

UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
FACULDADE DE ENGENHARIA – CAMPUS DE ILHA SOLTEIRA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

DANIELI BIAGI VILELA

Detecção da Ocupação de um Ambiente a partir de Dados de Sensores
Utilizando Rede Neural ARTMAP *Fuzzy*

ILHA SOLTEIRA
2020



DANIELI BIAGI VILELA

Detecção da Ocupação de um Ambiente a partir de
Dados de Sensores Utilizando Rede Neural ARTMAP
Fuzzy

Dissertação apresentada à Faculdade de Engenharia do Campus de Ilha Solteira – UNESP, como parte dos requisitos para obtenção do título de Mestre em Engenharia Elétrica.

Prof^ª. Dr^ª. Anna Diva Plasencia Lotufo
Orientadora

ILHA SOLTEIRA

2020



FICHA CATALOGRÁFICA
Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

Vilela, Danieli Biagi.
V699d Detecção da ocupação de um ambiente a partir de dados de sensores
utilizando Rede Neural Artificial ARTMAP Fuzzy / Danieli Biagi Vilela. -- Ilha
Solteira: [s.n.], 2020
89 f. : il.

Dissertação (mestrado) - Universidade Estadual Paulista. Faculdade de
Engenharia de Ilha Solteira. Área de conhecimento: Automação, 2020

Orientador: Anna Diva Plasencia Lotufo
Inclui bibliografia

1. Redes Neurais Artificiais. 2. Detecção da ocupação. 3. Rede Artmap Fuzzy.
4. Ambientes inteligentes. 5. Prédios inteligentes.


Raiane da Silva Santos

Supervisora Técnica de Seção
Seção Técnica de Referência, Atendimento ao usuário e Documentação
Diretoria Técnica de Biblioteca e Documentação
CRB/8 - 20999



UNIVERSIDADE ESTADUAL PAULISTA

Câmpus de Ilha Solteira

CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: Detecção da Ocupação de um Ambiente a partir de Dados de Sensores Utilizando Rede Neural ARTMAP Fuzzy

AUTORA: DANIELI BIAGI VILELA

ORIENTADORA: ANNA DIVA PLASENCIA LOTUFO

Aprovada como parte das exigências para obtenção do Título de Mestre em ENGENHARIA ELÉTRICA, área: Automação pela Comissão Examinadora:

Profª. Drª. ANNA DIVA PLASENCIA LOTUFO

Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira - UNESP

Profª. Drª. MARA LUCIA MARTINS LOPES

Departamento de Matemática / Faculdade de Engenharia de Ilha Solteira - UNESP

Pós-doutorando MAURO DE SOUZA TONELLI NETO

MacPhail School of Energy - Southern Alberta Institute of Technology - Calgary, AB, Canadá

Ilha Solteira, 31 de agosto de 2020

A todos que não tiveram a oportunidade de continuar seus estudos ou mesmo de iniciá-los,
sendo tolhidos de terem para si uma vida mais digna nesse país de exclusão.

AGRADECIMENTOS

A Prof^a. Dr^a. Anna Diva Plasencia Lotufo, minha orientadora, pela confiança na realização do trabalho, orientação, dedicação, prontidão, apoio, paciência e pelo exemplo como profissional.

A minha irmã Letícia, pelo exemplo, pelo amor, pela inspiração e por ser minha xerocópia em quase tudo. A minha irmã Tatiani, pelas noites e dias de conversa, pelo amor e pela esperança em dias melhores.

Aos meus pais, Solange e Marcos, pela vida, por serem meu ponto de partida e ponto final.

Ao Giovanni, pelo companheirismo, motivação, apoio, cuidado, amor, confiança e genuinidade.

Aos colegas de laboratório, pela companhia e cafés, em especial Monara, Haislan, Marleide, Drieli e Tânia pelo apoio na realização do trabalho.

A Prof^a. Dr^a. Mara Lúcia Martins Lopes, pelo apoio e confiança, pelas contribuições, pelo carinho, pela prontidão e disposição e pela inspiração como profissional.

Aos técnicos do laboratório de informática, pela assistência.

Ao CNPq e CAPES, pela concessão de bolsa de pesquisa.

E ao SINTEL, PPGE e FEIS por proporcionarem toda a estrutura necessária para a concretização deste trabalho.

*“Educação não transforma o mundo.
Educação muda as pessoas.
Pessoas transformam o mundo.”*
Paulo Freire

RESUMO

A detecção de presença em um ambiente tem se mostrado uma tarefa com grande potencial para aumentar a eficiência energética de prédios e auxiliar em tecnologias remotas de monitoramento e assistência nos *smarts buildings*, prédios inteligentes. Com a disponibilidade cada vez maior de sensores e tecnologias integradas, os prédios inteligente vêm evoluindo na maneira de interagir com usuários, com destaque na literatura atualizada as técnicas de *machine learning* e, dentre elas, as redes neurais artificiais. Com o intuito de testar novos algoritmos para esta tarefa, foi proposto neste trabalho, o uso da rede neural artificial ARTMAP *Fuzzy* como algoritmo classificador. Foram utilizados dados obtidos de sensores de temperatura, CO₂, luminosidade e umidade. As simulações foram realizadas com combinações diferentes de variáveis de entrada e três tipos de normalização. Foi possível observar um bom desempenho na classificação do *status* da ocupação, e pelo desempenho e tempo de diagnóstico da rede, o algoritmo tem potencial para ser agregado em um sistema comercial de detecção de presença em tempo real.

Palavras-chave: ARTMAP *Fuzzy*. Redes Neurais Artificiais. Detecção de Presença. Prédios Inteligentes. Ambientes Inteligentes.

ABSTRACT

Presence detection in an environment has proved to be a task with great potential to increase the energy efficiency of buildings and aid in remote monitoring and assistance technologies in smart buildings. With the increasing availability of sensors and integrated technologies, smart buildings have evolved in the way they interact with users, with machine learning and artificial neural networks techniques stand out in recent literature. In order to test new algorithms for this task, we propose in this work the use of the Fuzzy ARTMAP artificial neural network as a classifier algorithm. Data obtained from temperature, CO₂, light and humidity sensors were used. The simulations were performed with training in sequential and random order and with two sample sizes. The results show a good performance in classifying occupation status and by the network diagnosis time and performance the algorithm can be added to a commercial real time presence detection system.

Keywords: Fuzzy ARTMAP. Artificial Neural Networks. Presence Detection. Smarts Buildings. Smart Environments.

LISTA DE ILUSTRAÇÕES

Figura 1 – Evolução dos trabalhos publicados nos últimos 20 anos	15
Figura 2 – Componentes de um ambiente inteligente	23
Figura 3 – Conceito de ocupação em três dimensões	26
Figura 4 – Visão geral das principais etapas de um sistema generalista de detecção de ocupação	29
Figura 5 – Principais redes ART e tipo de treinamento	43
Figura 6 – Arquitetura da rede neural ART	45
Figura 7 – Fluxograma de funcionamento da RNA ART- <i>Fuzzy</i>	49
Figura 8 – Arquitetura da RNA ARTMAP <i>Fuzzy</i>	51
Figura 9 – Etapas da metodologia utilizada.	57
Figura 10 – Comportamento do CO ₂ em função das horas do dia.	58
Figura 11 – Comportamento da temperatura em função das horas do dia.	58
Figura 12 – Comportamento da umidade em função das horas do dia.	59
Figura 13 – Comportamento da luminosidade em função das horas do dia.	59
Figura 14 – Comportamento da ocupação do ambiente em função das horas do dia.	60
Figura 15 – Desempenho individual das variáveis na detecção de presença	65
Figura 16 – Evolução do acerto (%) no teste com as variáveis CO ₂ , L, T, U e H	66
Figura 17 – Relação entre o desempenho da classificação e a quantidade de categorias criadas	69
Figura 18 – Comparação da ocupação real e calculada pela rede.	69
Figura 19 – Pontos de erro da rede ARTMAP <i>Fuzzy</i> para Aplicação 1.	70
Figura 20 – Pontos de erro da rede ARTMAP <i>Fuzzy</i> para Aplicação 2.	70
Figura 21 – Modelo de um neurônio artificial	82

LISTA DE TABELAS

Tabela 1 – Visão geral dos trabalhos de detecção de ocupação que utilizaram RNAs.	21
Tabela 2 – Visão geral e comparativa dos tipos de sensores mais comuns em sistemas de detecção de ocupação.	36
Tabela 3 – Avaliação comparativa entre os algoritmos utilizados	39
Tabela 4 – Matriz de confusão.	41
Tabela 5 – Parâmetros ótimos utilizados na rede ARTMAP <i>Fuzzy</i>	62
Tabela 6 – Desempenho de diferentes combinações das variáveis de entrada.	63
Tabela 7 – Desempenho das normalizações testadas nas 25 primeiras repetições.	67
Tabela 8 – Continuação da Tabela 7: Desempenho das normalizações testadas.	68
Tabela 9 – Momento e classificação dos erros.	71
Tabela 10 – Matriz de confusão para o melhor resultado da Aplicação 2.	71

LISTA DE ABREVIATURAS E SIGLAS

ART	Adaptative Ressonance Theory
AVAC	Aquecimento, ventilação e ar condicionado
BECM	<i>Building Energy and Comfort Management</i>
BP	<i>Backpropagation</i>
CART	<i>Classification and Regression Trees</i>
COVT	Compostos orgânicos voláteis totais
EIBG	<i>European Intelligent Building Group</i>
ELM	<i>Extreme Learning Machine</i>
FN	Falso Negativo
FP	Falso Positivo
HMM	<i>Hidden Markov Models</i>
H	Hora
IBI	<i>Intelligent Building Institute</i>
KNN	<i>K-nearest neighbors</i>
L	Luminosidade
LTM	<i>Long Term Memory</i>
LDA	<i>Linear Discriminant Analysis</i>
P	Pressão
PIR	<i>Passive Infrared</i>
QN	<i>Limited Memory Quasi-Newton</i>
RBF	Rede Neural Artificial de Base Radial
RFID	Identificação por radiofrequência
RNAs	Redes Neurais Artificiais
RNAT	Redes Neurais com Atraso de Tempo

RNFF	Redes Neurais <i>Feedforward</i>
RF	<i>Random Forest</i>
STM	<i>Short Term Memory</i>
SVM	Support Vector Machine
T	Temperatura
TN	<i>True Negative</i>
TP	<i>True Positive</i>
U	Umidade

SUMÁRIO

1	INTRODUÇÃO	11
1.1	OBJETIVO DO TRABALHO	13
1.2	ORGANIZAÇÃO DO TRABALHO	13
2	TRABALHOS CORRELATOS	15
2.1	MODELOS GRÁFICOS PROBABILÍSTICOS	16
2.2	MODELOS DE APRENDIZAGEM ESTATÍSTICOS	16
2.3	MODELOS BASEADOS EM <i>KERNEL</i>	17
2.4	MINERAÇÃO DE DADOS	18
3	DETECÇÃO DE OCUPAÇÃO EM PRÉDIOS INTELIGENTES	22
3.1	SENSORES E EQUIPAMENTOS	28
3.1.1	Sensores PIR	28
3.1.2	Medidor inteligente de energia	30
3.1.3	Sensores ambientais	30
3.1.4	Câmeras	33
3.1.5	Wi-Fi	34
3.1.6	Fusão de sensores	34
3.2	PRINCIPAIS ALGORITMOS	37
3.3	AVALIAÇÃO DE DESEMPENHO	40
4	TEORIA DA RESSONÂNCIA ADAPTATIVA	42
4.1	REDE NEURAL ARTIFICIAL ART- <i>FUZZY</i>	44
4.1.1	Arquitetura	44
4.1.2	Algoritmo de Treinamento ART- <i>Fuzzy</i>	45
4.2	REDE NEURAL ARTIFICIAL ARTMAP <i>FUZZY</i>	50
4.2.1	Vetores de entrada e de atividade	50
4.2.2	Vetores de peso	52
4.2.3	Parâmetros	52
4.2.4	Escolha de categoria	53
4.2.5	Ressonância e <i>reset</i>	53
4.2.6	Aprendizagem	54
4.2.7	Algoritmo de treinamento da RNA ARTMAP <i>Fuzzy</i>	54
4.2.8	Algoritmo de teste da RNA ARTMAP <i>Fuzzy</i>	55
5	METODOLOGIA	57
5.1	OBTENÇÃO E ANÁLISE DOS DADOS	57

