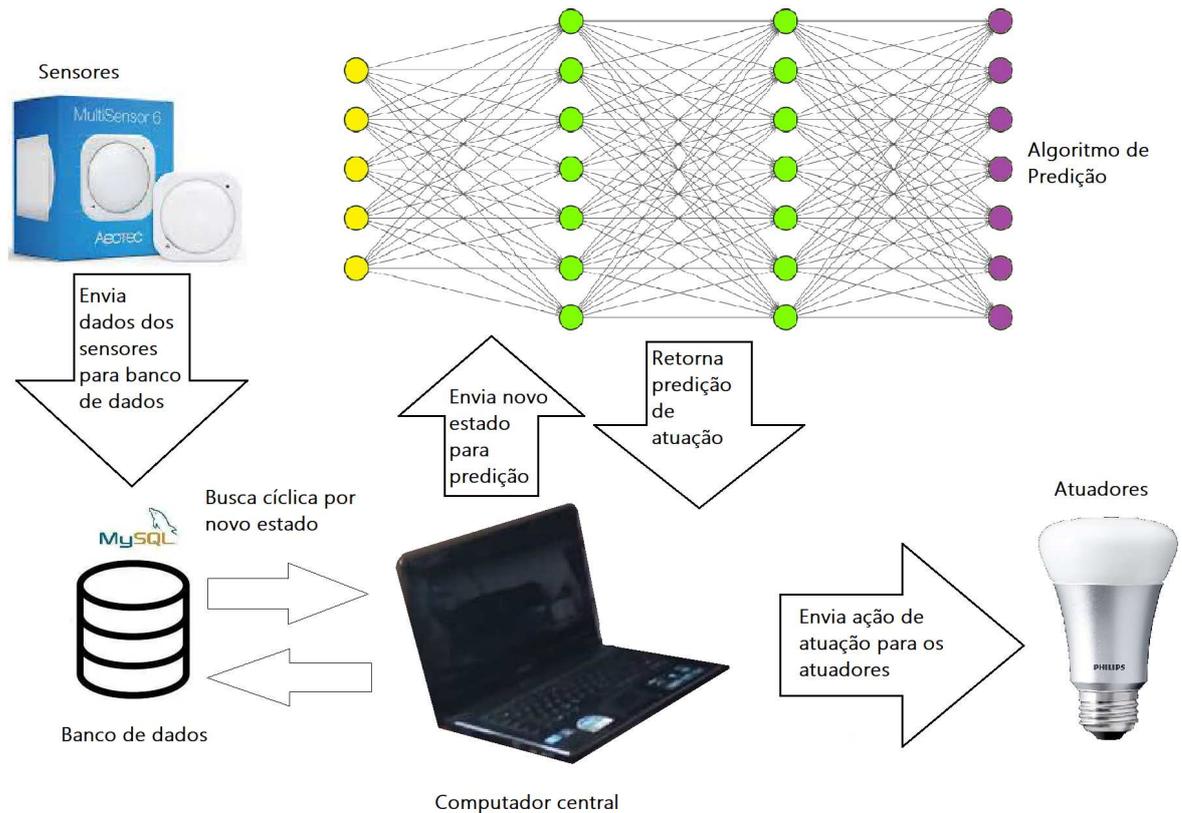
Fonte: Autor, 2023.

O código de predição de conforto executa em ciclo infinito em um computador central que tem conexão, via rede local e internet, com os sensores e atuadores do ambiente. O sistema de leitura de dados dos sensores, executando em ciclo infinito, armazena as informações dos sensores em um banco de dados a cada alteração em uma das propriedades do ambiente atual. Um software executando em ciclo infinito busca por alterações na última inserção no banco de dados dos sensores a cada um minuto. Este tempo foi obtido empiricamente neste projeto, sendo suficiente para execução de atuação no ambiente e percepção de alteração do estado do ambiente por parte do usuário. Ao detectar alteração na última inserção do banco de dados, o software de busca de alterações envia os dados para o algoritmo de predição. Os novos dados são executados no preditor, que retorna uma predição de atuação para o novo estado do ambiente. A predição de atuação é então executada pelos atuadores, que recebem o comando de atuação do computador central, como exemplificado na Figura 4.8.

4.5 Conclusões

Este capítulo apresentou os conjuntos de dados empregados no trabalho, bem como foi feita uma análise estatística dos mesmos. Foram feitas análises do percentual de rótulos por classe, uma caracterização dos atributos numéricos, bem como uma análise de correlação dos rótulos com cada atributo. Todos os conjuntos de dados tiveram sua maior porcentagem de valores no rótulo central e suas menores quantidades nos rótulos

Figura 4.8: Arquitetura de sistema do ciclo de predição e atuação.



Fonte: Autor, 2023.

de valores nas bordas dos intervalos. O conjunto de dados 2 foi o menos desbalanceado e o 3 o mais desbalanceado. A análise das métricas dos atributos mostrou a necessidade de intervenção de normalização dos dados devido à sua alta variância. Assim, foram aplicados dois métodos de normalização de dados conforme a necessidade de cada atributo.

A caracterização dos conjuntos de dados ainda mostrou que os mesmos possuem distribuições bem distintas, mesmo se tratando do mesmo problema (predição de conforto). Isso corrobora que a noção de conforto é diferente entre indivíduos.

Capítulo 5

Modelagem dos dados e Avaliação do Modelo

5.1 Modelagem dos dados

Na modelagem dos dados foi realizada a seleção da técnica de modelagem dos dados, a geração do projeto de teste, a construção do modelo e a avaliação do modelo. Na etapa de seleção da técnica de modelagem, o objetivo foi o de descrever o porquê e qual técnica de modelagem foi utilizada. Na fase de geração do projeto de testes o objetivo foi o de descrever os procedimentos e mecanismos de teste para mostrar a qualidade do modelo. Na construção de modelo descrevemos a aplicação das ferramentas de modelagem utilizadas. Na avaliação do modelo resumimos os resultados da tarefa executada pelo modelo.

5.1.1 Seleção da técnica de modelagem

A técnica de modelagem de dados selecionada foi a de Redes Neurais Artificiais (ANN), do inglês *Artificial Neural Network*. Junto à técnica de ANN foram aplicados os conceitos de transferência de conhecimento e de ajuste fino em Redes Neurais Artificiais. A escolha da técnica de ANN para este projeto se deu pela crescente aplicação de ANN, seus resultados promissores e pela ampla quantidade de bibliotecas, fontes de estudos e implementações sobre as ANNs. As redes neurais artificiais utilizadas são redes neurais densas, como a que pode ser vista na Figura 5.1, em que cada neurônio da camada anterior é conectado a cada neurônio da próxima camada.

5.1.2 Transferência de conhecimento com ajuste fino

A escolha da transferência de conhecimento com ajuste fino dentre várias formas de transferência de conhecimento foi devido às características dos problemas a serem solucionados por esse projeto.

A aplicação da transferência de conhecimento com ajuste fino se justifica pela pouca quantidade de dados, pelo algoritmo de modelagem e pela necessidade de personalização do modelo. A pouca quantidade de dados fez necessária a transferência de conhecimento, pois para alcançar um bom modelo de aprendizado de máquina é necessária uma grande quantidade de dados [81]. O problema do projeto está ligado à personalização do modelo, dessa forma, a aplicação do ajuste fino é uma forma eficiente de realizar a personalização [81].

A transferência de conhecimento aplicada neste projeto é de natureza homogênea, supervisionada, baseada em modelo e *offline* [81]. Por se tratar dos mesmo tipos de dados, a transferência de conhecimento aplicada neste projeto tem natureza homogênea [60]. Por treinarmos o modelo com dados rotulados, a transferência de conhecimento utilizada tem natureza supervisionada. Ao importarmos os parâmetros de outro modelo para compor um novo modelo temos que a transferência de conhecimento desse projeto é baseado em modelo. Esse projeto não faz atualizações constantes de dados para realizar a transferência de conhecimento, logo esta é de natureza *offline* [81].

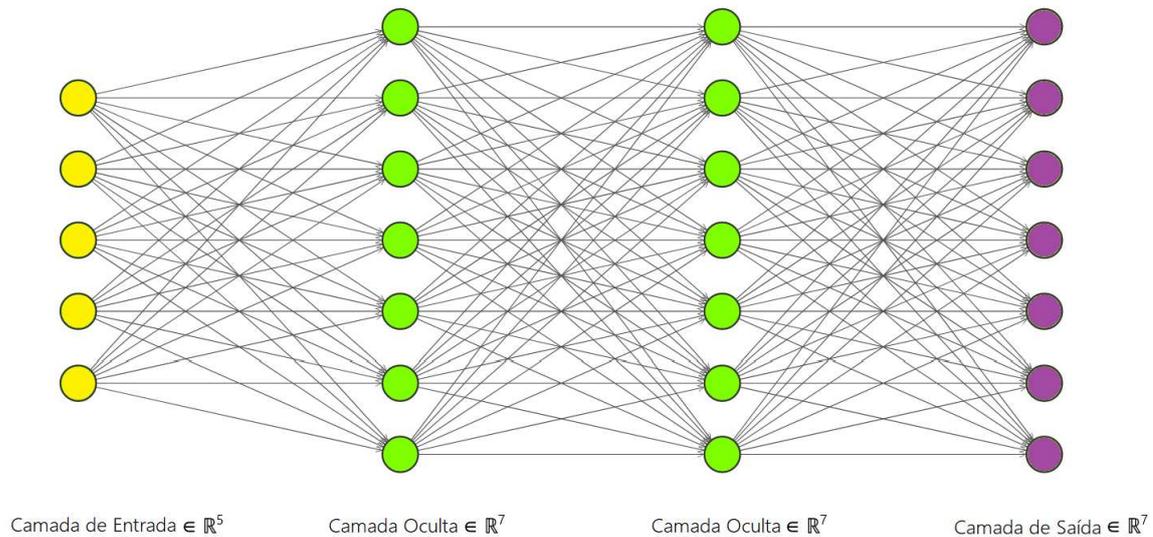
5.1.3 Número de neurônios de entrada e saída

As **camadas de entrada e saída** possuem número de neurônios conforme a necessidade do projeto. O **número de neurônios na camada de entrada** foi definido como o número de **características do ambiente** inteligente. Como o número de características auferidas dos ambientes eram 5, então a **camada de entrada** possuía **5 neurônios** como mostrado na Figura 5.1. As 5 entradas recebem os valores de luminosidade interna, luminosidade externa, temperatura do ambiente, umidade do ambiente e a hora. Estas características compõem o estado do ambiente para o preditor treinado retornar, na camada de saída, uma ação a ser tomada conforme o estado do ambiente.

A **camada de saída** possui saída com 7 neurônios. O **número de neurônios** representa a quantidade de classes de ações a serem realizadas pelo ambiente.

As **múltiplas saídas** de uma rede neural de classificação definem o número de classes que essa rede tenta prever. No caso deste projeto, **7 classes** foram definidas para

Figura 5.1: Rede Neural Artificial densa com 5 neurônios de entrada e 7 neurônios de saída.



Fonte: Autor, 2023.