5.2	AJUSTE DE PARÂMETROS	60
5.3	TREINAMENTO E TESTES	61
6	RESULTADOS E DISCUSSÃO	62
6.1	ANÁLISE DE DESEMPENHO DAS VARIÁVEIS	62
6.2	EFEITO DAS NORMALIZAÇÕES	65
6.3	PERFIL DA OCUPAÇÃO	67
6.4	ANÁLISE DE DESEMPENHO	69
7	CONCLUSÕES E TRABALHOS FUTUROS	72
7.1	SUGESTÕES PARA TRABALHOS FUTUROS	73
	REFERÊNCIAS	74
	APÊNDICE A – REDES NEURAIS ARTIFICIAIS	81
A.1	NEURÔNIO ARTIFICIAL	81
A.2	ESTRUTURA	83
A.3	TREINAMENTO	83

1 INTRODUÇÃO

Ambientes inteligentes vêm se tornando populares nos últimos anos e assumindo importantes funções nas tarefas cotidianas. Para Cook e Das (COOK; DAS, 2007) um ambiente inteligente adquire conhecimentos sobre o ambiente e os aplica, de forma a melhorar a experiência dos usuários na interação com o ambiente, personalizando sua experiência e adicionando níveis de controle, gerenciamento, conforto e segurança.

Em edifícios residenciais e comerciais, a combinação de automação com aprendizado de máquina leva ao conceito de edifícios inteligentes (*smart buildings*). O sensor de ocupação é particularmente importante nesse ambiente, devido à sua comunicação direta com os seres humanos, que resulta na extração de padrões de comportamento. Esses padrões têm grande importância na análise das necessidades dos usuários e podem auxiliar, por exemplo, em situações de emergência fornecendo suporte à decisão, além de integrar sistemas que permitem a economia de energia, de recursos e em sistema de segurança e controle de anomalias (SAHA et al., 2019).

A detecção de ocupação é um componente que integra os *smart buildings*, que ajustam suas configurações com base nas preferências e características dos ocupantes, produzindo uma interface homem-máquina fundamental devido ao tempo cada vez maior que os seres humanos passam em ambientes internos (SAHA et al., 2019).

Um exemplo de ambiente inteligente são os sistemas de gerenciamento de energia e conforto de edifícios, em inglês *Building Energy and Comfort Management* (BECM), usados em *smart buildings*. São sistemas de controle para edifícios que usam computadores e microprocessadores distribuídos para monitoramento, armazenamento de dados e comunicação com os usuários. São funções centrais em um sistema BECM o controle de aquecimento, ventilação e ar condicionado (AVAC), controle de iluminação e controle de eletricidade (LEVERMORE, 2000). Pelas características de fabricação e funcionamento, a maioria desses equipamentos de AVAC presumem uma ocupação máxima dos ambientes. Um sistema de ar condicionado, por exemplo, projetado para uma sala com capacidade de cem pessoas não adapta seu funcionamento se a sala estiver ocupada por dez pessoas, ou não tem a capacidade de detectar se a sala está ocupada a todo momento que o equipamento permanece ligado, gerando assim um gasto adicional de energia.

Prédios consomem cerca de 40% do total de energia produzida no mundo para manter os requisitos dos ocupantes por conforto e funcionalidades nos ambientes internos (CHEN; JIANG; XIE, 2018). Devido as crises energéticas, ao custo e a crescente consciência da necessidade de desenvolvimento de tecnologias sustentáveis, está cada vez mais frequente a procura por ferramentas que aumentem a eficiência energética de prédios. As informações de ocupação dos edifícios tem papel fundamental para o alcance desse objetivo (CHEN; JIANG; XIE, 2018).

Nesse sentido, estudos demonstraram o potencial da detecção de presença e/ou ocupação dos ambientes para um consumo mais consciente e eficiente de energia. Com a utilização de dados de sensores e algoritmos para detecção de presença é possível atingir uma economia anual de energia de até 42% nos sistemas de AVAC (ERICKSON; CARREIRA-PERPIÑÁN; CERPA, 2011). Uma investigação recente em prédios comerciais, mostrou uma grande variação no potencial de economia de energia, de 29% a 80% dependendo do perfil de utilização (BROOKS et al., 2014).

Além de ser uma ferramenta que comprovadamente aumenta a eficiência energética de prédios, o sistema de detecção de ocupação a partir de dados de sensores em ambientes inteligentes tem outras aplicações atuais, muito importantes no contexto do isolamento social que o mundo está atravessando devido a pandemia causada pelo Covid-19, como determinação e mapeamento do comportamento dos ocupantes para reconhecimento de padrões (RASHIDI; COOK, 2010), integração em sistemas para telemedicina com monitoramento, suporte e dispositivos de terapia (CHAN et al., 2008).

Algoritmos de várias naturezas foram reportados na literatura para a tarefa de detecção e classificação da ocupação de um ambiente a partir de dados de sensores, entre eles se destacam recentemente, pela flexibilidade e bom desempenho, as redes neurais artificiais (RNAs), uma estrutura de processamento maciça, que tem funcionamento baseado no cérebro humano (HAYKIN, 1999).

As redes neurais baseadas na teoria da ressonância adaptativa (*Adaptive Resonance Theory* – ART), são uma família de RNAs que performam uma aprendizagem estável com uma rápida convergência. Esse desempenho se dá por duas características principais muito importantes: a estabilidade (capacidade de absorver conhecimento por meio do ajuste de pesos) e a plasticidade (capacidade de continuar a aprender com a inclusão de novas entradas, sem perder ou corromper o conhecimento anterior).

A natureza estocástica do comportamento dos ocupantes em um prédio, combinada com as incertezas dos sensores, leva a uma área desafiadora de pesquisa que é atravessada por questões de preocupação com privacidade e dependência da tecnologia e recursos disponíveis (NGUYEN; AIELLO, 2013). Apesar dos sistemas disponíveis e dos muitos protótipos em construção, a tarefa de detecção de presença em ambientes ainda é um processo sujeito a várias variáveis, propenso a erros e caro em muitos casos (NGUYEN; AIELLO, 2013). Por esse motivo, investigações são necessárias para aumentar a eficiência das ferramentas utilizadas e tornar os protótipos viáveis em escala real e comercial.

Nesse sentido, este trabalho propõe a utilização de um algoritmo de detecção e classificação alternativo ao que vem sendo apresentado na literatura especializada. Será investigado o desempenho da RNA ARTMAP *Fuzzy* (CARPENTER et al., 1992) em detectar e classificar a presença de ocupantes em um ambiente, a partir de dados de sensores que medem parâmetros ambientais, aproveitando as características de rapidez,

consistência e confiabilidade das RNAs da família ART.

1.1 OBJETIVO DO TRABALHO

O objetivo deste trabalho é investigar o desempenho da rede neural ARTMAP *Fuzzy* (CARPENTER et al., 1992), como algoritmo de detecção e classificação da presença de ocupantes em ambientes inteligentes, utilizando dados de variáveis ambientais (níveis de CO_2 , luminosidade, temperatura e umidade) obtidas de sensores ambientais.

A proposta do trabalho é se valer das características de estabilidade e plasticidade da rede neural utilizada para atingir um desempenho satisfatório como algoritmo de detecção e classificação, testando a possibilidade e a viabilidade de aplicação em um sistema real.

1.2 ORGANIZAÇÃO DO TRABALHO

Este trabalho está organizado em sete capítulos, abordando trabalhos correlatos, detecção de ocupação em prédios inteligentes, RNAs e RNAs da Teoria da Ressonância Adaptativa, metodologia do trabalho, resultados e discussões e finalizando com as conclusões do estudo.

No capítulo 2 é feita uma revisão de trabalhos correlatos, que propuseram algoritmos de diferentes naturezas para sistemas de detecção de ocupação, com especial destaque nos modelos que utilizaram redes neurais artificiais.

O capítulo 3 apresenta uma contextualização, definições e teorias relacionadas ao tema de detecção de ocupação e ambientes inteligentes, e especificamente, prédios inteligentes. São abordados os equipamentos utilizados nos sistemas de detecção de ocupação, principais algoritmos apresentados na literatura para essa tarefa e forma de avaliação de desempenho dos algoritmos classificadores.

No capítulo 4 são descritos os principais conceitos da teoria da ressonância adaptativa, com enfoque na arquitetura e no algoritmo das redes neurais ART, que servem de base conceitual para a rede ARTMAP *Fuzzy* utilizada no desenvolvimento da metodologia proposta.

O capítulo 5 apresenta a metodologia de desenvolvimento do trabalho, com uma análise dos dados e variáveis utilizadas e apresentação dos procedimentos utilizados na escolha dos parâmetros e nos treinamento e testes da rede.

No capítulo 6 é apresentado os principais resultados obtidos, com análise das variáveis no modelo, efeito das normalizações no acerto da rede e avaliação de desempenho do algoritmo classificador em um sistema de detecção de ocupação.

O capítulo 7 apresenta as conclusões e as contribuições deste trabalho, com sugestões para trabalhos futuros.


E por fim, no Apêndice A é feita uma breve revisão dos principais conceitos acerca de redes neurais artificiais, apresentando o modelo neural artificial, principais tipos de estruturas e treinamentos utilizados em sistemas neurais artificiais.

2 TRABALHOS CORRELATOS

A detecção da ocupação de um ambiente tem se mostrado uma área ativa para pesquisas, principalmente nos últimos anos, e em constante evolução, devido a seus potencialmente significativos benefícios e o aumento da acessibilidade de tecnologias móveis e integradas em prédios e ambientes inteligentes.

Para enfatizar a relevância e atualidade do tema, a Figura 1 mostra a quantidade de trabalhos publicados na base de dados Scopus entre os anos 2000 e 2019. Para gerar esses resultados, foi feita uma busca por títulos e palavras-chaves dos termos em inglês “*occupancy detection*”, “*occupancy estimation*” e “*occupancy monitoring*”. A evolução das pesquisas no tema em quantidade, variedade e complexidade se acentua nos últimos anos, acompanhando as crescentes necessidades por tecnologias nessa área.

Figura 1 – Evolução dos trabalhos publicados nos últimos 20 anos



Fonte: Autoria própria.

O algoritmo classificador é parte fundamental nos sistemas de detecção de ocupação, uma vez que é a partir dele que se obtêm a resposta, o perfil de ocupação de um ambiente. Diversos algoritmos e técnicas foram propostos para a tarefa de detecção de ocupação. Como os algoritmos propostos na literatura são bem diversos, os trabalhos correlatos serão apresentados organizados em cinco grupos: modelos gráficos probabilísticos, modelos de aprendizagem clássicos e estatísticos, modelos baseados em *kernel*, mineração de dados e RNAs. Os trabalhos que utilizaram RNAs serão apresentados em maior quantidade e níveis de detalhes das contribuições, uma vez que o objeto de estudo é a aplicação de um tipo de RNA como algoritmo classificador em sistemas de detecção de ocupação.

2.1 MODELOS GRÁFICOS PROBABILÍSTICOS

Dados coletados de sensores ambientais, que mediam temperatura, umidade relativa, taxa de CO_2 e luminosidade foram utilizados no experimento de Candanedo e Feldheim (2016) (CANDANEDO; FELDHEIM, 2016) para prever a ocupação com uma metodologia baseada em *Hidden Markov Models* (HMM) (GHAHRAMANI, 2001), em português modelos ocultos de Markov. Os autores avaliaram a influência das diferentes variáveis ambientais na performance da detecção de ocupação, obtendo um desempenho que variou entre 32,68% e 99,33%, dependendo da combinação de variáveis usada. Pela grande variação dos resultados, destaca-se a importância da seleção apropriada das variáveis e do método de classificação. Os autores disponibilizaram o banco de dados gerado para mais investigações na comunidade científica e alguns trabalhos, que serão apresentados posteriormente, o utilizaram para testar aplicações em diferentes algoritmos de classificação.

Uma rede bayesiana (GHAHRAMANI, 2001) foi desenvolvida no estudo de Dodier (2006) (DODIER et al., 2006) para identificar a ocupação de um edifício com base nos dados gerados por uma rede de sensores ambientais. O objetivo principal do estudo foi inferir a distribuição de probabilidade para o número de ocupantes e sua localização no edifício usando medições históricas e atuais dos sensores.

Modelos de Markov não homogêneos (MOR; GARHWAL; KUMAR, 2020) foram utilizados no estudo de Chen, Xu e Soh (2015) (CHEN; XU; SOH, 2015) para modelar a ocupação regular em dois ambientes de natureza distintas: edifícios comerciais em zonas únicas de múltiplos ocupantes e em zonas múltiplas com múltiplos ocupantes. Modelos de Markov ocultos auto regressivos (MOR; GARHWAL; KUMAR, 2020) foram usados por Han, Gao e Fan (2012) (HAN; GAO; FAN, 2012) para modelar padrões de ocupação de edifícios e medir a qualidade do ambiente interno. Foram usados sensores ambientais para compor os dados de ocupação dos usuários e alcançou-se um desempenho de 80,78% nas classificações.

HMM foram utilizados para modelar as correlações ao longo do tempo entre variáveis ambientais e níveis de ocupação no estudo de Lam (2009) (LAM et al., 2009). A metodologia proposta alcançou uma performance de 80% na detecção de ocupação em um escritório de planta aberta.

2.2 MODELOS DE APRENDIZAGEM ESTATÍSTICOS

Uma árvore de decisão (KOTSIANTIS, 2013) foi utilizada como classificador por Hailemariam (2011) (HAILEMARIAM et al., 2011) para detecção de ocupação em tempo real de um posto de trabalho em um escritório. Foram usados vários tipos de sensores, incluindo o de movimento e os autores relataram desempenho máximo de 98,4% nas classificações. Os autores atentaram para o risco de sobreposição nas medidas dos sensores,

se vários tipos de sensores forem combinados sem seleção prévia adequada.

O algoritmo *K-nearest neighbors* (KNN) (COVER; HART, 1967), “*k-vizinhos mais próximos*”, é um algoritmo de funcionamento simples, baseado na distância, em outras palavras, na diferença ou similaridade de duas instâncias dentro de um conjunto de dados (JIANG et al., 2007). Uma abordagem utilizando KNN e dados de consumo de eletricidade foi utilizada por Akbar (2015) (AKBAR et al., 2015) para determinar informações de ocupação em um prédio. Os autores mostraram que utilizando somente dados de eletricidade, e nenhum outro dado obtido de sensores, puderam alcançar uma performance superior a 93,67% na classificação do estado de ocupação do ambiente monitorado.

Além de usarem HMM, no estudo de Candanedo e Feldheim (2016) (CANDANEDO; FELDHEIM, 2016) os autores também fizeram uso de outros algoritmos para testar a adequação e desempenho das diferentes abordagens nos dados dos sensores, sendo eles *Linear Discriminant Analysis* (LDA), *Random Forest* (RF) e *Classification and Regression Trees* (CART) (NGUYEN; AIELLO, 2013). Os melhores resultados foram obtidos com o uso dos três algoritmos combinados com diferentes tipos de sensores.

2.3 MODELOS BASEADOS EM *KERNEL*

Dados coletados de sensores de CO_2 foram utilizados por Zuraimi (2017) (ZURAIMI et al., 2017) para prever o número de ocupantes em um teatro, usando como classificador o algoritmo *Support Vector Machine* (SVM) (BOSER; GUYON; VAPNIK, 1992). Foi feita uma análise de validação cruzada para procurar os parâmetros ideais para um *kernel* da função de base radial (RBF), a fim de otimizar o desempenho do SVM. Os resultados mostraram uma performance de aproximadamente 76% na detecção de ocupação.

Foi simulado por Caliskan (2007) (CALISKAN et al., 2007) a ocupação de um estacionamento como um processo gaussiano retrógrado. Definiu-se um parâmetro que determinava o nível de ocupação esperado por veículo no cenário e a resposta do modelo era a porcentagem esperada de vagas ocupadas.

Uma abordagem com a utilização de SVM e doze variáveis obtidas de sensores ambientais para detecção do status da ocupação e número de ocupantes foi proposta por Yang (2014) (YANG et al., 2014). Os autores relataram um desempenho na detecção do *status* da ocupação entre 95,1% e 97,5%, enquanto o número de ocupantes foi estimado com um erro quadrático médio entre 0,141 e 1,192.

Foi proposta uma abordagem não intrusiva no estudo de Akbar (2015) (AKBAR et al., 2015) com base no reconhecimento de padrões de consumo em dados de eletricidade para detectar o status da ocupação. Esse trabalho apresenta uma comparação de desempenho do SVM com três diferentes núcleos (funções de base linear, polinomial e radial) para mostrar

a importância da seleção adequada da função do *kernel*. Os dados de eletricidade usados para validar essa abordagem foram coletados em um centro de pesquisa e os resultados variaram entre 55,37% e 79,12% de acertos na classificação.

Um sistema baseado em Wi-Fi foi proposto por Zou (2018) (ZOU et al., 2018) para estimar o número de ocupantes sem a necessidade de utilizar qualquer sensor ou outro tipo de hardware de monitoramento. O classificador para a detecção e contagem da ocupação foi baseado em SVM e fusão de informações. Resultados experimentais mostraram que o sistema obteve um desempenho de 92,8% na contagem de pessoas.

2.4 MINERAÇÃO DE DADOS

No estudo de Chen (2013) (CHEN et al., 2013) os autores exploram o monitoramento de ocupação não-intrusivo usando uma abordagem baseada em *cluster* (agrupamento), com três métricas coletadas de um medidor de eletricidade: potência média, desvio padrão e faixa de potência. A abordagem elimina a necessidade de dados de ocupação reais para comparação durante o treinamento, *i.e.*, treinamento não supervisionado.

Uma abordagem não supervisionada baseada em *clustering* também foi proposta por Nguyen, Zheng e Han (2013) (NGUYEN; ZHENG; HAN, 2013) para extrair a localização dos ocupantes em uma planta de laboratórios acadêmicos, rastreando seus telefones celulares conectados ao Wi-Fi. Resultados experimentais mostraram uma performance de 98% no rastreamento dos ocupantes no ambiente.

No estudo de D’oca e Hong (2015) (D’OCA; HONG, 2015) é proposto uma estrutura de mineração de dados para estabelecer o perfil de ocupação de um ambiente de trabalho, utilizando principalmente a indução de regras, *clustering* e métricas de distância. Os autores estabeleceram uma resposta de ocupação diária em um intervalo de dez minutos.

sectionREDES NEURAIIS ARTIFICIAIS

RNAs têm sido amplamente utilizadas como um algoritmo de aprendizado supervisionado em muitos campos, incluindo na detecção de informações de ocupação em edifícios e ambientes em gerais. Elas podem ser aplicadas de maneiras diversas, dependendo do objetivo final. Podem ser usadas como um classificador puro para detectar o *status* ou variação binária da ocupação, podem ser usados para prever a evolução da ocupação (posicionamento) em um ambiente ao longo do tempo (GOLESTAN; KAZEMIAN; AR-DAKANIAN, 2018) ou também para contagem e rastreamento de ocupantes (ZOU et al., 2015).

Utilizando uma RNA *Feedforward* (RNFF) com algoritmo de treinamento *backpropagation* (BP) (WERBOS, 1974) e medidas de CO_2 no ambiente como dados de entrada, foi estimado no estudo de Zuraimi (2017) (ZURAIMI et al., 2017) o número de ocupantes

em um teatro. A RNA obteve desempenho médio de 70% na contagem. No trabalho de Lam (2009) (LAM et al., 2009) também foi feita uma quantificação da ocupação com a mesma RNA e mesmo algoritmo de treinamento, dessa vez em um escritório de planta aberta. Os autores utilizaram para coleta de dados uma rede de múltiplos sensores ambientais, que medem CO_2 , compostos orgânicos voláteis totais (COVT), temperatura, umidade relativa, movimento e luminosidade. A performance média obtida com a metodologia usada foi de 75% na detecção do número de ocupantes. Um sistema com múltiplos sensores também foi utilizado por Yang (2012) (YANG et al., 2012a) para capturar dados de temperatura, umidade, concentração de CO_2 , luminosidade, som e movimento. O diferencial foi o uso da RNA de Base Radial (RBF) (BROOMHEAD; LOWE, 1988) como classificador. Testes de campo foram realizados e a melhor taxa de detecção foi de 87,62% das amostras, com tolerância de um ocupante.

No estudo de Yang (2012) (YANG et al., 2012b) foram utilizadas como entradas de uma RNFF várias combinações de dados coletadas de vários tipos de sensores para detecção de ocupação. Analisaram a efetividade de cada sensor e comparou-se o desempenho de uma RNA de única camada oculta com uma RNA de múltiplas camadas ocultas. Os resultados do teste relataram uma taxa de detecção entre 62,41% e 97,97%, sendo que os melhores resultados foram alcançados com três camadas escondidas.

Diferentes combinações de tipos de sensores e um medidor de carga elétrica foram os parâmetros de entrada para uma RNFF com uma camada escondida utilizados por Hobson (2019) (HOBSON et al., 2019) para estimar o número de ocupantes em uma sala de um prédio acadêmico, resultando em um acerto médio de 83% na contagem. Observaram que dispositivos Wi-Fi associados se mostram altamente benéficos a estimativa do número de ocupantes.

Redes neurais com atraso de tempo (RNAT) (WAIBEL, 1989) foram utilizadas por Rahman e Han (2017) (RAHMAN; HAN, 2017) para estimar o número de ocupantes em uma sala. O algoritmo foi testado sob diferentes condições de entrada, produzindo resultados com um coeficiente de variação entre 0,51% e 15,52%. Com o intuito de investigar as incertezas causadas pelos parâmetros da RNAT, foram simulados dados de níveis de CO_2 em um ambiente interno, correspondentes a vários horários de ocupação e padrões de fluxo de ar por Alam (2017) (ALAM et al., 2017). Os autores concluíram que a precisão da estimativa foi significativamente influenciada pela frequência de variação da ocupação e não pela flutuação na taxa do fluxo de ar.

Alguns estudos fizeram uso do banco de dados gerado por Candanedo e Feldheim (2016) (CANDANEDO; FELDHEIM, 2016) para a investigação da classificação de ocupação com diferentes metodologias e RNAs. Foram testados sete algoritmos para treinamento em uma RNFF no experimento de Tutuncu, Cataltas e Koklu (2016) (TUTUNCU; CATALTAS; KOKLU, 2016) e o melhor resultado foi alcançado pelo algoritmo *Limited Memory Quasi-*

Newton (PHUA; MING, 2003), que obteve um desempenho de 98,803% na classificação. Elkhouchi (2018) (ELKHOUKHI et al., 2018) aplicou algoritmos de Machine Learning e RNAs com variação de aprendizados *online* e *off-line*. A máxima performance alcançada foi 95% de classificações corretas. Para os mesmos dados, foram apresentados por Kraipeerapun e Amornsamankur (2017) (KRAIPEERAPUN; AMORNSAMANKUR, 2017) dois métodos para obter o status da ocupação. O primeiro foi uma combinação da técnica chamada *Stacked Generalization* (WOLPERT, 1992) com uma RNA multiclasse e o segundo aplicou a mesma técnica com uma RNA de saída dupla. Os resultados da validação mostraram um acerto entre 68,87% e 91,18%.