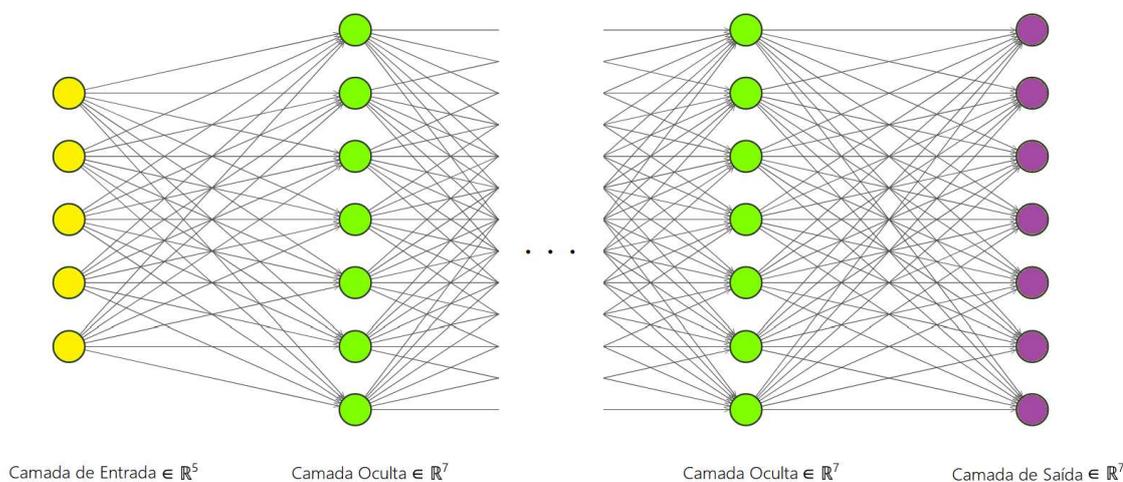
Tabela 5.1: Mapeamento da avaliação de valores categóricos de diferentes condições de luminosidade do ambiente e valores incrementados na intensidade luminosa das lâmpadas.

Valor da avaliação	Avaliação	Valor incrementado (luxes)
0	Escuro Demais	+3
1	Muito Escuro	+2
2	Pouco Escuro	+1
3	Confortável	0
4	Pouco Claro	-1
5	Muito Claro	-2
6	Claro Demais	-3

Fonte: Autor, 2023.

representar o grau de conforto do usuário do ambiente. Dessa forma a rede neural possui **7 neurônios de saída** como pode ser visto na Figura 5.1. As 7 saídas representam os 7 valores de ações do ambiente que representam as classes de nível de conforto do usuário. Estes valores são interpretados pelo ambiente como a quantidade a ser incrementada ou decrementada no atuador de luminosidade do ambiente, como mostrado na Tabela 4.1. Dessa forma, os atuadores podem corrigir o conforto do ambiente e deixar o usuário mais confortável. Nessa rede neural de classificação é utilizada a função de ativação *Softmax* na última camada. Essa função define qual ação possui a maior probabilidade de ser a classe de conforto do usuário entre as 7 classes.

Figura 5.2: Rede Neural Artificial densa com 5 neurônios de entrada e 7 neurônios de saída e mais de uma camada oculta.



Fonte: Autor, 2023.

5.1.4 Hiperparâmetros definidos para pesquisa em grade

Os **hiperparâmetros** da ANN foram escolhidos utilizando a técnica de pesquisa exaustiva, também conhecida como pesquisa em grade (*grid search*) que foi descrita na Seção 2.3.5. Os **hiperparâmetros** que foram utilizados podem ser visto na Tabela 5.2 com o intervalo de valores utilizados na busca em grade.

Tabela 5.2: Tabela de valores de hiperparâmetros utilizados na busca em grade.

Hiperparâmetro	Valores utilizados
Número de neurônios na camada de entrada	5
Número de neurônios na camada de saída	7
Número de camadas ocultas	3,4,5,6
Número de neurônios por camada oculta	5,7,32,64,128
Taxa de aprendizado	0,0001, 0,001, 0,01, 0,1, 0,2, 0,3, 0,4
Tamanho da validação cruzada	3, 5, 10
Número de épocas	1000
Função de ativação	Sigmoid, Tanh
Função de otimização	Adam, SGD

Fonte: Autor, 2023.

Com exceção do número de neurônios da camada de entrada e número de neurônios da camada de saída, os outros hiperparâmetros foram escolhidos utilizando a pesquisa em

grade. A pesquisa em grade foi aplicada em um intervalo de valores para cada hiperparâmetro, estes valores foram selecionados observando resultados das melhores práticas de treinamento de redes neurais. Estas práticas informam melhores valores que se pautam por conceitos que utilizam algumas métricas como a quantidade de dados utilizados, proporções otimizadas de treino e testes, tipos de problema a ser resolvido e análise empírica sobre os dados. A seleção dos melhores valores foi importante, pois a pesquisa em grade é uma técnica exaustiva e demanda custo computacional alto como mencionado na Seção 2.3.5. Dessa forma foi necessário reduzir as dimensões dos conjuntos de valores dos hiperparâmetros.

5.2 Geração de projeto de teste

A geração do projeto de teste descreve os procedimentos ou mecanismos de testes para mostrar a qualidade do modelo. Nesta etapa são relatadas as intenções do planejamento para treinar e testar o modelo.

Para realizar o treino e a validação dos modelos foi utilizado o método de validação cruzada para selecionar as amostras de dados de treino e teste. Como a distribuição dos dados obtidos durante a coleta não tem proporção equânime entre os rótulos, também foi aplicada a técnica de estratificação para realizar a amostragem de treino e teste.

Os testes do modelo foram criados para comparar se os poucos dados de um novo ambiente alvo poderia se beneficiar do conhecimento obtido de um ambiente fonte já treinado. Para realizar essa análise foram utilizados 3 usuários, os dados de cada usuário foi combinado com os outros dois. Dessa forma, cada usuário foi fonte de dados para os demais, gerando assim um conjunto de 6 combinações. A cada combinação foi aplicada a *busca em grade* no intervalo de valores de hiperparâmetros. Assim, para cada combinação de hiperparâmetros e usuários fonte e alvo foi gerado um conjunto de resultados de execução com valores de métricas.

Cada uma das métricas tem o objetivo de analisar e comparar o desempenho das modelagens. O objetivo da comparação do desempenho de modelagens é encontrar o melhor desempenho dos modelos do usuário alvo com e sem a aplicação da transferência de conhecimento com ajuste fino. Esta comparação verifica se o ajuste fino consegue melhorar os dados do melhor preditor do usuário alvo sem a transferência de conhecimento no contexto de ambientes inteligentes.

As métricas utilizadas para avaliar os modelos foram *Acurácia*, *Erro de Entropia cruzada* e *matriz de confusão*.

5.2.1 Acurácia

A função de acurácia computa o número de predições corretas realizadas pelo modelo. Dessa forma, a acurácia informa qual a porcentagem dos dados o modelo está acertando.

Podemos definir a acurácia da seguinte forma, se \hat{y}_i é o valor predito da i -ésima amostra e y_i é o valor do rótulo correspondente ao \hat{y}_i , então a fração de predições corretas sobre as n amostras é definida pela Equação 5.1 a seguir [72]:

$$acuracia(y_i, \hat{y}_i) = \frac{1}{n} \sum_{i=0}^{n-1} 1(y_i = \hat{y}_i) \quad (5.1)$$

Em que $1(x) = [x \in A]$ tal que A é o conjunto dos valores em que $y_i = \hat{y}_i$.

$$1(x) = \begin{cases} 1 & \text{se } x \in A \\ 0 & \text{se } x \notin A \end{cases} \quad (5.2)$$

5.2.2 Matriz de Confusão

Uma matriz de confusão é uma tabela que mostra o desempenho de um algoritmo de classificação. A matriz de confusão mostra como está a dispersão de predição e rótulo dos dados. Com a matriz de confusão é possível analisar qual foi a predição do modelo no conjunto de dados para cada rótulo. Dessa forma é possível analisar acurácia e a precisão do modelo.

5.3 Construção do modelo

Na fase da construção do modelo foi realizada a configuração de parâmetros do modelo bem como a descrição do modelo.

Nesta fase executamos as ferramentas de modelagem no conjunto de dados preparados para criar os modelos. Nesta etapa foram descritas as aplicações das ferramentas utilizadas na escolha dos valores dos parâmetros dos modelos e as ferramentas para redu-

zir efeitos negativos de dados desbalanceados e em pouca quantidade. A construção do modelo também descreve os modelos resultantes, relatando a interpretação dos modelos.

5.3.1 Linguagem de programação e bibliotecas

A construção do modelo foi realizada na linguagem de programação *Python* que possui um grande conjunto de bibliotecas e suporte para o desenvolvimento de modelos de aprendizado de máquina. Os modelos de aprendizado de máquina desenvolvidos se basearam no conceito de redes neurais artificiais de classificação.

Para o desenvolvimento das redes neurais artificiais foram utilizadas bibliotecas do *Pytorch* [20] com auxílio das bibliotecas do Scikit-Learn [57]. O *Pytorch* foi escolhido para ser a biblioteca de desenvolvimento, pois inicialmente houve problemas com o uso da biblioteca do *Keras* [16] com o processador Core I5-460M 2.53GHz da primeira geração. Este era o processador do computador utilizado para o desenvolvimento das redes neurais artificiais. Diante disso, foi realizada a migração para as bibliotecas do *Pytorch* o qual não houve nenhuma restrição.

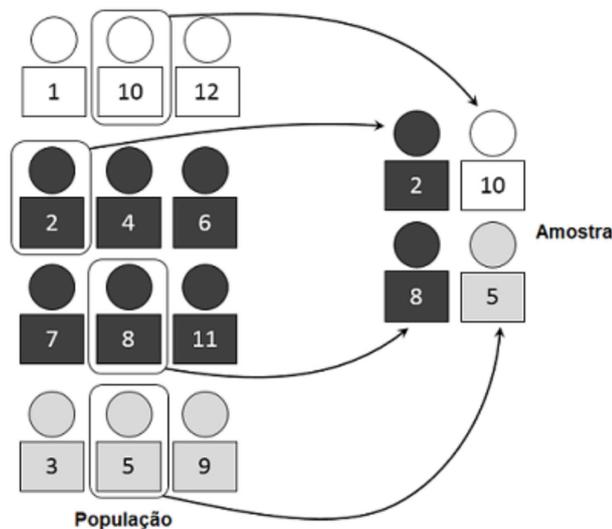
5.3.2 Construção da amostragem estratificada

Na fase de modelagem dos dados foi identificado que algumas propriedades dos dados como desbalanceamento de rótulos e amostragem desequilibrada podem prejudicar o modelo dos dados. Para amenizar o problema do desbalanceamento e da amostragem desequilibrada de dados, foi aplicada a técnica de **amostragem estratificada**.

A amostragem estratificada é uma técnica que realiza a amostragem proporcional dos rótulos como exemplificado na Figura 5.3. Essa técnica evita que a seleção de dados seja enviesada pela alta amostragem de alguns rótulos e baixa amostragem de outros rótulos [50].

A aplicação da amostragem estratificada com a validação cruzada forma a validação cruzada estratificada. Para construção da validação cruzada e da estratificação foi utilizada um método do *Scikit-learn* [57] conhecido e nomeado como *Stratifiedkfold* [58]. Esse método provê índices de treino e teste para dividir os conjuntos de dados de treino e de teste para serem aplicados no modelo.

Figura 5.3: Exemplificação da estratificação.



Fonte: [18], 2020.

5.3.3 *Early Stop e Dropout*

Para evitar que os modelos sofressem sobreajuste, foram aplicadas as técnicas de regularização, *Early Stop e Dropout*. A técnica do *Early Stop* consiste em analisar o desempenho de uma das métricas de avaliação como acurácia ou erro. Para isso a técnica verifica se a métrica sofre melhorias em seu valor por um número escolhido de iterações. A técnica aborta o treinamento da modelagem se após o número de tolerância de iterações for atingido e não ocorrer nenhuma melhoria na métrica de avaliação [33]. Neste projeto diversas combinações de *Early Stop* foram testadas, mas a que teve melhor resultado foi a de tolerância de 10 iterações com precisão de 0,0001. Isso permitiu manter o modelo de predição com maior poder de generalização.