No estudo de Masood, Soh e Chang (2015) (MASOOD; SOH; CHANG, 2016) os autores propuseram o uso do modelo de seleção *wrapper* e *extreme learning machine* (ELM), máquina de aprendizado extremo em português, para examinar o número de ocupantes em uma sala por meio de dados de sensores ambientais, alcançando um desempenho entre 74,06% e 81,37%.

Uma abordagem com detecção e estimativa do número de ocupantes em tempo real usando somente medições de níveis de CO₂ no ambiente foi proposta por Jiang (2016) (JIANG et al., 2016) utilizando uma variação do ELM. Os dados experimentais usados para validar o algoritmo proposto foram coletados em um escritório com capacidade para 35 ocupantes e os resultados obtidos mostraram acerto de até 94%, com tolerância de quatro ocupantes.

Foi proposto um algoritmo para rastreamento da localização interna no experimento de Zou (2015) (ZOU et al., 2015) baseado em ELM sequencial online. Os autores realizaram experimentos em um laboratório (580 m²) e demonstraram que o algoritmo poderia rastrear a localização dos ocupantes com uma precisão de 1,973 metro.

Para melhor visualização e comparação entre as abordagens, objetivos e desempenhos, na Tabela 1 é apresentada uma visão geral dos trabalhos de detecção de ocupação utilizando RNAs revisados nesse capítulo.

Tabela 1 – Visão geral dos trabalhos de detecção de ocupação que utilizaram RNAs.

Tipo de RNA	Sensores	Ambiente	Resposta	Desempenho
RNFF	CO_2	Teatro	Contagem	70,00%
RNFF	CO_2 , T, U, L, M	Planta aberta	Contagem	75,00%
RBF	CO_2 , T, U, L, M, Som	Laboratórios	Contagem	87,62%
RNFF - 3 CE	CO_2 , T, U, L, M, Som	Laboratórios	Contagem	62,41% – 97,97%
RNFF	CO_2 , L, M, Wi-Fi, carga	Prédio acadêmico	Contagem	83,00%
RNAT	CO_2	Sala	Contagem	0,51% < CV > 15,52%
RNFF - QN	CO_2 , T, U, L	Laboratório	Presença	98,80%
RNFF	CO_2 , T, U, L*	Laboratório	Presença	68,87% – 91,18%
ELM	CO_2 , T, U, P*	Sala	Contagem e Rastreamento	74,06% – 91,18%
ELM	CO_2 , T, U, L	Sala	Contagem	94,00%
ELM	Wi-Fi	Laboratório	Rastreamento	1,973 m

RNFF: Rede Neural *Feedforward*. RBF: RNA de Base Radial. CE: camadas escondidas. RNAT: RNA com atraso de tempo. QN: algoritmo de treinamento *Limited Memory Quasi-Newton*. ELM: *extreme learning machine*. T: temperatura, U: umidade. L: luminosidade. M: movimento. P: pressão. *Estudos realizados com o mesmo banco de dados

Fonte: Autoria própria.

3 DETECÇÃO DE OCUPAÇÃO EM PRÉDIOS INTELIGENTES

Um ambiente inteligente adquire e aplica conhecimentos sobre o ambiente e seus usuários para melhorar a experiência e interação no ambiente (COOK; DAS, 2007). De acordo com os autores, um ambiente inteligente é composto por quatro camadas: componentes físicos, comunicação, informação e decisão. As camadas de um ambiente inteligente e seus componentes podem ser visualizados na Figura 2.


A automação em um ambiente inteligente pode ser vista como um ciclo de percepção sobre o estado do ambiente, raciocínio sobre o estado com tarefas objetivas e resultados de possíveis ações e atuação sobre o ambiente para mudar o estado (COOK; DAS, 2007). A percepção do ambiente é um processo feito de baixo para cima (camadas da Figura 2). Os sensores monitoram o ambiente usando componentes físicos e disponibilizam informações através da camada de comunicação. O banco de dados armazena essas informações enquanto outros componentes da camada de informações processam os dados brutos em conhecimentos mais úteis (por exemplo, modelar ações, padrões). Novas informações são apresentadas aos algoritmos de tomada de decisão (camada superior) mediante solicitação ou arranjo prévio. A execução da ação flui de cima para baixo. A ação de decisão é comunicada às camadas de serviços (informações e comunicação) que registram a ação e a comunicam aos componentes físicos. A camada física executa a ação com a ajuda de atuadores ou dispositivos de controle, alterando o estado do ambiente e desencadeando uma nova percepção (COOK; DAS, 2007).

Todos os conceitos que levam o nome de inteligente são baseados no processo cognitivo humano. Nesse sentido, é possível realizar um exercício de comparação com uma pessoa executando uma ação e o caminho percorrido para que ela ocorra com a definição de ambiente inteligente proposta por Cook e Das (2007) (COOK; DAS, 2007). Os componentes físicos representam os órgãos sensoriais humanos, os olhos e o tato, por exemplo, que captam informações do ambiente através de estímulos físicos ou químicos. Esses estímulos, na sequência, são transmitidos na forma de impulsos elétricos (representantes da camada de comunicação) até o sistema nervoso central. O sistema nervoso central, que representaria a camada de decisão, processa a informação, a traduz em sensação e gera uma resposta que percorre o sentido contrário até chegar nos órgãos externos que executarão a ação.

O conceito de ambiente inteligente pode ser aplicado a qualquer espaço ocupado com alguma finalidade, desde casas e prédios a hospitais, fábricas e escolas. Atualmente existem mais de trinta definições diferentes de inteligência relacionadas a prédios (NGUYEN; AIELLO, 2013). Para esclarecer a discussão, no contexto do presente texto entende-se prédio como uma palavra generalista para qualquer tipo de construção e finalidade, como casas, edifícios, prédios comerciais, institucionais e outros.

Duas das definições mais frequentemente aceitas são propostas pelo *Intelligent*

Figura 2 – Componentes de um ambiente inteligente



Fonte: Adaptado de Cook e Das (2007).

Building Institute (IBI) dos Estados Unidos da América e pelo *European Intelligent Building Group* (EIBG), com sede no Reino Unido. O IBI define um edifício inteligente como "aquele que fornece um ambiente produtivo e economicamente rentável através da otimização de seus quatro elementos básicos: sistemas, serviços, gerenciamento e as inter-relações entre eles" (WIGGINTON; HARRIS, 2002). A definição de edifício inteligente dada pelo EIBG é "aquele que cria um ambiente que maximiza a eficácia dos ocupantes do edifício, ao mesmo tempo em que permite o gerenciamento eficiente de recursos com custos mínimos de vida útil de hardware e instalações" (WIGGINTON; HARRIS, 2002). A definição do IBI se concentra mais no benefício dos proprietários e no ambiente interno desejado por eles, enquanto que o EIBG se concentra no benefício dos ocupantes e na criação do ambiente interno desejado por eles. Ambas as definições também chamam a atenção para o gerenciamento e o impacto ambiental e econômico.

Para fins de especificidade de definição, pode-se valer da estrutura proposta por (SO; WONG; WONG, 1999) onde um prédio inteligente é composto por 10 módulos (M1 a M10):

1. M1: Sustentabilidade do ambiente: uso consciente da energia;
2. M2: Utilização e flexibilidade do espaço;
3. M3: Economia eficiente: operações e manutenções com ênfase na eficiência econômica;
4. M4: Conforto humano;
5. M5: Eficiência no trabalho;
6. M6: Medidas de segurança: incêndios, terremotos, acidentes e problemas estruturais;
7. M7: Cultura;
8. M8: Imagem de alta tecnologia;
9. M9: Processo e estrutura de construção;
10. M10: Saúde.

Conhecer as informações dos perfis de ocupantes de um prédio através do sistema inteligente de detecção de ocupação resulta em estratégias de gerenciamento e decisões que integram quase a totalidade dos módulos, especialmente M1, M2, M3, M4, M6 e M10. O sistema ajusta suas configurações com base nas preferências e características dos ocupantes, produzindo uma interface homem-máquina que otimiza e personaliza a interação dos ocupantes com o ambiente (SAHA et al., 2019).

A detecção de ocupação possui várias aplicações práticas na vida cotidiana dos habitantes de um prédio inteligente. Uma das principais aplicações é a utilização da resposta do sistema de detecção no gerenciamento de energia em prédios. Os sistemas de gerenciamento de energia e conforto de edifícios, em inglês *Building Energy and Comfort Management* (BECM), são sistemas de controle em edifícios inteligentes que usam computadores e microprocessadores distribuídos para monitoramento, armazenamento de dados e comunicação. O objetivo principal de um sistema BECM é atender os requisitos de conforto dos ocupantes enquanto reduz o consumo de energia durante as operações realizadas. São funções centrais, em geral, em um sistema BECM o controle de aquecimento, ventilação e ar condicionado (AVAC), controle de iluminação e controle de eletricidade (LEVERMORE, 2000).

Os sistemas de detecção de ocupação também são úteis em situações de emergência, na qual conhecer a posição dos ocupantes e suas dinâmicas de movimento podem reduzir significativamente perdas de vidas e lesões (TOMASTIK; LIN; BANASZUK, 2008). Aplicações em tecnologias de assistência à saúde e telemedicina estão cada vez mais frequentes e incorporando tendências tecnológicas de várias naturezas ao conceito de home healthcare (CHAN et al., 2008). Outras aplicações comumente encontradas são nos sistemas de segurança, com a identificação de intrusos e atividades suspeitas.


O ponto de partida na análise de um sistema de detecção de ocupação é a presença do ocupante. O conceito de presença em três dimensões foi desenvolvido por (MELFI et al., 2011) e a Figura 3 apresenta um esquema visual que representa esse conceito. As três dimensões são física, espacial e temporal. O sentido das setas em cada dimensão indica o caminho de detalhamento das informações: à medida que as informações da ocupação no tempo e espaço vão sendo mais detalhadas, a precisão e conhecimento sobre o perfil da ocupação geral aumentam.

A detecção de ocupação preocupa-se em extrair informações dos ocupantes em ambientes dos mais variados perfis. O problema, em geral, abrange uma ampla variedade de subproblemas, cada um com suas próprias particularidades. Novos algoritmos são constantemente testados para essa tarefa, devido à variedade e particularidades dos diferentes cenários de aplicação. Os diferentes tipos de algoritmos podem ser agrupados em três categorias: algoritmos de detecção de presença, algoritmos de contagem e algoritmos de rastreamento (SAHA et al., 2019).

Os algoritmos de detecção de presença têm o objetivo de detectar se um ocupante está presente ou não em uma determinada área do prédio em tempo real (SAHA et al., 2019). Os algoritmos recebem os dados dos sensores por meio do sistema de comunicação e os transformam na informação do status binário da ocupação: ou determinado ocupante está presente ou não está.

Em geral não há grandes preocupações com a privacidade dos ocupantes na detecção

Figura 3 – Conceito de ocupação em três dimensões



Fonte: Adaptado de Melfi et al. (2011).

de presença, pois a maioria dos sistemas utilizam meios de coleta de dados não invasivos para o ocupante.

Os algoritmos classificadores alcançam uma taxa aceitável de acerto nas classificações para essa tarefa na literatura (CANDANEDO; FELDHEIM, 2016)(AKBAR et al., 2015)(TUTUNCU; CATALTAS; KOKLU, 2016)(ELKHOUKHI et al., 2018), mas há limitações de origem físicas e inerentes aos parâmetros do ambiente (discutidas na próxima seção) que conferem complexidade a tarefa e diminuem a eficiência dos sistemas de detecção. As variáveis de entrada para algoritmos de detecção de presença incluem principalmente parâmetros ambientais, de consumo de energia ou de movimento.

As informações da detecção de presença dão suporte a estratégias de conforto térmico e uso inteligente de energia, principalmente ajustando a temperatura dos ambientes

em operações contextuais com base nas demandas reais dos ocupantes. Podem ser utilizadas também nos sistemas de segurança e para planejamento da utilização dos espaços.

Nos algoritmos de contagem, como o próprio nome deixa claro, faz-se uma contagem em tempo real do número de ocupantes presentes em um determinado espaço ou região específica do prédio (SUN; ZHAO; ZOU, 2020). Normalmente, os dados são coletados de vários tipos de sensores, principalmente de CO_2 , e são combinados para produzir estimativas do número de ocupantes.

Podem ser utilizados algoritmos supervisionados ou não supervisionados para a contagem da ocupação. Com o uso dos algoritmos supervisionados, faz-se necessária uma variável de ocupação real medida, ou pode ser feita uma estimativa com alguma técnica adequada. Como os perfis de ocupação dos ambientes podem variar muito e serem imprevisíveis, a qualidade da estimativa do número real de ocupantes pode ser muito variável também (NGUYEN; AIELLO, 2013).

A resposta dos algoritmos de contagem, em geral, também resulta em estratégias de conforto térmico e uso inteligente de energia nos ambientes, criando uma utilização contextual dos recursos. Pode-se utilizar, por exemplo, uma estratégia de acionamento gradual dos aparelhos de ar condicionado em um prédio conhecendo a quantificação da ocupação em determinado ambiente. O uso contextual baseado no número de ocupantes pode resultar em economias significativas de energia, de 30 % a 40% (BROOKS et al., 2014) segundo dados experimentais. Outras aplicações práticas do sistema de contagem da ocupação envolvem a contagem de pessoas em um shopping center (BEYMER, 2000), em um teatro (ZURAIMI et al., 2017) e o número de pessoas em prédios de escritórios (ERICKSON; CARREIRA-PERPIÑÁN; CERPA, 2011).

Os algoritmos de rastreamento se baseiam em inferir o histórico de movimentos (trajetória) de um ocupante em particular dentro de um ambiente (SAHA et al., 2019). Esse processo inclui a determinação da localização e pode incluir a detecção da identidade do ocupante. Com o objetivo de prever os futuros padrões de ocupações, nessa classe de algoritmos também se utiliza algoritmos de previsão e simulação.

As tecnologias para levantamento de todas as informações necessárias para esse sistema, são, de maneira geral, consulta ao ponto de acesso da rede Wi-Fi (ZOU et al., 2015), monitoramento visual com câmeras (LI; LIU; TAN, 2019) e localização pelos smartphones dos ocupantes (ZOU et al., 2018).

As ações de rastreamento, localização e identificação conferem a essa classe de algoritmos muitas questões relacionadas a privacidade dos ocupantes. O sistema de detecção deterá, considerando que a tecnologia de coleta de dados utilizada permita, todas as informações de movimentações temporais e espaciais de todos os ocupantes do prédio.

Em contrapartida, por conterem informações de ocupação mais completas e co-

nhecerem o perfil geral de ocupação do ambiente, os algoritmos de rastreamento são os que resultam no maior número de aplicações e estratégias úteis para a vida diária dos ocupantes. O rastreamento, por exemplo, é o único tipo de algoritmo que pode planejar uma estratégia de evacuação em caso de algum incidente. Com informações de localização e identificação, as condições internas de conforto térmico podem ser personalizadas e gerenciadas para um grande número de pessoas.

3.1 SENSORES E EQUIPAMENTOS

Nessa seção será apresentada uma visão abrangente das principais tecnologias utilizadas na literatura para a coleta de dados do ambiente e/ou dos usuários para detecção de ocupação. Serão discutidos os principais usos, características, vantagens e limitações de cada ferramenta.


A dimensão da tecnologia, os hardwares utilizados nos sistemas de detecção podem ser classificados de acordo com a necessidade de usar um terminal ou não (LEE; HA; LEE, 2006). No caso dos métodos que requerem um terminal, é necessário que os ocupantes se conectem a dispositivos com transmissores sem fio incorporados que suportam diferentes tecnologias de comunicação, como Identificação por radiofrequência (RFID), Wi-Fi, Bluetooth e GPS (*Global Positioning System*), disponíveis em dispositivos vestíveis (*wearables*) e *smartphones*. Nos métodos não terminais, a detecção é com base em uma abordagem passiva focada no monitoramento do ambiente, usando, por exemplo, câmeras para monitoramento visual ou infravermelho, sensores e medidores inteligentes para consumo de energia.

A Figura 4 é um esquema representativo do sistema de detecção de ocupação em todas as camadas, com exemplos de aplicações de parâmetros medidos, tecnologia de coleta de dados, classes de algoritmos utilizados e camada de tomada de decisão com a resposta da ocupação.

3.1.1 Sensores PIR

Um sensor PIR (*Passive Infrared*) é um dispositivo eletrônico capaz de detectar radiações a um comprimento de onda de cerca de 10 micrômetros (o pico do comprimento de onda da energia térmica emitida por humanos, em forma de radiação infravermelha). O termo passivo significa que o sensor não usa nenhum tipo de energia na detecção, ele funciona detectando a energia emitida por outros objetos. Seu funcionamento é baseado na utilização de um transdutor piezoelétrico, que detecta radiação infravermelha e a converte em um sinal de tensão (BENYA et al., 2003).

Devido à facilidade de implementação e custo-benefício (RAYKOV et al., 2016), os sensores PIR são dispositivos muito utilizados nos sistemas de detecção de ocupação.

Figura 4 – Visão geral das principais etapas de um sistema generalista de detecção de ocupação

Fonte: Autoria própria.

Os ocupantes de um ambiente, ao se movimentarem, provocam alterações na radiação infravermelha e os sensores PIR detectam o movimento e por consequência, a presença de ocupantes. Também podem ser utilizados para estimar o número de ocupantes, mas é necessária uma metodologia para transformar os padrões de movimento extraídos dos dados brutos em um modelo de estimativa de ocupação. Um exemplo é o uso da regressão estatística em (WAHL; MILENKOVIC; AMFT, 2012).

De um modo geral, os sensores PIR têm as vantagens de baixo custo, baixo custo computacional, baixo consumo de energia, alta confiabilidade e precisão nas medidas e facilidade de serem implantados nos ambientes (CHEN; JIANG; XIE, 2018). No entanto, uma limitação do sensor PIR é a necessidade de movimento para detectar os ocupantes, o que significa que, para ocupantes estáticos não é um equipamento adequado. Somente pode fornecer informações binárias (ocupado ou desocupado) e o ruído inerente precisa ser filtrado. Distâncias diferentes entre os sensores PIR e as pessoas resultarão em uma precisão diferente (SUN; ZHAO; ZOU, 2020).

Outra limitação desse tipo de sensor é que ele é mais suscetível a “falsos negativos”. Esse tipo de erro geralmente ocorre pelas características de funcionamento do sensor PIR. Por ser um dispositivo *line-of-sight*, “linha de visão” em português, não consegue

“enxergar” nos cantos e um ocupante não será detectado se houver uma obstrução entre ele e o dispositivo na linha de visão. Além disso, um sensor PIR não é capaz de detectar várias pessoas ao mesmo tempo na linha de visão (AHMAD et al., 2018).

3.1.2 Medidor inteligente de energia

O consumo de energia elétrica em prédios é capaz de refletir as interações entre os ocupantes de áreas internas e os aparelhos utilizados (CHEN; JIANG; XIE, 2018). Portanto, informações de ocupação de edifícios podem ser inferidas a partir de dados de consumo de energia, que podem ser medidos pelos medidores inteligentes (*smart meters*). No entanto, a relação entre dados de ocupação e consumo de energia não é direta e, às vezes, muito difícil de modelar. As abordagens de aprendizado de máquina são uma boa opção para essa modelagem. Ao analisar as alterações das métricas estatísticas dos dados de potência, eles podem detectar os eventos de presença de ocupação (CHEN et al., 2013).

Os dados brutos do consumo de eletricidade não são indicativos diretos e suficientes da presença e ausência de ocupação, mas são derivados de algumas características mais representativas. O uso de algoritmos de detecção que se baseiem exclusivamente em características do conjunto de dados, como o KNN podem levar a bons resultados (AKBAR et al., 2015).

Como demonstrado em (KLEIMINGER et al., 2013), uma resposta de detecção do status da ocupação pode ser obtida utilizando somente dados do consumo de eletricidade, sem a necessidade de outros sensores adicionais, com uma taxa de acerto média de 80% na maioria dos cenários.

Em um sistema de detecção de ocupação que usa somente medidores inteligentes, não há necessidade de utilizar outros sensores mais caros e complexos para obter um bom desempenho na detecção. Outras vantagens são o aproveitamento da infraestrutura prévia dos prédios inteligentes para a coleta dos dados de ocupação e a não existência de problemas de privacidade (CHEN; JIANG; XIE, 2018).

Com o uso exclusivo de medidores inteligentes para detecção de ocupação surgem algumas limitações, como a possibilidade de detectar somente o status binário da ocupação, não sendo possível realizar quantificação ou localização (SUN; ZHAO; ZOU, 2020). Pelo fato de não haver medidas de outros parâmetros dos ocupantes ou do ambiente, se na amostra existirem ocupantes que não estão conectados à aparelhos que utilizem energia elétrica, não será possível detectá-los e o sistema de detecção apresentará um erro maior.

3.1.3 Sensores ambientais

Sensores ambientais são sensores que medem parâmetros do ambiente. Os principais parâmetros medidos são dióxido de carbono (CO_2), temperatura, umidade e luminosidade.

Esses sensores estão amplamente disponíveis nos sistemas de construção de edifícios inteligentes, principalmente no sistema de AVAC (NGUYEN; AIELLO, 2013). Sensores ambientais podem ser utilizados em ambientes internos e externos. Como os ocupantes influenciam e modificam diretamente os ambientes internos nos parâmetros medidos pelos sensores, os dados provenientes das leituras dos sensores podem ser bons indicadores para detectar a ocupação de um edifício.

Muitos estudos foram feitos na literatura com a utilização de múltiplos sensores ambientais nos sistemas de detecção de ocupação. Entre todos os sensores ambientais, o de CO_2 (geralmente medido em p.p.m.) demonstrou maior eficácia para detectar o status e quantificação da ocupação (CANDANEDO; FELDHEIM, 2016) (MASOOD; SOH; CHANG, 2016), sendo o parâmetro mais significativo na resposta da ocupação, quando analisado isoladamente. Alguns pesquisadores aplicaram apenas os dados medidos de CO_2 no ambiente para estimativa e detecção da ocupação e obtiveram desempenho satisfatório (JIANG et al., 2016) (ZURAIMI et al., 2017)(RAHMAN; HAN, 2017).

Como o CO_2 é produto da respiração humana, as concentrações internas do gás estão diretamente relacionadas ao número de ocupantes e ao nível de ventilação em um ambiente (DONG; ANDREWS, 2009). Mas essa relação não é simples de ser medida, há uma complexidade na concentração interna de CO_2 , que é influenciada por fatores como: características inerentes de propagação do CO_2 no ar, diferentes taxas de respiração por ocupante e níveis de atividade, influência do número de ocupantes, posicionamento dos sensores, influência da abertura de janelas e portas.

Devido à essa alta complexidade, uma modelagem explícita das concentrações de CO_2 em termos do número de ocupantes se torna difícil e imprecisa. Uma solução alternativa é usar abordagens orientadas a dados que modelem diretamente o relacionamento entre entradas e saídas usando alguns algoritmos gerais, como algoritmos de aprendizado de máquina e RNAs (CHEN; JIANG; XIE, 2018).