O *Dropout* Não foi utilizado para obter os resultados. Porém, este foi aplicado para tentar remover o sobreajuste do modelo. O *Dropout* é uma técnica aplicada em aprendizado de máquinas, não exclusiva, mas muito aplicada em redes neurais artificiais. O *Dropout* consistem em remover nós das camadas da rede neural com uma determinada probabilidade. Na execução do modelo os nós são removidos e o modelo treinado sem sofrer a influência do nó removido [77]. O *Dropout* previne sobre ajuste evitando que as unidades compensem os erros cometidos por outras unidades durante o processo de treinamento [33]. A técnica de *Dropout* permitiu o cessar do sobre ajuste, mas foi melhor desativar o *Dropout* pois estava gerando valores de acurácia e erro de teste melhor do que os de treino. Os valores de *Dropout* utilizados foram de 20% e 40%. Com ambas as porcentagens, os valores de acurácia de teste estavam muito superiores que os valores de acurácia de treino do modelo em sua maioria. Ao pesquisar por motivações, foram

encontrados muitos relatos de que o *Dropout* causava esse tipo de problema. Ao desabilitar o *Dropout* aplicando probabilidade 0,0% como parâmetro, os resultados de acurácia de testes voltaram a ficar menores ou iguais às acurácias de treino em sua maioria.

5.4 Avaliação dos resultados da modelagem

Os resultados obtidos com a aplicação da transferência de conhecimento com ajuste fino para redução do tempo de treinamento em ambientes inteligentes obteve êxito. Isso quer dizer que a acurácia da melhor hipótese de modelo da aplicação da transferência de conhecimento com ajuste fino foi melhor do que a acurácia da melhor hipótese de modelo do usuário alvo sem a transferência de conhecimento com ajuste fino. Isso implica que teoria a ser aplicada para redução de tempo e quantidade de dados para treino de conforto personalizado de ambientes inteligentes funciona para a tarefa a que foi destinada neste projeto.

Todas as combinações de usuários como alvo e fonte obtiveram êxito para a modelagem de classificação com transferência de conhecimento com ajuste fino. Mesmo em conjuntos de dados com imperfeições, a modelagem de melhoria funcionou para reduzir o tempo de aprendizado com poucos dados para predição de conforto personalizado em ambiente inteligentes.

5.4.1 Análise de resultados dos hiperparâmetros

O objetivo de variar e combinar os hiperparâmetros é obter as melhores combinações destes que retorne modelos com melhores acurácias sobre os dados apresentados. O resultado das execuções da busca em grade é mostrado na Tabela 5.3 que exhibe quais hiperparâmetros tiveram melhores desempenhos para cada combinação de usuário como alvo e fonte. O otimizador *Adam* foi o que mais apareceu com melhor desempenho, como mostra a Tabela 5.3. O otimizador *Adam* teve melhor desempenho para os usuários 1 e 2 como alvo. O conjunto de dados 3 como alvo teve melhor desempenho com o otimizador *SGD*, do inglês *Stochastic Gradient Descent*. A função de ativação *Tanh* (Tangente Hiperbólica) foi a que mais apareceu em quase todas as combinações de usuários. Esta função de ativação é uma variação da função de ativação *Sigmoid*.

A taxa de aprendizado que mais se sobressaiu foi a de 0,2. Esta foi a terceira taxa

mais rápida utilizada. Aparentemente o usuário 1 como alvo precisa de taxas menores para alcançar valores otimizados. Os conjuntos de dados 2 e 3 como alvo tem taxa de aprendizado maior, realizando maiores saltos da função de minimização de erro. O principal fator comum entre os conjunto de dados 2 e 3 é a baixa quantidade de dados.

A quantidade de 5 camadas da rede neural foi a quantidade de camadas que teve melhores desempenhos. Aparentemente, ter mais camadas é melhor, porém devemos manter o limite de 5 camadas para esses conjuntos de dados. Essa informação foi analisada empiricamente ao se executar mais de 5 camadas na rede neural para o conjunto de dados e ocorreu que a rede neural não alterava os pesos. Ao pesquisar por motivos dos pesos não estarem alterando, uma possível resposta encontrada, que justificava o problema, foi o desaparecimento de gradiente [22]. Isso ocorre quando os valores retornados para ajustar os pesos na retro-propagação são zeros ou muito próximos de zero. O que foi constatado com análise de saída dos erros de treinamento iguais as zero. As redes com quantidade de camadas menores do que 3 não permitiam substituir mais do que a camada final. Por isso, a menor quantidade de camadas foram 3 camadas.

A quantidade de 64 neurônios por camada obteve a maioria dos melhores resultados. Aparentemente mais neurônios por camada poderia surtir efeitos melhores, pois ao se adicionar mais camadas, observou-se que os modelos selecionavam esse valor de hiperparâmetro como o de melhor desempenho. A melhoria no desempenho não alcançava as duas primeiras casas decimais ao se adicionar mais do que 32 neurônios. Dessa forma, adicionar mais neurônios por camada tinha um limite de melhoria que não era ultrapassado com o adicionar de mais neurônios. Assim optou-se por não aumentar para mais do que 64 neurônios por camada, mantendo apenas os testes com no máximo 64 neurônios como resultado oficial. Isso se deve ao custo alto de tempo de execução em variar a quantidade de hiperparâmetros sem a previsão de um ganho real e contundente.

O número de partições de validação teve seu melhor desempenho na quantidade de 5 partições que aparece em 3 das 6 execuções. O valor de 5 partições permitem utilizar 20% dos dados como teste e 80% dos dados como treino, sendo uma ótima proporção de treino e teste segundo [29]. Essa parece ser uma divisão otimizada para uma quantidade maior de dados como os do conjunto de dados 1 que possui uma grande quantidade de dados em comparação com os demais conjuntos de dados. O conjunto de dados 2 teve melhor desempenho com os valores de partições mais altos como 5 e 10. A quantidade de 10 partições permite maior quantidade de dados para treino em que 90% dos dados foram usados para treino e 10% para teste. Utilizar 90% dos dados para treino permite uma boa melhora na acurácia de treino, pois mais dados serão vistos pelo treino do modelo. O valor 3 da validação cruzada utilizado no conjunto de dados 3 como alvo faz com que 33,33% dos dados sejam utilizados como teste e apenas 66,66% usados como treino.

É importante enfatizar que estes não foram os únicos hiperparâmetros nos quais a acurácia de teste da transferência de conhecimento com ajuste fino ficou maior que a maior

acurácia de teste do usuário alvo. Estes foram os primeiros hiperparâmetros dos maiores valores de acurácia de teste de transferência de conhecimento que não foram superados.

Tabela 5.3: Hiperparâmetros do modelo de classificação das melhores acurácias dos usuários alvo.

Alvo	Fonte	Taxa de aprendizado	Partições da validação	Otimizador	Camadas ocultas	Nós por camada	Função de ativação	N.º Camadas substituídas
1	2	0,01	5	Adam	5	64	Tanh	3
1	3	0,01	5	Adam	5	64	Tanh	3
2	1	0,1	10	Adam	3	32	Tanh	1
2	3	0,2	5	Adam	4	64	Tanh	2
3	1	0,2	3	SGD	5	5	Tanh	1
3	2	0,2	3	SGD	4	7	Sigmoid	3

Fonte: Autor, 2023.

5.4.2 Análise de resultados das Acurácias

Na Figura 5.4 são comparados todos os usuários atuando como fonte de dados para a transferência de conhecimento e também atuando como usuário alvo para receber a transferência de conhecimento com ajuste fino. Os dados são apresentados por pares A-B, onde o valor à esquerda do traço indica o conjunto de dados fonte da transferência de conhecimento, e o valor à direita é o conjunto de dados de destino.

O gráfico da Figura 5.4 mostra os melhores resultados das acurácias de testes do usuário alvo com e sem a transferência de conhecimento. As barras rotuladas como *Alvo*, barras azuis, representam os valores das acurácias de testes dos usuários alvo sem aplicação da transferência de conhecimento com ajuste fino. As barras rotuladas como *Transferência*, barras vermelhas, representam os valores das acurácias de testes dos usuários alvo com aplicação da transferência de conhecimento com ajuste fino.

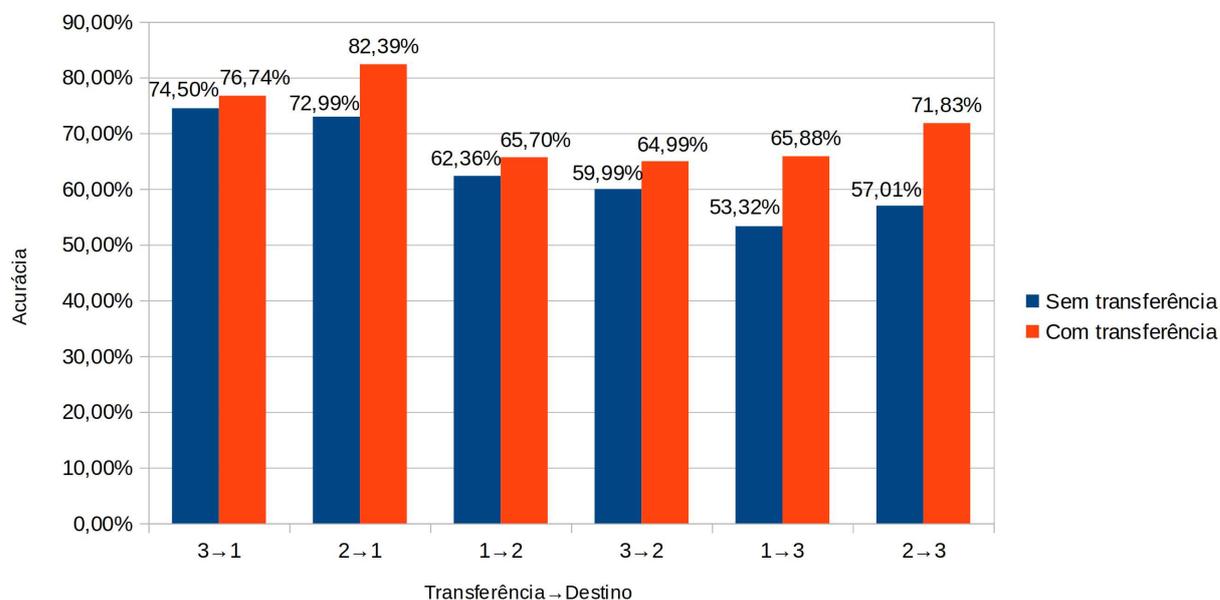
As barras vermelhas mais altas do que as barras azuis no gráfico da Figura 5.4 indicam que as combinações de transferência de conhecimento com ajuste fino superou a melhor predição obtida com os dados sem a transferência de conhecimento.

Várias combinações de transferência de conhecimento com ajuste fino melhoraram a acurácia do usuário alvo. As melhores acurácias do usuário alvo foram melhoradas com a aplicação da transferência de conhecimento para os modelos de *classificação*.

Podemos concluir que para a modelagem de *classificação* e os hiperparâmetros utilizados, a transferência de conhecimento supera a predição dos dados originais, mesmo estes sendo em pequena quantidade. O que corrobora a tese inicial da eficácia da aplicação da transferência de conhecimento para melhorar o tempo de treinamento de um ambiente inteligente com poucos dados.

Ao analisarmos o gráfico da Figura 5.4 percebemos que as maiores acurácias de teste da transferência de conhecimento foram alcançadas pelo conjunto de dados 1 como usuário alvo. O fato do conjunto de dados 1 ser um conjunto maior de dados, permitiu uma acurácia maior tanto no teste do alvo quanto no teste da transferência de conhecimento. Isso implica que mesmo um conjunto de dados menor pode transferir conhecimento para um conjunto de dados maior. Isso quer dizer que a transferência de conhecimento faz com que a hipótese inicial do modelo a ser treinado comece de um ponto de partida melhor do que se tivesse começado do zero.

Figura 5.4: Comparação das melhores acurácias obtidas no modelo de classificação.



Fonte: Autor, 2023.

Os maiores ganhos alcançados foi pelo conjunto de dados 3 que obteve melhorias de 12,56% e 14,82% com a transferência de conhecimento do conjunto de dados 2 e 1 respectivamente. Os menores ganhos de acurácia alcançados foram dos conjuntos de dados 3 para o 1, 1 para o 2 e 3 para o 2. Estas transferências obtiveram melhorias de 2,24%, 3,34% e 5% respectivamente. A relação perceptível destes três conjuntos como foram descritos é que o conjunto de dados 2 tem menor desbalanceamento dos dados e maior variância na característica de luminosidade externa. Podemos inferir que a transferência de conhecimento de um conjunto de dados menos balanceado para um mais balanceado tende a ter menor poder de melhoria. Devido à alta variância na característica de luminosidade externa, também é possível inferir que os demais conjuntos de dados podem não ter conseguido melhorar os rótulos do modelo referente a esta característica para o conjunto de dados 2.

O conjunto de dados 2 aplicou duas das 3 maiores melhorias na acurácia. O conjunto de dados dois melhorou a acurácia dos conjuntos de dados 1 e 3 em 9,4% e 14,82% respectivamente. Podemos perceber que as características dos dados tem mais

influência na modelagem do que a quantidade de dados. Isso por que o conjunto de dados 1 é o maior e o conjunto de dados 2 é o mais balanceado. O conjunto de dados 2 também possui uma variância maior no atributo de luminosidade externa, o que também pode ser um fator de influência na modelagem por abranger mais valores na rotulação.

O conjunto de dados 1 foi o que teve as maiores acurácias, sendo melhor do que os outros modelos mesmo estes recebendo a transferência de conhecimento. A acurácia do conjunto de dados 1 sem a transferência de conhecimento foi melhor do que a dos demais conjuntos de dados, mesmo estes recebendo a transferência de conhecimento. Esse fato pode ser atribuído a alta quantidade de dados do conjunto de dados 1 em relação aos demais conjuntos de dados. Isso se justifica por que quanto mais dados mais informações sobre o padrão dos dados é entregue ao modelo. Quanto maior a informação sobre os dados, melhor é a acurácia de predição do modelo sobre os dados.

O conjunto de dados 3 conseguiu o pior resultado de treinamento sem a transferência de conhecimento. Podemos inferir que seu pior desempenho em relação à acurácia de teste pode ser atribuído ao seu alto nível de desbalanceamento dos rótulo e sua baixa quantidade de dados. O conjunto de dados 3 ao receber a transferência de conhecimento alcançou melhorias superiores às melhorias do conjunto de dados 2. Isso fez o modelo do conjunto de dados 3 superar o modelo do conjunto de dados 2 com e sem a transferência de conhecimento. Isso mostra que a transferência de conhecimento pode fazer um modelo superar a predição de um modelo fonte em condições adequadas. Porém, este assunto está fora do escopo deste projeto.

A Tabela 5.4 mostra como a transferência de conhecimento possibilita a redução do número de dados para treinamento do modelo. Como consequência disso, a transferência de conhecimento também influencia na redução do tempo necessário de coleta de dados para realizar a modelagem dos dados, como mostrado na Tabela 5.4.

Tabela 5.4: Comparação do tempo necessário para coleta de dados com e sem a transferência de conhecimento.

Alvo	Dias Alvo	Fonte	Dias Fonte	Sem transferência		Com transferência		Economia de tempo de coleta em %
				Dias	N.º instâncias	Dias	N.º instâncias	
1	31	2	11	42	1276	31	946	26,19%
1	31	3	25	56	1130	31	946	44,64%
2	11	1	31	42	1276	11	330	73,81%
2	11	3	25	36	514	11	330	69,44%
3	25	1	31	56	1130	25	184	55,36%
3	25	2	11	36	514	25	184	30,56%

Fonte: Autor, 2023.

Ao analisarmos a Tabela 5.4 podemos perceber que treinar o modelo sem a transferência de conhecimento consome os dias de coleta dos conjuntos de dados alvo e fonte somados. Ao treinar o modelo com a transferência de conhecimento o tempo de coleta

de dados é menor, pois temos que coletar apenas os dados do modelo alvo. Dessa forma, o treinamento de um ambiente inteligente personalizado consome menos tempo com a aplicação da transferência de conhecimento do que sem a aplicação da transferência de conhecimento.

5.4.3 Análise de resultados das matrizes de confusão

As matrizes de confusão mostram o desempenho das predições dos usuários alvo antes e depois da transferência de conhecimento. As matrizes exibem como cada entrada foi predita pelo modelo. A diagonal principal mostra a quantidade de predição correta para os respectivos rótulos. As demais entradas da matriz de confusão são as predições realizadas erradas.

No ambiente elaborado para este projeto, aproximar da predição correta pode ser um ganho na predição que não está sendo contabilizado. Isso por que uma predição errada é contabilizada como um erro de predição, mas esta pode deixar o usuário com maior ou menor nível de desconforto. Deixar o usuário com um menor nível de desconforto é menos pior do que deixá-lo com mais desconforto. A exemplo, uma predição que prevê que o usuário está com sensação de claro demais, mas na realidade o usuário está confortável irá diminuir a intensidade luminosa do ambiente em três níveis. Isso irá deixar o usuário muito mais desconfortável se o erro fosse apenas em um nível. Ainda a exemplo, uma predição de que o usuário está com a sensação de claro, mas na realidade este está confortável, irá gerar uma atuação no ambiente que deixará o usuário com pouco desconforto. Isso por que ao atuar equivocadamente no ambiente, o atuador irá reduzir a luminosidade em apenas um nível do que deveria ser.

Uma particularidade das características do ambiente estudado é que deixar o ambiente mais escuro do que deveria, tende a ser mais prejudicial do que deixar o ambiente mais claro do que deveria ser. Isso por que estamos falando de um ambiente de trabalho, o que implica que ficar no escuro pode atrapalhar ou até mesmo impedir o usuário do ambiente de realizar suas tarefas. Talvez essa particularidade não se aplique em um ambiente como um quarto, por exemplo, em que apagar demais a luz pode prejudicar tanto quanto acender demais a luz.

Além da acurácia, podemos utilizar a aproximação dos rótulos para o valor de acurácia para medir a qualidade da transferência. Como mostrado nos exemplos anteriores, errar para valores próximos da acurácia tem efeito menos negativo do que errar para longe dos valores da acurácia.

Para avaliarmos o modelo através da matriz de confusão podemos olhar para as

falsas predições como um grau de aproximação das predições. Devido à natureza deste projeto, uma aproximação da acurácia é um fator que pode ser usado para interpretar a qualidade do preditor. Essa aproximação da acurácia pode ser analisada através da matriz de confusão.

Todas as predições de transferências de conhecimento geraram alguma aproximação das predições para perto da acurácia, como pode ser visto nas Figuras 5.5, 5.6, A.1, A.2, A.3 e A.4. As Figuras A.1, A.2, A.3 e A.4 são exibidas no Apêndice A. Ao analisarmos as matrizes de confusão do alvo e da transferência de conhecimento é possível perceber que muitos valores que estavam distantes da diagonal principal se aproximaram desta. Além do aumento da acurácia, a aproximação de valores da diagonal principal também pode ser interpretado como uma melhora na predição da modelagem como já exemplificado.

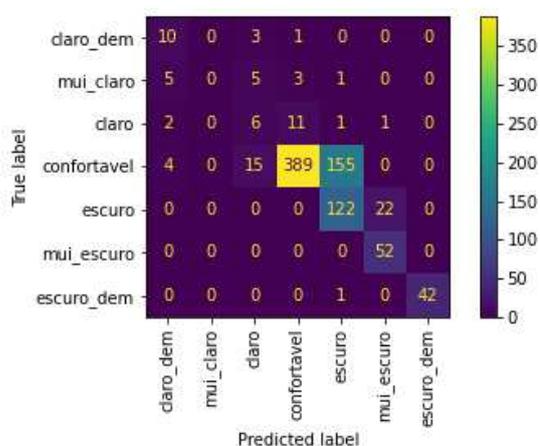
Apesar de possuir uma taxa muito grande de rótulos confortável, o conjunto de dados 3 melhorou os outros rótulos como fonte de dados de transferência de conhecimento. Podemos inferir que o conhecimento do conjunto de dados 3 levou mais informação a respeito da condição de confortável.

A exceção do usuário 1 como fonte e 2 como alvo, o restante das combinações todas melhoraram a acurácia da predição de confortável. Isso pode ser atribuído a alta taxa de rótulos confortável em todos os conjuntos de dados.

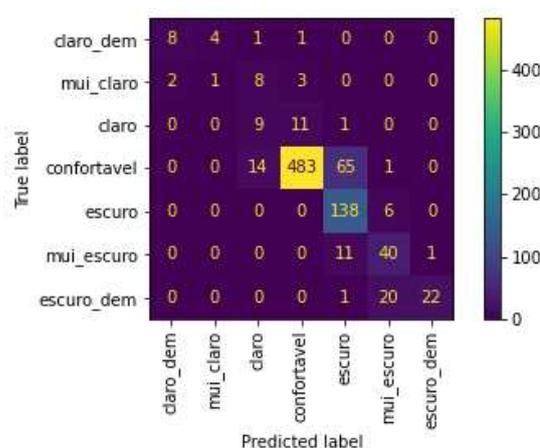
No conjunto de dados 3 a principal melhoria ocorrida foi sobre o rótulo de confortável. Isso pode ser justificado pelo desbalanceamento dos rótulos e a alta taxa de rótulos confortável do conjunto de dados 3.

Figura 5.5: Comparação das matrizes de confusão com e sem transferência de conhecimento do usuário 2 para o usuário 1 da modelagem de classificação.

(a) Matriz de confusão de acurácia de teste do usuário 1.



(b) Matriz de confusão de acurácia de teste da transferência de conhecimento.

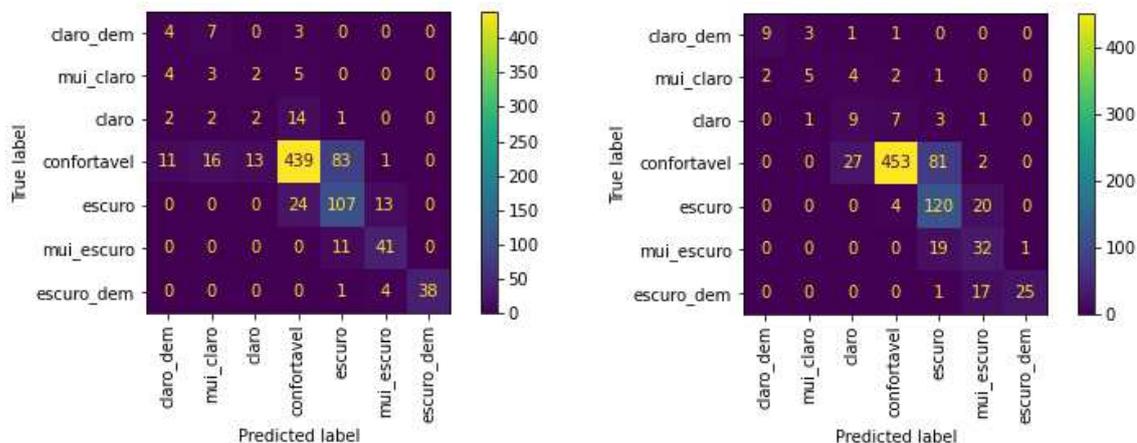


Fonte: Autor, 2023.