A principal limitação da estimativa e detecção da ocupação usando exclusivamente concentrações de CO_2 é que os resultados da estimativa estão sempre com um atraso de tempo em relação à ocupação real do edifício devido à lenta taxa de mistura de gases no ambiente, ou seja, uma lenta propagação do CO_2 no ambiente. O tempo de atraso depende da taxa de mudança do ar, e apresenta maiores taxas de erro à medida que mais pessoas circulam no ambiente. Outras desvantagens são aberturas imprevisíveis de janelas e portas e circulação imprevisível de pessoas (SUN; ZHAO; ZOU, 2020).

As principais vantagens do uso de sensores de CO_2 para um sistema de detecção de ocupação são o baixo custo dos equipamentos e a inexistência de problemas de privacidade, por ser uma tecnologia não invasiva. Os sensores de CO_2 podem ser utilizados tanto para determinar o status da ocupação quanto para estimar o número de ocupantes em um ambiente. Porém para estimar o número de ocupantes e localização interna, a precisão se

torna muito baixa, pelas características anteriormente mencionadas.

Os outros sensores ambientais mais utilizados nos sistemas de detecção propostos, temperatura, umidade e luminosidade, também possuem algumas características e limitações da mesma natureza do CO_2 .

A umidade é um parâmetro que está relacionado com os níveis de CO_2 no ar, já que a água também é um produto na respiração humana. Em um ambiente interno, a umidade relativa (medida em % de presença no ar) varia muito pouco (DONG; ANDREWS, 2009) e a medição pelos sensores de umidade também é prejudicada pela abertura de portas e janelas, pois acontece uma mistura com o ar externo. O posicionamento dos sensores de umidade também acarreta variações na medição.

Em um ambiente interno sem aberturas externas, as flutuações de temperatura causadas pela presença humana individual são mínimas ou variam lentamente com o tempo. Grandes variações na temperatura ($1^\circ C$) em um curto intervalo de tempo (10 minutos) são provavelmente associadas a atividades que liberam maiores quantidades de energia, como um grande grupo de pessoas e inicialização do sistema AVAC (DONG; ANDREWS, 2009). Os sensores de temperatura, dependendo da precisão, podem não ser capazes de captar essas pequenas variações.

A luminosidade é o parâmetro que apresenta menor variabilidade na medição dos sensores ambientais e não apresenta grande parte das limitações dos outros sensores. As mudanças bruscas nas medidas do sensor de luminosidade (medido em Lux), como diminuição e aumento acentuado representam o momento em que as luzes do ambiente são desligadas e ligadas, respectivamente. Alterações nas medidas do sensor de luminosidade podem acontecer nos horários de maior incidência dos raios solares, em ambientes que permitam a passagem da luz do sol.

Além dos sensores de CO_2 , temperatura, umidade e luminosidade, também são utilizados na literatura como sensores ambientais os parâmetros de pressão e movimento. Para alcançar desempenhos satisfatórios na detecção de ocupação com muitos sensores ambientais é necessário que sejam feitas seleções apropriadas dos parâmetros de entrada e dos algoritmos de aprendizado (CANDANEDO; FELDHEIM, 2016).

Os sensores ambientais, de maneira geral, podem ser usados para determinar o status da ocupação, mas para fazer a contagem dos ocupantes não são muito indicados. Os dados sensoriais brutos de múltiplos sensores ambientais contêm ruídos e não são representativos e suficientes para realizar a estimativa da ocupação de um ambiente.

Como principais vantagens dos sensores ambientais, pode-se elencar de maneira geral, sua ampla disponibilidade, baixo custo e a inexistência de problemas de privacidade. Em contrapartida, as principais limitações, em geral, são desempenho limitado dependendo da configuração do ambiente e atraso nas medidas.

3.1.4 Câmeras

O método baseado em imagens/vídeos tornou-se um tópico popular de pesquisa na ocupação de edifícios devido à alta precisão, quando comparado com outras tecnologias de detecção. O método baseado na visualização utiliza a tecnologia de visão computacional através de câmeras para processar imagens, obtendo informações de ocupação que incluem presença, número de ocupantes, trajetória, identidade e localização (TSAKANIKAS; DAGIUKLAS, 2018).

As câmeras podem ser classificadas de acordo com o tipo de informação derivada da imagem. Podem ser divididas, de maneira geral, em câmeras sem profundidade e câmeras com profundidade. Nas câmeras sem profundidade, as imagens RGB (*Red, Green, Blue*) ou imagens infravermelhas podem ser coletados para determinação visual do status e estimativa da ocupação, enquanto que nas câmeras com profundidade, além das imagens RGB podem ser coletadas também informações de profundidade. As câmeras de profundidade calculam a distância da câmera aos objetos no campo de visão da câmera, e o valor de *pixel* das imagens em profundidade representa essa distância, podendo calcular também localização e trajetória dos ocupantes (LI; LIU; TAN, 2019).

As câmeras também podem ser classificadas dependendo dos locais instalados. Geralmente essa classificação é feita em câmeras localizadas na entrada do ambiente (geralmente na parte superior da porta) e no interior do ambiente (TSAKANIKAS; DAGIUKLAS, 2018). Em aplicações reais, esses dois tipos de câmeras podem operar independentemente ou juntos. Na câmera da entrada é utilizada a visão aérea para detectar e reconhecer informações de movimentação dos ocupantes. Das câmeras do interior do ambiente, são utilizadas as imagens ou vídeos com uma visão geral do espaço (SUN; ZHAO; ZOU, 2020).

Então, com base em diferentes câmeras e em diferentes locais instalados, existem quatro situações de monitoramento visual: câmeras sem profundidade na entrada (superior); câmeras sem profundidade no interior; câmeras com profundidade na entrada (superior) e câmeras com profundidade no interior. Essas quatro situações também podem ser usadas em conjunto ou individualmente, dependendo dos objetivos requeridos pelo sistema de detecção (SUN; ZHAO; ZOU, 2020).

Utilizando imagens da câmera da entrada ou do interior com algum algoritmo de contagem, ou mesmo com trabalho manual, pode-se obter o status e quantificação real do ambiente, construindo assim a variável de ocupação real, necessária para algoritmos supervisionados. Essa abordagem foi utilizada nos experimentos de (CANDANEDO; FELDHEIM, 2016)(MASOOD; SOH; CHANG, 2016)(JIANG et al., 2016)(MASOOD; SOH; JIANG, 2017) .

A principal vantagem na detecção utilizando câmeras é que essa tecnologia pode

fornecer resultados mais precisos quando comparada as outras abordagens. Além disso, com o desenvolvimento do sistema de vigilância e segurança, muitos prédios já possuem câmeras instaladas. Dessa forma, o sistema de detecção pode aproveitar a estrutura preexistente. Utilizando em conjunto câmeras de profundidade o desempenho do sistema pode ser melhorado. No entanto, o custo deve ser considerado, porque os sistemas de vigilância predial existentes não são equipados com câmeras de profundidade (SUN; ZHAO; ZOU, 2020).

As limitações no uso de câmeras no sistema de detecção de ocupação incluem alta complexidade computacional, sérios problemas de invasão de privacidade, baixa qualidade de imagem das câmeras de vigilância e influência das condições de iluminação.

3.1.5 Wi-Fi

Devido à ampla disponibilidade de sinais de Wi-Fi em ambientes internos, o uso da tecnologia Wi-Fi em sistemas de detecção de ocupação pode ser promissor. Com o estado atual da tecnologia de dispositivos móveis, sua disponibilidade, flexibilidade e aplicações, podemos inferir que a maioria dos ocupantes de um ambiente tenha um smartphone. Assim, o número de smartphones pode ser tratado como um possível indicador do número de ocupantes em um determinado espaço.

Algumas abordagens de sistemas de detecção de ocupação utilizando somente a infraestrutura Wi-Fi existente foram propostas. As metodologias variaram em verificar as informações individuais dos dispositivos, buscar no ponto de acesso conectado com informações de metadados e padrões de ocupação, utilizar técnicas de localização internas baseada em Wi-Fi e outras técnicas mais específicas (ZOU et al., 2018)(NGUYEN; ZHENG; HAN, 2013)(ZOU et al., 2015). Em todos esses estudos, é necessário assumir que cada ocupante carregaria um smartphone com Wi-Fi ativado.

Uma grande vantagem dos sistemas baseados em Wi-Fi é que os sinais da rede estão amplamente disponíveis em ambientes internos e os métodos de coleta de dados dos ocupantes resultam em ótimas taxas de acerto na detecção, contagem ou localização (CHEN; JIANG; XIE, 2018). Em contrapartida, existem limitações óbvias dos sistemas baseados em Wi-Fi: os ocupantes podem ter vários smartphones ou nenhum, podem estar com o Wi-Fi desativado, a bateria do dispositivo pode acabar e passíveis de falhas que interrompam o funcionamento. Não se pode garantir disponibilidade total dos smartphones pessoais para a coleta de dados.

3.1.6 Fusão de sensores

Em sistemas reais, dados provenientes de apenas um tipo de tecnologia de coleta dificilmente alcançará confiabilidade suficiente na detecção da ocupação. Como cada tipo

de sensor possui vantagens e limitações exclusivas, a técnica de fusão de sensores pode aumentar o desempenho da detecção, na maioria dos casos, aproveitando as vantagens de cada tecnologia e contornando suas limitações (CHEN; JIANG; XIE, 2018).

A estratégia de fusão de sensores coleta e funde dados de diferentes naturezas. Pela variedade e volume de dados de entrada do sistema, é necessário utilizar uma técnica apropriada de seleção de variáveis para obter informações de ocupação mais precisas. Uma técnica utilizada atualmente na literatura para avaliar a contribuição dos dados de cada sensor é a teoria do ganho de informação (*information gain theory*) (YANG et al., 2014).

Uma comparação entre as tecnologias de sensores com base em alguns critérios de avaliação está apresentada na Tabela 2. Os critérios de comparação são: tipos de detecção realizados, custo, problemas de privacidade, vantagens e limitações. Esses critérios de avaliação são de grande importância para uma análise da aplicação das tecnologias de sensores em sistemas reais com necessidades específicas e/ou recursos limitados.

Tabela 2 – Visão geral e comparativa dos tipos de sensores mais comuns em sistemas de detecção de ocupação.

Tecnologia	Informação de ocupação			Custo	Problemas de privacidade	Vantagens	Limitações
	Presença	Contagem	Rastreamento				
PIR	Sim	Não	Não	Baixo	Não	Baixo custo computacional	Não captura ocupantes estáticos.
<i>Smart meter</i>	Sim	Não	Não	Médio	Parcial	Infraestrutura existente	Ignora ocupantes, desconectados à energia.
Sensores ambientais	Sim	Sim	Não	Médio	Não	Baixo custo, não invasivo	Tempo de atraso, sensível ao ambiente.
Câmera	Sim	Sim	Sim	Alto	Sim	Disponibilidade	Problemas de privacidade e alto custo computacional.
Wi-Fi	Sim	Sim	Sim	Médio	Sim	Alta precisão	Múltiplos <i>smartphones</i> ocupantes desconectados.

Fonte: Autoria própria.

Se em uma aplicação o custo for o principal critério levado em consideração para a construção do sistema de detecção, devem ser selecionadas tecnologias que aproveitem a infraestrutura preexistente, como câmeras, smart meter e Wi-Fi. Se o principal critério a se considerar for a privacidade dos ocupantes, podem ser utilizados sensores ambientais, smart meter e sensores PIR. No primeiro exemplo, as limitações do sistema seriam questões de privacidade dos ocupantes e no segundo seriam limitações no desempenho dos sensores pelo tempo de atraso dos sensores ambientais e dificuldades do PIR com ocupantes estáticos.

Quanto a tendências futuras em tecnologias na detecção de ocupação, o desenvolvimento da rede móvel de quinta geração (5G) em conjunto com a plataforma de armazenamento de dados em nuvem e a inteligência artificial são tecnologias promissoras. O 5G trará maior largura de banda, proporcionando taxas maiores de transmissões de dados dos sensores, aumento a velocidade de resposta dos sistemas de detecção e reduzindo a complexidade da rede (QAMAR et al., 2019).

3.2 PRINCIPAIS ALGORITMOS

Nessa seção será feita uma breve apresentação e classificação das principais classes de algoritmos utilizadas com maior frequência na literatura na tarefa de detecção de ocupação. Ao final da apresentação será feita uma comparação dos modelos.

A partir do levantamento bibliográfico feito e apresentado em parte no capítulo 2, podemos classificar os algoritmos para detecção de ocupação em: modelos de aprendizagem estatísticos, modelos baseados em *kernel*, modelos gráficos probabilísticos, RNAs e mineração de dados.

Os modelos de aprendizagem estatísticos se referem a um grande conjunto de ferramentas para análise de dados baseado em componentes estatísticos. O aprendizado estatístico pode ser supervisionado e não supervisionado. Em termos gerais, o aprendizado estatístico supervisionado envolve a construção de um modelo para prever ou estimar uma saída baseando-se em uma ou mais entradas. No aprendizado estatístico não supervisionado não há uma saída para comparação, mas com as ferramentas estatísticas pode-se encontrar as estruturas de relações entre os dados (GARETH et al., 2013). Os algoritmos dessa classe mais populares na literatura foram *K-nearest neighbors* (KNN), *Linear Discriminant Analysis* (LDA), *Random Forest* (RF) e *Classification and Regression Trees* (CART).

Nos modelos gráficos probabilísticos busca-se aprender uma estrutura específica de dependência condicional entre as variáveis, que são os dados coletados dos sensores. A construção do modelo geralmente consiste em duas partes: encontrar a estrutura de dependências das variáveis, que é um passo essencial nas redes bayesianas e encontrar as distribuições de probabilidade condicionais para as variáveis conectadas no gráfico. Este é um passo essencial em quase todos os tipos de modelos gráficos e é frequentemente

usado para calcular a probabilidade de um espaço ser ocupado, dadas as probabilidades de outros sensores detectarem um evento (SAHA et al., 2019). Essa classe de algoritmos também é comumente encontrada na detecção e contagem de ocupação usando a fusão de informações de redes de sensores, principalmente o HMM e suas variações e a rede Bayesiana.

Modelos baseados em *kernel* foram desenvolvidos para modelar relações não lineares entre variáveis independentes e dependentes. Nessa perspectiva, os dados originais do espaço de entrada são transformados de forma a aumentar a sua dimensão (aumentando o grau de polinômios, por exemplo), por uma função de mapeamento, ϕ . Essa transformação deve ser realizada com cuidado para oferecer um modelo linear confiável que corresponda a uma solução não linear no espaço de dados original (SCH et al., 1999). Um kernel é uma função que pode ser interpretada como a distância ou similaridade entre dois pontos e a matriz de covariância resume as medidas de similaridade entre pares de observações. Como a construção do modelo é executada com base na matriz de covariância e não com base nos dados inicial, aproveita-se a vantagem de reduzir a complexidade computacional (SCH et al., 1999). Os *kernels* mais típicos incluem funções de base polinomial e radial (RBF). Os algoritmos baseados em *kernel* utilizados com maior frequência na literatura de detecção de ocupação são SVM e processos gaussianos (BOSER; GUYON; VAPNIK, 1992).

A mineração de dados (*data mining*) pode ser entendida como a aplicação de algoritmos específicos para extração de padrões em dados. Suas seis principais funções são: classificação, regressão, agrupamento (*cluster*), modelagem de dependências (ou regras de associação), detecção de anomalias e sumarização (FAYYAD; PIATETSKY-SHAPIRO; SMYTH, 1996). Na literatura de detecção de ocupação são utilizados principalmente os algoritmos de agrupamento e classificação de regras de associação.

No capítulo 2 foi apresentada uma visão geral dos estudos na área de detecção de ocupação que utilizaram RNAs como algoritmos classificadores, que está condensada na Tabela 3. A apresentação e discussão formal de RNAs será feita no Apêndice A.

Uma avaliação comparativa dos métodos com base nos requisitos de dados, custo computacional, pré-processamento de dados, flexibilidade do modelo, robustez às variações nas condições de teste e aplicativos existentes, respectivamente, está apresentada na Tabela 3. Os critérios receberam “pesos” baixo, médio ou alto, exceto no critério aplicações onde os “pesos” de avaliação foram poucas, algumas ou muitas.

Tabela 3 – Avaliação comparativa entre os algoritmos utilizados

Classificação	Requisito de dados	Pré-processamento de dados	Flexibilidade	Robustez	Aplicações existentes
Modelos gráficos probabilísticos	Médio	Médio	Média	Alta	Muitas
Baseados em <i>kernel</i>	Médio	Médio - Alto	Baixa - Média	Média	Muitas
Aprendizagem estatística	Baixo - Médio	Médio	Média	Alta	Algumas
Mineração de dados	Médio - Alto	Média - Alta	Baixa - Média	Muitas	Muitas
RNAs	Alto	Baixo - Médio	Alta	Média	Muitas

Fonte: Autoria própria.

3.3 AVALIAÇÃO DE DESEMPENHO

Uma vez que um algoritmo tenha sido aplicado para produzir resultados, o desempenho nos dados de teste deve ser calculado tendo como base uma metodologia de avaliação adequada. As métricas de desempenho comumente usadas na literatura para sistema de detecção do status binário da ocupação são taxa de acerto, acurácia e taxa de erros. Na classificação da presença, ou status da ocupação, há duas classes possíveis, verdadeira (ocupado) e falsa (desocupado), então não são necessárias métricas com maiores níveis de detalhamento do desempenho de cada classe.

A taxa de acerto é comumente definida de maneira direta como o número de instâncias estimadas corretamente (NA) dividido pelo número total de instâncias (N).

$$Taxa\ de\ acerto = \frac{NA}{N} \quad (1)$$

A acurácia mede a porcentagem das entradas que foram corretamente classificadas (2), e a taxa de erros mede a porcentagem das entradas que foram incorretamente classificadas (3). TP (*true positive*) e TN (*true negative*) representam a classificação correta das entradas que pertencerem a classe positiva (ocupado) e negativa (não ocupado), respectivamente. FP (*false positive*) e FN (*false negative*) representam a classificação incorreta das entradas que não pertencem a classe positiva e negativa, respectivamente (POWERS; AILAB, 2007).

$$Acurácia = \frac{TP + TN}{N} 100 \quad (2)$$

$$Taxa\ de\ erros = 1 - Acurácia \quad (3)$$

O Recall (4) quantifica a proporção de positivos identificados corretamente, em outras palavras, mostra o desempenho do modelo em prever positivos, sendo positivo entendido como a classe que se quer prever. A precisão (5), por sua vez, quantifica qual proporção de identificações positivas foi realmente correta.

$$Recall = \frac{TP}{TP + FN} \quad (4)$$

$$Precisão = \frac{TP}{TP + FP} \quad (5)$$

A matriz de confusão é uma ferramenta muito utilizada na análise de desempenho de classificadores, mostrando as frequências de classificação para cada classe do modelo: TP, FP, TN e FN ((POWERS; AILAB, 2007)).

Tabela 4 – Matriz de confusão.

Classes	Positivo	Negativo
Positivo	TP	FP
Negativo	FN	TN

O F-score é uma medida de desempenho de um modelo em um conjunto de dados, usado para avaliar sistemas de classificação binários. É definido como a média harmônica entre a precisão e o *recall* ((POWERS; AILAB, 2007)).

$$F - score = \frac{TP}{TP + \frac{1}{2}(FP + FN)} \quad (6)$$

Para avaliar um classificador, é necessário verificar sua precisão em processar dados desconhecidos. Os classificadores podem ter alta precisão quando são testados com o conjunto de dados de treinamento, mas podem ter precisão menor com um novo conjunto de dados. Portanto, recomenda-se dividir os dados em um conjunto para treinamento e em um conjunto para teste. Em problemas de classificação, os dados podem ser divididos em três partes: treinamento (para treinar o algoritmo classificador), validação cruzada (para ajustar os parâmetros) e teste (para verificar o desempenho do classificador) (BISHOP, 2007).

4 TEORIA DA RESSONÂNCIA ADAPTATIVA

No aprendizado de uma RNA a capacidade de adquirir e armazenar conhecimento de forma estável sem corrompê-lo com a apresentação e aprendizagem de novos padrões é essencial para problemas em que os dados evoluem com o tempo. Estudos anteriores mostraram que RNAs feedforward treinadas sem exemplos negativos resultam em esquecimento catastrófico e interferência retroativa, em que o conhecimento previamente armazenado é interferido negativamente com a apresentação de outros padrões (SHARKEY; SHARKEY, 1995). Tais questões levaram ao desenvolvimento do dilema da estabilidade e plasticidade (GROSSBERG, 1980), que busca respostas as seguintes questões:

- Como um sistema de aprendizagem pode manter sua plasticidade (ser adaptável) em resposta às informações desconhecidas, e manter sua estabilidade diante da apresentação de informação irrelevante?
- Como um sistema pode preservar seu conhecimento adquirido e ao mesmo tempo ser suficientemente flexível para armazenar uma nova informação?
- Como um sistema de aprendizagem pode decidir quando alternar do estado de estabilidade à plasticidade e vice-versa?

Como resposta ao dilema da estabilidade/plasticidade Grossberg introduziu, em 1976, a rede neural artificial ART (*Adaptive Resonance Theory*) (GROSSBERG, 1976), um sistema de aprendizado não-supervisionado baseada no processo de formação cognitiva do cérebro humano. A estabilidade no contexto da RNA está associada a garantia de agrupamento de todos os elementos nas categorias criadas pela rede e a plasticidade é a característica que garante que a rede é capaz de aprender um novo padrão, em qualquer tempo de sua operação, sem perder o aprendizado previamente adquirido (LOPES, 2005) (AMORIM, 2006). O controle da estabilidade e da plasticidade é feito por um mecanismo interno de regulação, que controla a ressonância através de parâmetros pré-estabelecidos.


A arquitetura da rede ART foi baseada na teoria da ressonância adaptativa (WEENINK, 1997). O conceito de ressonância pode ser entendido como “oscilações” que ocorrem em um sistema físico quando o mesmo é submetido a uma entrada de frequência específica (frequência de ressonância), usualmente definida pelas propriedades físicas do sistema. Estabelecendo um paralelo, na rede ART, a aprendizagem ocorre quando as informações, na forma de saída das unidades de processamento (neurônios), “oscilam” entre as camadas de unidades da rede, desenvolvendo um estado de ativação de equilíbrio. Essas “oscilações” seriam o equivalente neural à ressonância em um sistema físico (AMORIM, 2006).

Nesse sentido, as redes ART são, então, redes neurais capazes de codificar conhecimentos estáveis, em tempo real, permitem aprendizado incremental, através da

auto-organização, em resposta a seqüências arbitrárias de padrões de entrada (CARPENTER; GROSSBERG, 1992).

Após o desenvolvimento inicial, a rede ART foi usada como base para evolução do algoritmo e criação de outras abordagens tanto de treinamento não-supervisionado como supervisionado (Figura 5).

Figura 5 – Principais redes ART e tipo de treinamento



Fonte: Autoria própria.