Os rótulos que melhoraram a acurácia com a transferência de conhecimento variaram em cada combinação de conjuntos de dados alvo-fonte. Todos os rótulos receberam

Figura 5.6: Comparação das matrizes de confusão com e sem transferência de conhecimento do usuário 3 para o usuário 1 da modelagem de classificação.

(a) Matriz de confusão de acurácia de teste do usuário 1. (b) Matriz de confusão de acurácia de teste da transferência de conhecimento.



Fonte: Autor, 2023.

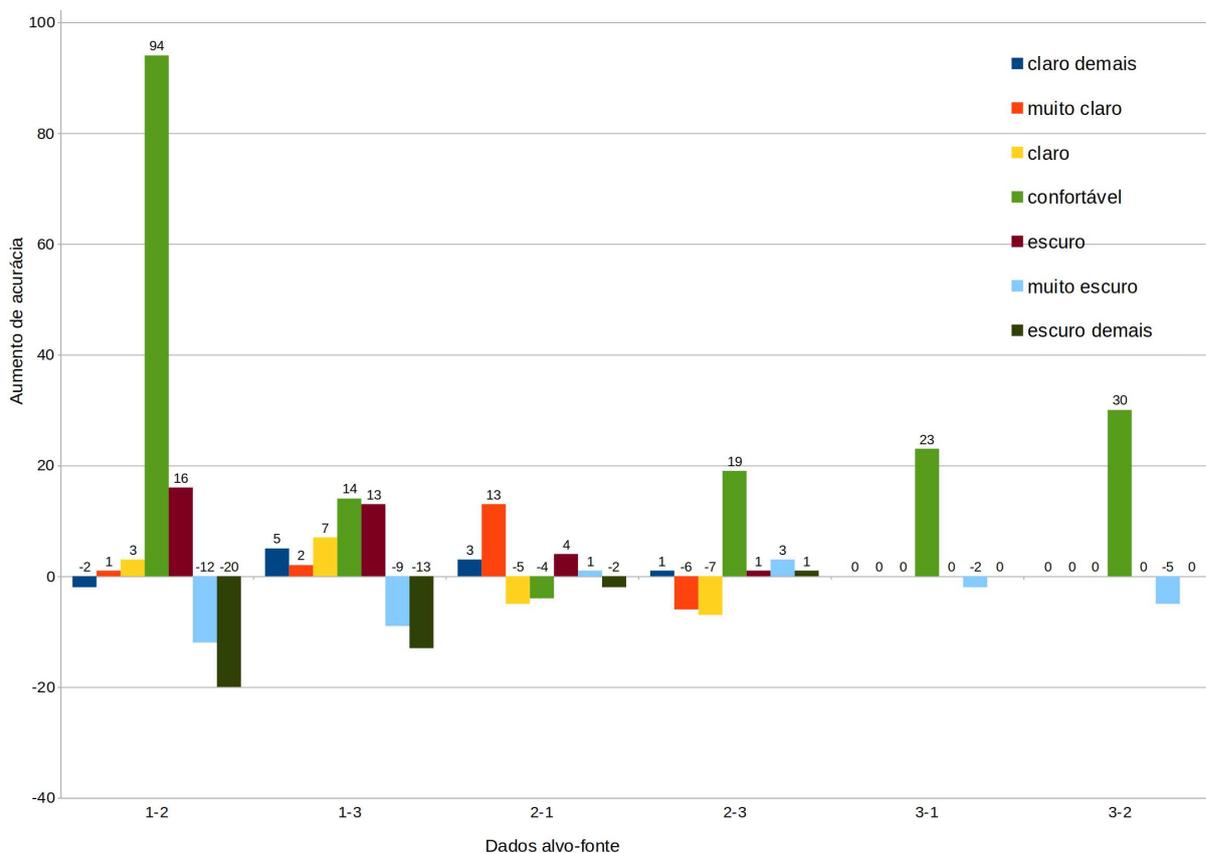
melhorias em alguma quantidade, como mostra o gráfico da Figura 5.7. Porém, alguns rótulos receberam muitos aumentos de acurácias, como o rótulo de confortável, e outros receberem bem pouco, como os rótulos escuro demais e muito escuro, como mostra o gráfico da Figura 5.7.

O gráfico da Figura 5.7 mostra que todos os rótulos performaram negativamente para pelo menos uma combinação de conjunto de dados alvo-fonte. O gráfico da Figura 5.7 mostra que a transferência do conjunto de dados 1 como fonte para o conjunto de dados 2 como alvo teve diminuição na predição do rótulo de confortável, bem como os rótulos escuro demais e claro.

Ao observar o gráfico da Figura 5.7 é perceptível que exceto o rótulo de confortável, nenhum outro rótulo aumentou o número de predições em mais do que 20 predições corretas. Com isso podemos inferir que os modelos alvo tiveram alto desempenho para os rótulos e não deram margem para melhoria, o que pode ser visto nas Figuras 5.5 e 5.6. Também é possível inferir que nenhum modelo de transferência generalizou suficiente para aumentar a acurácia de predição para além de 20 acertos nos rótulos diferentes do confortável.

Os rótulos tiveram desempenho diferente em cada combinação de conjunto de dados alvo fonte. Para saber o desempenho geral de cada rótulo foi calculada a diferença de número de acertos entre a predição do alvo sem a transferência de conhecimento e com a transferência de conhecimento de cada rótulo de todos os experimentos. Este cálculo mostra o aumento da acurácia para cada rótulo em cada experimento como mostrado na Figura 5.7. Em seguida foi calculado a porcentagem de aumento de cada rótulo em cada experimento e por fim foi calculada a média da porcentagem de aumento de cada rótulo em cada experimento como mostrado na Figura 5.8. Cada ponto do gráfico da Figura 5.8

Figura 5.7: Aumento das acurácias dos rótulos para cada par de dados alvo fonte.



Fonte: Autor, 2023.

mostra a porcentagem média de aumento de cada rótulo em todos os experimentos.

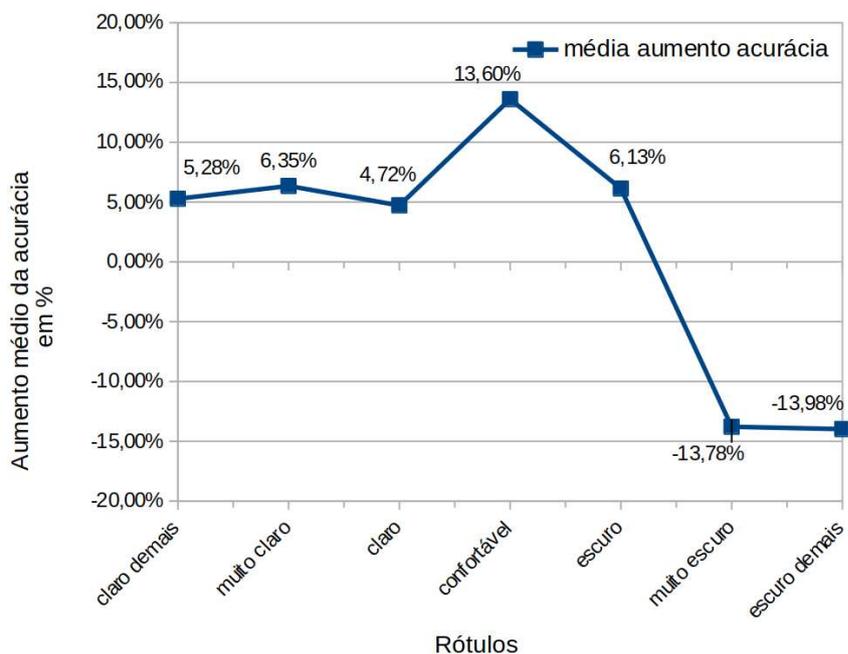
Os rótulos claro demais, muito claro e escuro foram os que tiveram maior porcentagem de aumento depois do rótulo confortável. Os rótulos claro demais, muito claro e escuro alcançaram uma média 5,28%, 6,35% e 6,13% respectivamente como pode ser observado na Figura 5.8. Os rótulos muito escuro e escuro demais tiveram porcentagem negativa no aumento da acurácia como podemos ver na Figura 5.8. A porcentagem negativa quer dizer que em média houve mais daqueles rótulos preditos corretamente no conjunto de dados sem a transferência de conhecimento do que com a transferência de conhecimento.

Outro fator relevante para avaliar o desempenho do modelo é o quanto os modelos aproximaram os rótulos da diagonal principal das matrizes de confusão. Essa ação indica erros menos desconfortáveis para o usuário do ambiente inteligente.

A contabilização do número de aproximações é feita contando o número de rótulos que aproximaram menos o número de rótulos contados que se afastaram da diagonal principal da matriz de confusão. O número de aproximações inclui aquelas que colocaram a predição na diagonal principal.

O número de rótulos que aproximaram é calculado analisando, na matriz de confusão do conjunto de dados alvo. Essa análise avalia se houve diminuição ou aumento dos

Figura 5.8: Aumento médio da acurácia de cada rótulo.



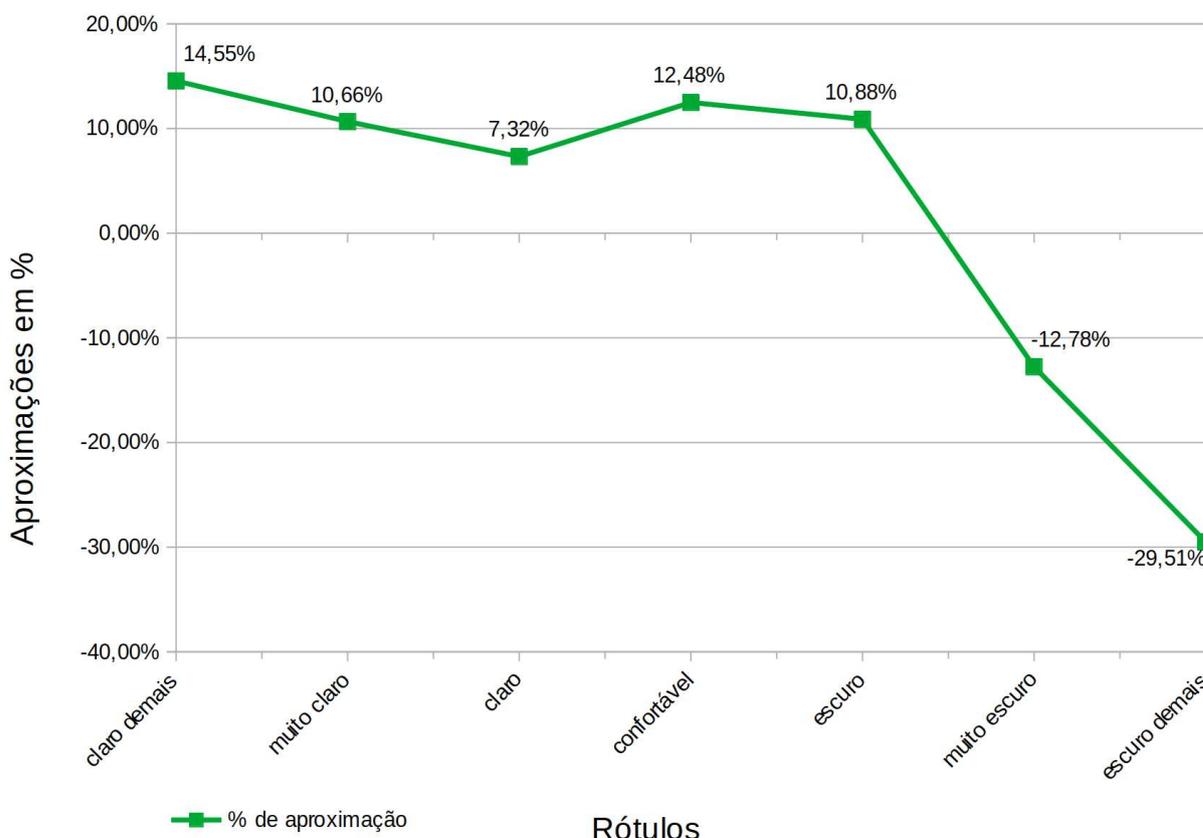
Fonte: Autor, 2023.

rótulos mais próximos da diagonal principal na matriz de confusão da transferência de conhecimento. Se uma entrada da matriz da transferência de conhecimento mais distante do rótulo diminuiu seu valor e uma entrada mais próxima da diagonal principal aumentou seu valor, contabilizamos como aproximação. Se uma entrada próxima da diagonal principal na matriz de transferência diminuiu seu valor e uma entrada mais longe da diagonal principal aumentou seu valor, essa propriedade é contabilizada como um afastamento da diagonal principal. Um afastamento da diagonal principal pode ser considerado uma aproximação negativa. Foi verificado entrada a entrada e contabilizada a aproximação de cada rótulo entre as matrizes do alvo e da transferência de conhecimento.

A Figura 5.9 mostra os rótulos que mais se aproximaram proporcionalmente da predição. Podemos perceber que o rótulo confortável foi o que mais aproximou da predição correta, seguido do rótulo escuro e do rótulo claro demais. Verificando as aproximações dos rótulos, percebemos que exceto os rótulos muito escuro e escuro demais, os demais rótulos aproximaram mais predições do que afastaram como mostra a Figura 5.9.

Os rótulos muito escuro e escuro demais tiveram aproximação negativa, isso quer dizer que estes rótulos tiveram mais valores afastados do que valores aproximados da predição correta.

Figura 5.9: Porcentagem de aproximações dos rótulos da diagonal principal por rótulo em valores absolutos.



Fonte: Autor, 2023.

5.5 Conclusões

É possível concluir que em diversos aspectos a transferência de conhecimento trouxe melhorias para a modelagem dos 3 conjuntos de dados. As melhorias não ocorreram apenas no aumento da acurácia, mas também amenizando o erro do preditor para um nível menos desconfortável para o usuário.

Se contabilizarmos os diversos problemas que os conjuntos de dados tinham, a modelagem com transferência de conhecimento e ajuste fino foi muito bem sucedida. O sucesso da modelagem pode ser confirmada visto que todos os modelos obtiveram melhorias nas acurácias e também na amenização da predição equivocada. Se incluirmos a rotulação de conforto do ambiente sem a necessidade de interação humana de forma consciente, medindo apenas o comportamento do usuário, a predição de conforto com transferência de conhecimento com ajuste fino poderia ter uma taxa de predição correta maior. Isso se baseia no fato desse tipo de coleta fornecer maior quantidade de dados além de menos dados incoerentes.

Capítulo 6

Conclusões

Este capítulo apresenta as conclusões sobre o projeto e os trabalhos futuros.

6.1 Conclusões

Neste projeto implementamos a transferência de conhecimento com ajuste fino para uma nova aplicação. Com isso o objetivo era o de aprimorar e expandir a percepção sobre a aplicação de modelagem de aprendizado para predição de conforto personalizado em um ambiente inteligente. O projeto obteve êxito na proposta de transferência de conhecimento com ajuste fino para melhorar o tempo de predição de conforto personalizado em ambientes inteligentes.

Podemos considerar que o resultado do projeto alcançou as expectativas, pois a proposta foi cumprida mesmo utilizando conjuntos de dados reais que trouxeram consigo muitos desafios para os autores do projeto. Os dados são um fator muito importante na elaboração de projetos como esse e devem ter o máximo empenho por parte dos pesquisadores durante sua coleta para que as propriedades dos dados sejam otimizadas. Estas propriedades definem a precisão e a capacidade de generalização dos modelos.

Os resultados corroboraram toda a teoria proposta de transferência de conhecimento com ajuste fino para predição de conforto personalizado em ambientes inteligentes. Com os resultados obtidos, foi ampliada a perspectiva sobre o tema abordado. Isso mostrou que a transferência de conhecimento com ajuste fino tem grande potencial de melhoria no treinamento de modelos de predição com poucos dados em personalização de ambientes inteligentes.

6.2 Trabalhos Futuros

Em trabalhos futuros exibimos possíveis tecnologias que planejamos implementar e aplicar para melhorar a modelagem de dados com poucos dados para predição de conforto personalizados em ambientes supervisionados.

O **Melhoramento sobreposto de modelos** é um possível trabalho futuro em que testamos melhorias sequenciada com mais de um modelo em sequência. Com isso podemos verificar se o conhecimento acumulado ao longo da sequência de aprendizado melhora a predição do modelo mais do que uma transferência de conhecimento simples. Com isso, temos a transferência de conhecimento de um grupo de pessoas para uma única pessoa. Isso pode ter melhor desempenho de predição por transferir um conhecimento mais genérico sobre a percepção humana do que transferir o conhecimento de um único usuário [11].

O **Few-shot Learning (FSL)** é uma técnica de transferência de conhecimento que aplica o conhecimento de dados existentes de tarefas relacionadas em um novo conjunto de dados que não possuem dados rotulados suficientes para treinar um modelo [26].

O **Aprendizado por Reforço Profundo** é outra proposta para os trabalhos futuros. O aprendizado por reforço trabalha com o conceito de recompensa positiva e negativa. O modelo é treinado e a cada execução das tarefas este recebe uma recompensa. O modelo realiza diversos treinos visando maximizar as recompensas obtidas [47]. O aprendizado por reforço permite que o modelo aprenda ao longo do tempo e atrelado à transferência de conhecimento pode ser uma ótima forma de modelar predição personalizada em ambientes inteligentes.

6.3 Dificuldades

Os maiores desafios para o desenvolvimento do projeto foram a implementação dos softwares para a modelagem de predição e a implementação e instalação dos softwares para funcionamento do hardware. Grande parte do projeto consiste em desenvolver modelos que dependem de utilizar extensas bibliotecas com curvas de aprendizado difícil. Estas bibliotecas possuem uma complexa quantidade de conceitos e requisitos que devem ser compreendidos antes mesmo de aprender os métodos da biblioteca e suas utilidades.

Instalar o hardware e os softwares das plataformas do experimento em casa foi outro grande desafio e de grande dificuldade. A plataforma de experimentação possuía uma

extensa quantidade de conceitos e minúcias. Estas demandaram muito tempo e interação com os autores tanto do hardware quanto dos softwares da plataforma de experimentação. Questões como compatibilidade de bibliotecas, formas de interação e funcionamento do hardware e instanciação de drivers demandaram muitos meses de estudo e discussão para poder implementar um escritório residencial inteligente.

Referências

- [1] SmartThings Aeotec. Multisensor 6 aeotec. <https://aeotec.com/products/aeotec-multi-sensor-6/>, 2023. Acessado: 18-08-2023.
- [2] Thamer Al-Rousan. The future of the internet of things. *International Journal of Computers, Communications & Control (IJCCC)*, 2017.
- [3] A. Anjomshoaa and E. Curry. Transfer learning in smart environments. *Mach. Learn. Knowl. Extr.*, 3:318–332, 2021.
- [4] Josué Batista Antunes. Uma plataforma para gerenciamento e aplicações em internet das coisas. Master’s thesis, Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de Minas Gerais, 2016.
- [5] Kevin Ashton. That ”internet of things” thing. *RFID Journal*, 2009.
- [6] Luigi Atzori, Antonio Iera, and Giacomo Morabito. The internet of things: A survey. *Comput. Netw.*, pages 2787–2805, 2010.
- [7] A. Daoud B. Alhafidh and W. Allen. Poster abstract: Comparison of classifiers for prediction of human actions in a smart home. *IProceedings - ACM/IEEE International Conference on Internet of Things Design and Implementation, IoTDI 2018*, 2018.
- [8] Daniel Belete and Manjaiah D H. Grid search in hyperparameter optimization of machine learning models for prediction of HIV/AIDS test results. *International Journal of Computers and Applications*, 44:1–12, 09 2021.
- [9] Christopher M. Bishop. *Pattern Recognition and Machine Learning (Information Science and Statistics)*. Springer-Verlag, Berlin, Heidelberg, 2006.
- [10] Sidia M. Callegari-Jacques. *Bioestatística, princípios e aplicações*. Artmed, 2003.
- [11] Marcos Carvalho, Daniel Soares, and Daniel Macedo. Transfer learning-based QoE estimation for different cloud gaming contexts. pages 71–79, 06 2023.
- [12] Marcos Carvalho, Daniel Soares, and Daniel F. Macedo. Transfer learning-based QoE estimation for different cloud gaming contexts. In *2023 IEEE 9th International Conference on Network Softwarization (NetSoft)*, pages 71–79, 2023.

- [13] Diane J. Cook Chao Chen, Barnan Das. A data mining framework for activity recognition in smart environments. *Sixth International Conference on Intelligent Environments*, 2010.
- [14] Peter Chapman, Julian Clinton, Randy Kerber, Tom Khabaza, Thomas P. Reinartz, Colin Daimlerchrysler, Rüdiger Shearer, and Wirth. CRISP-DM 1.0: Step-by-step data mining guide. 2000.
- [15] Yi Ting Chiang, Ching Hu Lu, and Jane Yung Jen Hsu. A feature-based knowledge transfer framework for cross-environment activity recognition toward smart home applications. *IEEE Transactions on Human-Machine Systems*, 47:310–322, 6 2017.
- [16] Francois Chollet et al. Keras deep learning for humans. <https://keras.io/>, 2015. (Acessado em 17/10/2023).
- [17] M. H. Coen. Design principles for intelligent environments. *Proceedings of the National Conference on Artificial Intelligence*, pages 547–554, 1998.
- [18] Wikimedia Commons. File:stratified sampling.png — wikimedia commons, the free media repository, 2020. [Online; Acessado em 24/11/2023].
- [19] Guillermo Ponce Contreras. A smart IoT office employing machine learning for personalized user comfort. Master’s thesis, Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de Minas Gerais, 2019.
- [20] PyTorch Contributors. Pytorch. <https://pytorch.org/>, 01 2017. (Acessado em 17/10/2023).
- [21] Equipe Dsa. *Capítulo 10 - As 10 Principais Arquiteturas de Redes Neurais - Deep Learning Book*. December 2022. Acessado em 15/01/2024.
- [22] Equipe Dsa. *Capítulo 34 - O Problema da Dissipação do Gradiente - Deep Learning Book*. December 2022. Acessado em 27/11/2023.
- [23] J. Durbin. Kolmogorov-smirnov tests when parameters are estimated with applications to tests of exponentiality and tests on spacings. *Biometrika*, 62(1):5–22, 1975.
- [24] D.M. El-Din, A.E. Hassanein, and E.E. Hassanien. Smart environments concepts, applications, and challenges. *Machine Learning and Big Data Analytics Paradigms: Analysis, Applications and Challenges. Studies in Big Data*. Springer, 77:493–519, 2021.
- [25] A. Ethem. *Introduction to Machine Learning*. MIT Prees, 2004.
- [26] Siwei Feng and Marco F. Duarte. Few-shot learning-based human activity recognition. *Expert Systems with Applications*, 138:112782, December 2019.

- [27] Peter Flach. *Machine Learning The Art and Science of Algorithms that Make Sense of Data*. Cambridge University Press, 2012.
- [28] Donal H. Foley. Considerations of sample and feature size. *IEEE Transactions on Information Theory*, page 618–626, 1972.
- [29] Afshin Gholamy, Vladik Kreinovich, and Olga Kosheleva. Why 70/30 or 80/20 relation between training and testing sets: A pedagogical explanation. 2018. Acessado em 24/11/2023.
- [30] Weizheng Hu, Yong Luo, Zongqing Lu, and Yonggang Wen. Heterogeneous transfer learning for thermal comfort modeling. pages 61–70. Association for Computing Machinery, Inc, 11 2019.
- [31] IBM. O que são Redes Neurais? | IBM, January 2024. [Online; Acessado em 15/01/2024].
- [32] R. Izbicki and T. M. dos Santos. *Aprendizado de máquina: uma abordagem estatística*. 2020.
- [33] S. Jansen. *Machine Learning for Algorithmic Trading: Predictive Models to Extract Signals from Market and Alternative Data for Systematic Trading Strategies with Python*. Expert Insight. Packt Publishing, 2020.
- [34] Pushpendu Kar, Arish Shareef, Arun Kumar, Koh Tsyr Harn, Balaji Kalluri, and Sanjib Kumar Panda. ReViCEE: A recommendation based approach for personalized control, visual comfort & energy efficiency in buildings. *Building and Environment*, 152:135–144, 4 2019.
- [35] K. Kolcaba. *Comfort Theory and Practice: A Vision for Holistic Health Care and Research*. 2003.
- [36] K. Y. Kolcaba. The art of comfort care. *The Journal of Nursing Scholarship*, page 287–289, 1995.
- [37] S. Vidotti L. Camargo. Personalização: um serviço mediador em ambientes de pesquisa. *TransInformação*, 2007.
- [38] Yann LeCun, Yoshua Bengio, and Geoffrey Hinton. Deep learning. *Nature*, 521(7553):436–444, May 2015.
- [39] Huan Liang, Wenlong Fu, and Fengji Yi. A survey of recent advances in transfer learning. *International Conference on Communication Technology Proceedings, ICCT*, pages 1516–1523, 2019.

- [40] Petro Liashchynskiy and Pavlo Liashchynskiy. Grid search, random search, genetic algorithm: A big comparison for NAS. *CoRR*, abs/1912.06059, 2019.
- [41] Guofeng Ma and Xuhui Pan. Research on a visual comfort model based on individual preference in china through machine learning algorithm. *Sustainability (Switzerland)*, 13, 7 2021.
- [42] Larissa Arakawa Martins, Veronica Soebarto, Terence Williamson, and Dino Pisaniello. A deep learning approach to personal thermal comfort models for an ageing population. page 2020, 2020.
- [43] J. Mathew. *PyTorch Artificial Intelligence Fundamentals*. Packt Publishing, 2020.
- [44] Geórgia Alcântara Alencar Melo, Renan Alves Silva, Francisco Gilberto Fernandes Pereira, and Joselany Áfio Caetano. Adaptação cultural e confiabilidade do general comfort. *Revista Latino-Americana de Enfermagem*, 2017.
- [45] T. M. Mitchell. *Machine learning*. McGraw-Hill Science/Engineering/Math, 1997.
- [46] C. Wang M.M. Tseng, R.J. Joao. Design for mass personalization. *CIRP Annals - Manufacturing Technology*, 2010.
- [47] Volodymyr Mnih, Koray Kavukcuoglu, David Silver, Andrei A. Rusu, Joel Veness, Marc G. Bellemare, Alex Graves, Martin Riedmiller, Andreas K. Fidjeland, Georg Ostrovski, Stig Petersen, Charles Beattie, Amir Sadik, Ioannis Antonoglou, Helen King, Dhharshan Kumaran, Daan Wierstra, Shane Legg, and Demis Hassabis. Human-level control through deep reinforcement learning. *Nature*, 518:529–533, February 2015.
- [48] Sharada Prasanna Mohanty, David Hughes, and Marcel Salathe. Using deep learning for image-based plant disease detection, 2016.
- [49] A.C. Muller and S. Guido. *Introduction to Machine Learning with Python: A Guide for Data Scientists*. O’Reilly Media, Incorporated, 2018.
- [50] Kevin P. Murphy. *Machine learning : a probabilistic perspective*. MIT Press, Cambridge, Mass. [u.a.], 2012.
- [51] A ; Natarajan, E Laftchiev, Annamalai Natarajan, and Emil Laftchiev. A transfer active learning framework to predict thermal comfort. 2019. Acessado em 15/04/2023.
- [52] P. Norvig and S. Russell. *Inteligência Artificial*. ELSEVIER EDITORA, 2013.
- [53] C. Oliveira. Conforto e bem-estar enquanto conceitos em uso em enfermagem. *Pensar Enfermagem*, pages 2–8, 2013.

- [54] Sérgio de Oliveira. *Internet das Coisas com ESP8266, Arduino e Raspberry Pi*. Novatec Editora, São Paulo, SP-Brasil, 2^a edition, 2021.
- [55] S. Pan and Q. Yang. A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering*, pages 1345–1359, 2010.
- [56] Nikolaos Passalis and Anastasios Tefas. Probabilistic knowledge transfer for deep representation learning. *CoRR*, abs/1803.10837, 2018.
- [57] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, and E. Duchesnay. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12:2825–2830, 2011. (Acessado em 17/10/2023).
- [58] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, and E. Duchesnay. sklearnmodel.selection.stratifiedkfold scikitlearn 131 documentation. https://scikit-learn.org/stable/modules/generated/sklearn.model_selection.StratifiedKFold.html#sklearn.model_selection.StratifiedKFold, 06 2016. (Acessado em 18/10/2023).
- [59] W. Pedrycz and S.M. Chen. *Deep Learning: Algorithms and Applications*. Studies in Computational Intelligence. Springer International Publishing, 2019.
- [60] Giuseppe Pinto, Zhe Wang, Abhishek Roy, Tianzhen Hong, and Alfonso Capozzoli. Transfer learning for smart buildings: A critical review of algorithms, applications, and future perspectives. *Advances in Applied Energy*, 5, 2 2022.
- [61] Kevin L. Priddy and Paul E. Keller. *Artificial neural networks : an introduction*. SPIE—The International Society for Optical Engineering, 2005.
- [62] Jorge Ramos, Rodrigo Rodrigues, João Silva, and Pamella Oliveira. CRISP-EDM: uma proposta de adaptação do modelo CRISP-DM para mineração de dados educacionais. In *Anais do XXXI Simpósio Brasileiro de Informática na Educação*, pages 1092–1101, Porto Alegre, RS, Brasil, 2020. SBC.
- [63] Parisa Rashidi and Diane J. Cook. Activity recognition based on home to home transfer learning. In *Proceedings of the 5th AAAI Conference on Plan, Activity, and Intent Recognition*, AAAIWS’10-05, page 45–52. AAAI Press, 2010. Acessado em 14/11/2023.

- [64] S. Ravichandiran. *Hands-On Deep Learning Algorithms with Python: Master deep learning algorithms with extensive math by implementing them using TensorFlow*. Packt Publishing, 2019.
- [65] Sudharsan Ravichandiran. *Deep Reinforcement Learning with Python*. Packt Publishing, 2^a edition, 2020.
- [66] Angie K. Reyes, Juan C. Caicedo, and Jorge E. Camargo. Fine-tuning deep convolutional networks for plant recognition. In *Conference and Labs of the Evaluation Forum*, 2015.
- [67] Ricardo Ribani and Mauricio Marengoni. A survey of transfer learning for convolutional neural networks. *IEEE*, pages 47–57, 2019.
- [68] P. Rivas. *Deep Learning for Beginners: A beginner’s guide to getting up and running with deep learning from scratch using Python*. Packt Publishing, 2020.
- [69] M. Russo and M. Stella. Guest editorial: Smart environment technologies. *Journal of Communications Software and Systems*, 10:161–162, 2014.
- [70] R. T. Sataloff, M. M. Johns, and K. M. Kost. *Machine learning and IoT : a biological perspective / [edited by] Shampa Sen, Leonid Datta, Sayak Mitra*. CRC Press, 2019.
- [71] Christoph Schröer, Felix Kruse, and Jorge Marx Gómez. A systematic literature review on applying CRISP-DM process model. *Procedia Computer Science*, 181:526–534, 2021.
- [72] scikit-learn developers. Metrics and scoring: quantifying the quality of predictions. https://scikit-learn.org/stable/modules/model_evaluation.html#accuracy-score, 2007 / 2023. Acessado: 15/10/2023.
- [73] S. Sen and L. Datta. *Machine learning and IoT : a biological perspective*. CRC Press, 2019.
- [74] Colin Shearer. The CRISP-DM model: the new blueprint for data mining. *Journal of data warehousing*, 5(4):13–22, 2000.
- [75] B. H. Shekar and Guesh Dagneu. Grid search-based hyperparameter tuning and classification of microarray cancer data. In *2019 Second International Conference on Advanced Computational and Communication Paradigms (ICACCP)*, pages 1–8, 2019.
- [76] Carlos H. C. Ribeiro Sildomar T. Monteiro. Desempenho de algoritmos de aprendizagem por reforço sob condições de ambiguidade sensorial em robótica móvel. *Revista Controle & Automação*, 2004.

-
- [77] Nitish Srivastava, Geoffrey Hinton, Alex Krizhevsky, Ilya Sutskever, and Ruslan Salakhutdinov. Dropout: A simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, 15(56):1929–1958, 2014.
- [78] Edna Chebet Too, Li Yujian, Sam Njuki, and Liu Yingchun. A comparative study of fine-tuning deep learning models for plant disease identification. *Computers and Electronics in Agriculture*, 161:272–279, 2019. BigData and DSS in Agriculture.
- [79] G. A. Tsihrintzis, D. N. Sotiropoulos, and L. C. Jain. *Machine learning paradigms: Advances in data analytics*, volume 149 of *Intelligent Systems Reference Library*. Springer, 2019.
- [80] M. Veselý, W. Zeiler, G. Boxem, and D. R. Vissers. The human body as its own sensor for thermal comfort. *Proceedings of CISBAT*, pages 379–384, 2013.
- [81] J. Wang and Y. Chen. *Introduction to Transfer Learning: Algorithms and Practice*. Machine Learning: Foundations, Methodologies, and Applications. Springer Nature Singapore, 2023.
- [82] Y. Wang, Q. Yao, J. Kwok, and L. M. Ni. Generalizing from a few examples: A survey on few-shot learning. *arXiv:1904.05046*, 2019.
- [83] Mark Weiser. The computer for the 21st century. *Scientific American*, 1991.
- [84] Rüdiger Wirth and Jochen Hipp. CRISP-DM: towards a standard process model for data mining. 2000.

Apêndice A

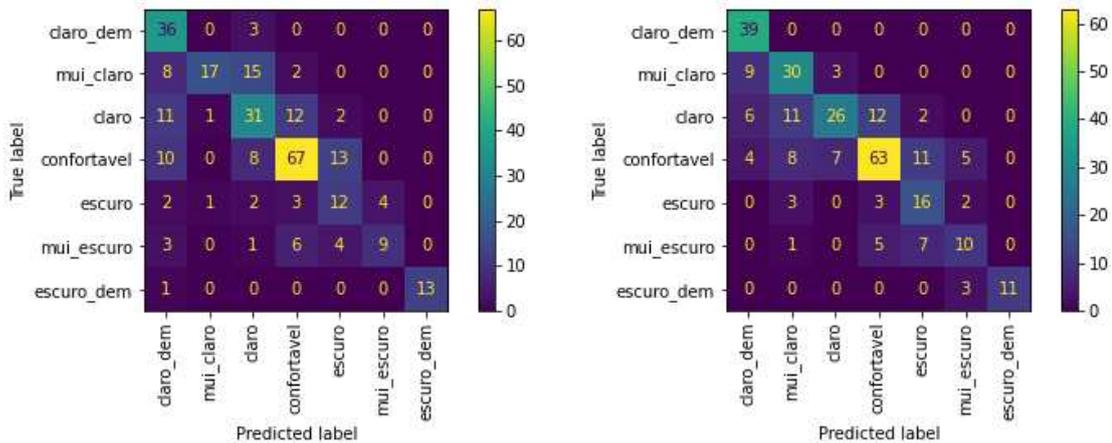
Matrizes de confusão

A.1 Modelagem com redução do rótulo de confortável no conjunto de dados 3

O rótulo confortável do conjunto de dados 3 foi reduzido em 50% para averiguar como o modelo se comportaria como alvo. A conclusão foi de que houve aumento na quantidade de rótulos com aumento de acurácia como pode ser visto nas Figuras [A.5](#) e [A.6](#). Porém, houve redução na acurácia com a transferência de conhecimento na maioria dos rótulos diferentes do confortável. Podemos concluir que o desbalanceamento é um fator para melhoria de acurácia. Porém, além do desbalanceamento, a falta de rótulos no conjunto de dados 3 pode ser um fator que prejudica a transferência de conhecimento. Os rótulos de confortável continuaram a obter melhorias assim como na versão do conjunto de dados 3 sem a remoção de parte dos rótulos confortável.

Figura A.1: Comparação das matrizes de confusão com e sem transferência de conhecimento do usuário 1 para o usuário 2 da modelagem de classificação.

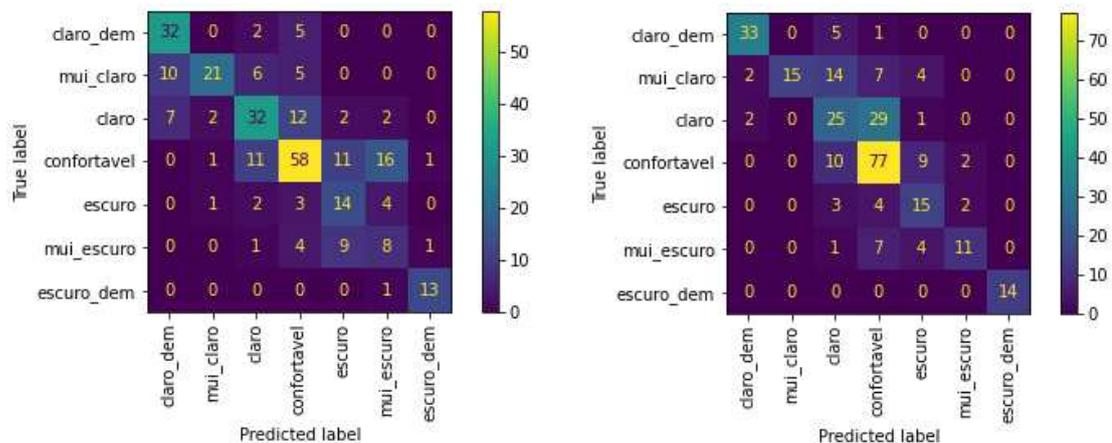
- (a) Matriz de confusão de acurácia de teste do usuário 2. (b) Matriz de confusão de acurácia de teste da transferência de conhecimento.



Fonte: Autor, 2023.

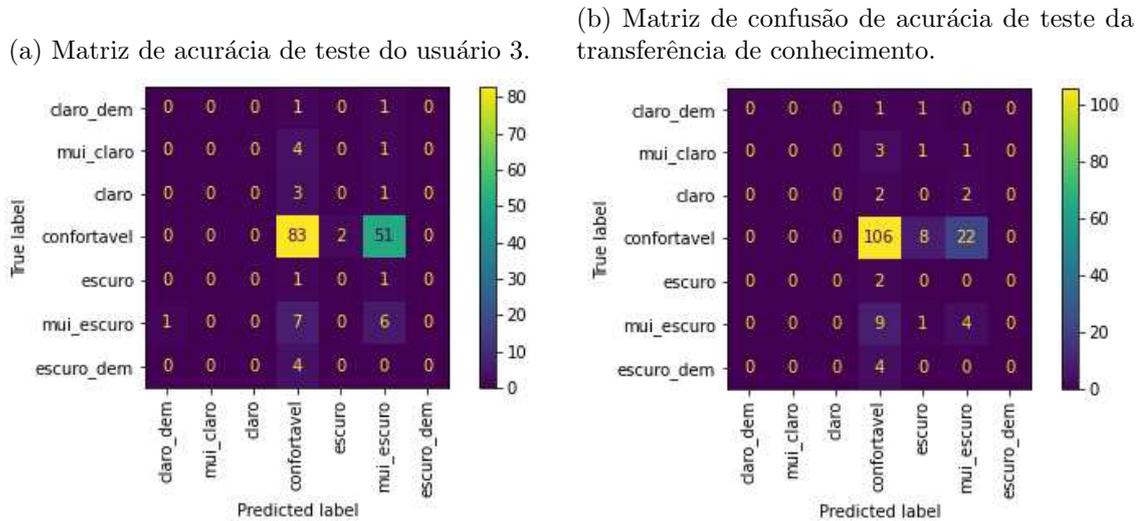
Figura A.2: Comparação das matrizes de confusão com e sem transferência de conhecimento do usuário 3 para o usuário 2 da modelagem de classificação.

- (a) Matriz de confusão de acurácia de teste do usuário 2. (b) Matriz de confusão de acurácia de teste da transferência de conhecimento.



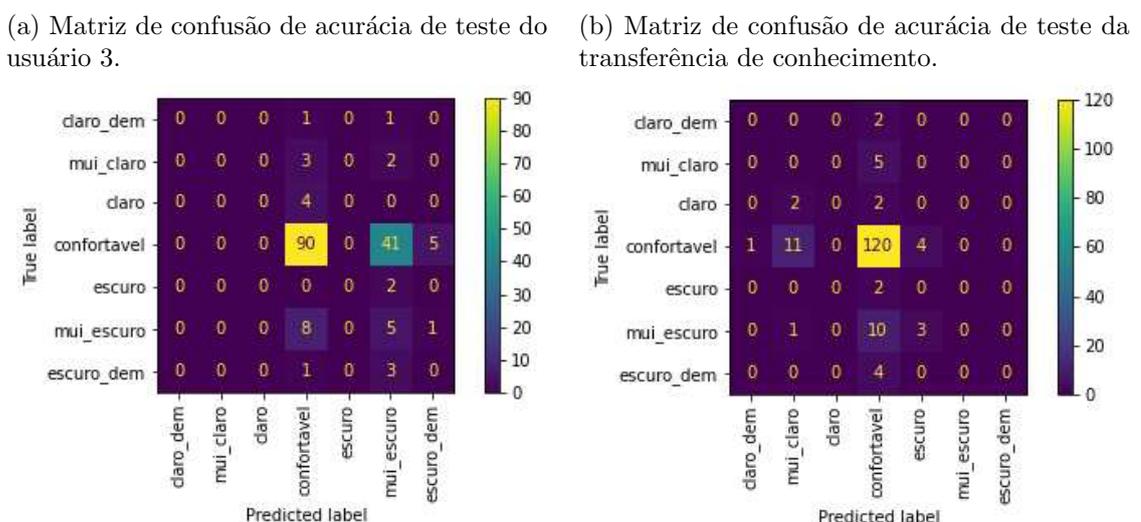
Fonte: Autor, 2023.

Figura A.3: Comparação das matrizes de confusão com e sem transferência de conhecimento do usuário 1 para o usuário 3 da modelagem de classificação.



Fonte: Autor, 2023.

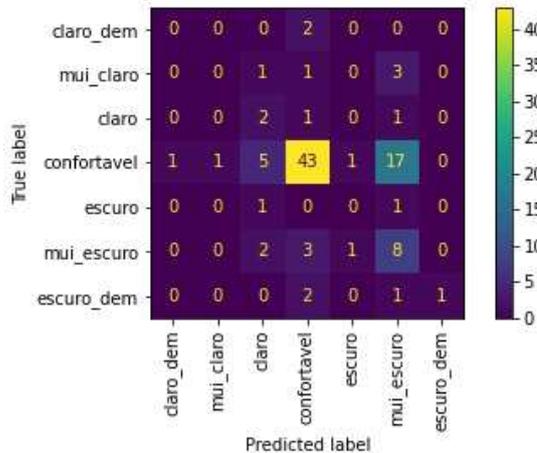
Figura A.4: Comparação das matrizes de confusão com e sem transferência de conhecimento do usuário 2 para o usuário 3 da modelagem de classificação.



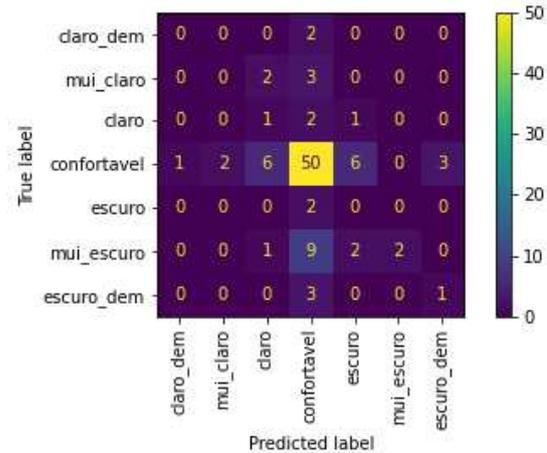
Fonte: Autor, 2023.

Figura A.5: Comparação das matrizes de confusão com e sem transferência de conhecimento do usuário 1 para o usuário 3 da modelagem de classificação com redução na quantidade de rótulos de conforto do conjunto de dados 3.

(a) Matriz de confusão de acurácia de teste do usuário 3 com redução na quantidade de rótulos de conforto do conjunto de dados 3.



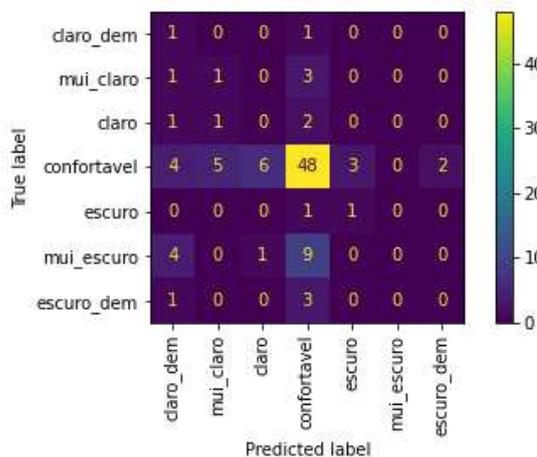
(b) Matriz de confusão de acurácia de teste da transferência de conhecimento com redução na quantidade de rótulos de conforto do conjunto de dados 3.



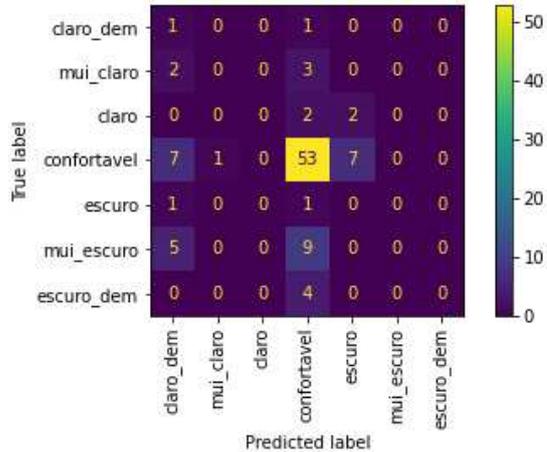
Fonte: Autor, 2023.

Figura A.6: Comparação das matrizes de confusão com e sem transferência de conhecimento do usuário 2 para o usuário 3 da modelagem de classificação com redução na quantidade de rótulos de conforto do conjunto de dados 3.

(a) Matriz de confusão de acurácia de teste do usuário 3 com redução na quantidade de rótulos de conforto do conjunto de dados 3.



(b) Matriz de confusão de acurácia de teste da transferência de conhecimento com redução na quantidade de rótulos de conforto do conjunto de dados 3.



Fonte: Autor, 2023.