Podemos destacar como os principais modelos derivados da teoria da ART:

1. Rede neural ART1: De treinamento não-supervisionado, reconhece padrões de entrada binários de forma arbitrária (CARPENTER; GROSSBERG, 1987a);
2. Rede neural ART2: também possui treinamento não-supervisionado e reconhece padrões de entrada binários e analógicos (CARPENTER; GROSSBERG, 1987b);
3. Rede neural ART *Fuzzy* : generalização de ART1, é de treinamento não-supervisionado com a diferença de incluir na sua arquitetura cálculos baseados na lógica *Fuzzy*. Reconhece tanto padrões de entradas binários como analógicos . (CARPENTER; GROSSBERG; ROSEN, 1991);
4. Rede neural ARTMAP: de treinamento supervisionado, é composta por um par de módulos ART interconectados, através de um campo chamado inter-ART. Reconhece padrões de entradas binários e analógicos (CARPENTER; GROSSBERG; REYNOLDS, 1991);
5. Rede neural ARTMAP *Fuzzy* : é uma versão da rede ARTMAP, portanto também de treinamento supervisionado, com a diferença dos cálculos serem fundamentados na lógica *Fuzzy* (CARPENTER et al., 1992).

4.1 REDE NEURAL ARTIFICIAL ART-*FUZZY*

A RNA ART-*Fuzzy* é formada por um sistema de aprendizagem competitivo que auto-organiza categorias de forma estável em resposta a sequências de padrões de entrada, que podem ser binários ou analógicos. Estes padrões agrupam-se em categorias em forma de hiper-retângulos, cobrindo regiões distintas do espaço de entrada. A formação de grupos em forma de categorias é uma maneira de compressão da informação, na qual se formam regras abstratas sobre a distribuição dos dados permitindo generalizações (LOPES, 2005)(AMORIM, 2006)(CARPENTER; GROSSBERG, 1992).


4.1.1 Arquitetura

A arquitetura da RNA ART-*Fuzzy* é formada por dois subsistemas, o subsistema de atenção e o de orientação e por três camadas (Figura 6), F_0 , F_1 e F_2 (LOPES, 2005). Esses componentes são as estruturas que permitem a verificação de similaridade entre um novo padrão apresentado a RNA e um padrão já representado por algum neurônio (com alguma categoria já ativa), por meio da comparação de padrões. O subsistema de atenção é responsável na seleção de uma categoria vencedora, enquanto o subsistema de orientação tem a função de aceitar a categoria proposta ou reorientar a busca por uma nova categoria (GRANGER et al., 1996).

No subsistema de atenção, F_0 representa o vetor de entrada, F_1 a camada de comparação e F_2 a de reconhecimento. No estado de ressonância, os padrões de atividade desenvolvidos em F_1 e F_2 , são chamados de memória a curto prazo (*short term memory* - STM), pois somente existem em decorrência da aplicação de uma entrada às camadas e será atualizado posteriormente (SIMPSON, 1990)(GRANGER et al., 1996).

As camadas F_1 e F_2 são conectadas através de conexões feedforward (F_1 a F_2) e recorrentes (F_2 e F_1), ou seja, o fluxo de informações entre elas é bidirecional. Os pesos (w_j) associados com as conexões entre essas camadas, tanto de cima pra baixo como de baixo para cima, recebem o nome de memória a longo prazo (*long term memory* - LTM), pois representam a memória da rede, que permanece quando o padrão de entrada muda (KEYVAN; SONG; KELLY, 1999).

O subsistema de orientação é necessário para estabilizar o processo de STM e a aprendizagem em LTM, encontrando um equilíbrio entre esses dois processos, para que a rede aprenda em torno de novas entradas sem perder seu conhecimento prévio. A ressonância e o *reset* acontecem no subsistema de orientação por meio de um parâmetro que determina a decisão do processo de classificação de categorias, chamado parâmetro de vigilância (KEYVAN; SONG; KELLY, 1999).

Figura 6 – Arquitetura da rede neural ART

Fonte: Autoria própria.

4.1.2 Algoritmo de Treinamento ART-*Fuzzy*

Nessa seção será apresentado e discutido o algoritmo de funcionamento da RNA ART-*Fuzzy*. Os passos do algoritmo de treinamento da rede ART-*Fuzzy* estão apresentados na forma fluxograma na Figura 7. Primeiramente, é necessária uma definição dos vetores utilizados para a realização dos cálculos e dos parâmetros importantes da rede, de acordo com (CARPENTER; GROSSBERG, 1992).

Os vetores de atividade mostram se respectivo nó está ativo ou não. Os vetores de atividade são:

- Atividade em F_0 : $I = [I_1 \dots I_i], i = 1 \dots M$;
- Atividade em F_1 : $x = [x_1 \dots x_i], i = 1 \dots M$;
- Atividade em F_2 : $y = [y_1 \dots y_j], j = 1 \dots N$.

Sendo M o número de vetores de entrada na camada F_1 e N a dimensão dos vetores de entrada que na camada F_2 formarão as categorias.

O vetor peso (nó j) $w_j = [w_{j1} \dots w_{jM}]$ é um vetor associado com cada categoria de F_2 . No início do algoritmo adota-se o valor 1 para indicar que não há nenhuma categoria ativa:

$$w_{j1}(0) = \dots = w_{jM}(0) = 1 \quad (7)$$

Se a categoria j for selecionada significa que ela se tornou ativa e w_j atualiza seu valor (CARPENTER; GROSSBERG, 1992).

Os parâmetros da rede controlam o aprendizado da rede por meio da seleção de categorias, do controle da combinação entre entradas e pesos e da velocidade de adaptação dos pesos. Esses parâmetros são:

- Parâmetro de escolha α ($\alpha > 0$): Atua na seleção de categorias, controla a sequência de busca entre os nós na camada de reconhecimento (WEENINK, 1997);
- Parâmetro de vigilância ρ ($\rho \in [0, 1]$): verifica a combinação dos padrões de entrada e dos pesos, ou seja, controla a ressonância da rede. Em outras palavras, ele controla o tamanho máximo dos hiper-retângulos. Se ρ é grande, muitas categorias são criadas em F_2 fazendo com que a rede possua baixa capacidade de generalização. Mas se ρ é pequeno, serão geradas poucas categorias e consequentemente a rede terá alta capacidade de generalização (CARPENTER; GROSSBERG, 1992);
- Taxa de treinamento β ($\beta \in [0, 1]$): controla a velocidade de adaptação dos pesos da rede. Quando $\beta = 1$, tem-se o treinamento rápido (CARPENTER; GROSSBERG, 1992).

O algoritmo de funcionamento da RNA ART-*Fuzzy* está apresentado em forma de fluxograma na Figura 7 para melhor visualização do fluxo do processo de treinamento. Serão descritos os cálculos necessários, realizados nas etapas do algoritmo.

1. Normalização do vetor de entrada I

As entradas devem ser normalizadas para evitar a proliferação de categorias e garantir assim, o bom desempenho geral da rede. As entradas podem ser normalizadas em uma operação de pré-processamento por (CARPENTER; GROSSBERG, 1992):

$$I = \frac{a}{|a|} \quad (8)$$

2. Codificação de complemento

É uma regra de normalização das entradas através do cálculo de complemento. Esse procedimento gera o desenvolvimento de uma simetria teórica, em que o operador MIN ($\wedge$) e o operador MAX ($\vee$) da teoria de conjuntos *Fuzzy* assumem papéis complementares, formando um hiper-retângulo bidimensional que representa as categorias. Os valores MIN e MAX definem a faixa de variação aceitável das características em cada dimensão do hiper-retângulo. Para um vetor de entrada a , a resposta *on* (características presentes na entrada) é representada pelo próprio a e a resposta *off* (características ausentes na entrada) é representada pelo complemento (a, a^c) (CARPENTER; GROSSBERG, 1992):

$$a_i^c \equiv 1 - a_i \quad (9)$$

A entrada após a codificação de complemento se torna um valor 2M-dimensional:

$$[a, a^c] = [a_1 \dots a_M a_1^c \dots a_M^c] \quad (10)$$

3. Escolha de categoria

Para cada entrada I e nó j a função de escolha (T_j) é definida por (CARPENTER; GROSSBERG, 1992):

$$T_j = \frac{|I \wedge w_j|}{\alpha + |w_j|} \quad (11)$$

A função de escolha representa, então, a similaridade entre o padrão de entrada e o vetor de pesos w_j do nó j em F_2 .

O operador MIN ($\wedge$) é reduzido ao operador de interseção ($\cap$) no caso binário. Quando o parâmetro α se aproxima de zero, a função T_j se reduz a uma operação de subconjunto *fuzzy*. Nessa situação, T_j mede o grau em que o vetor de pesos w_j é um subconjunto *fuzzy* do vetor de entrada I (CARPENTER; GROSSBERG, 1992).

Quando um nó de F_2 torna-se ativo em um dado tempo o sistema realiza a escolha da categoria vencedora para representar aquele padrão de entrada. O índice J indica a categoria escolhida, para diferenciar do nó j , como sendo (CARPENTER; GROSSBERG, 1992):

$$T_J = \max \{T_j : j = 1 \dots, N\} \quad (12)$$

Para atualizar a atividade da categoria, se está ativa ou não, quando a J -ésima categoria é escolhida denota-se (CARPENTER; GROSSBERG, 1992):

$$y_J = \begin{cases} 1, & \text{se } j = J \\ 0, & \text{se } j \neq J \end{cases} \quad (13)$$

4. Ressonância

A ressonância entre o padrão de entrada e o vetor de pesos ocorre se a combinação dos dois satisfaz o critério de vigilância, determinado pelo valor de ρ (CARPENTER; GROSSBERG, 1992):

$$\frac{|I \wedge w_J|}{|I|} \geq \rho \quad (14)$$

Se o critério de vigilância não for atendido a função de escolha T_J assume valor 0 para evitar que a mesma categoria seja escolhida novamente em uma busca posterior. Uma nova busca é ativada e termina quando a categoria J escolhida satisfaça o critério de vigilância (CARPENTER; GROSSBERG, 1992). A aprendizagem ocorre durante o período de ressonância (SIMPSON, 1990) e o estado de ressonância é mantido até a apresentação do padrão de entrada seguinte.


5. Aprendizagem

A aprendizagem ocorre por meio da atualização e armazenamento dos pesos. Com a categoria escolhida, o vetor peso w_J é atualizado para w_J^{novo} por meio de (CARPENTER; GROSSBERG, 1992):

$$w_J^{novo} = \beta(I \wedge w_J^{velho}) + (1 - \beta)w_J^{velho} \quad (15)$$

Quando $\beta = 1$, têm-se o treinamento rápido. O treinamento rápido permite aos pesos se adaptarem com maior rapidez. Já o treinamento lento, $\beta = 1$, força os pesos a se adaptarem lentamente sobre muitos ciclos de aprendizagem. No treinamento rápido o hiper-retângulo se expande o suficiente pra incluir o ponto de entrada, enquanto que no lento ele se expande em direção a entrada na proporção de β (LOPES, 2005).

O aprendizado da rede ART-*Fuzzy* é estável porque os pesos somente decrescem, ou seja, à medida que as adaptações dos pesos são realizadas, os novos valores tendem sempre a diminuir até a estabilização. O decréscimo dos pesos representa um aumento no tamanho dos hiper-retângulos das categorias e o aprendizado só termina quando o espaço de entrada está todo coberto por eles (CARPENTER; GROSSBERG, 1992).

Figura 7 – Fluxograma de funcionamento da RNA ART-*Fuzzy***Fonte:** Autoria própria.

4.2 REDE NEURAL ARTIFICIAL ARTMAP FUZZY

A rede neural ARTMAP *Fuzzy* é um sistema de aprendizagem de treinamento supervisionado capaz de auto-organizar o reconhecimento estável de categorias em resposta a seqüências arbitrárias de padrões de entrada, que podem ser binários ou analógicos. A rede ARTMAP *Fuzzy* tem como principal diferença da rede ARTMAP a incorporação dos operadores nebulosos, advindos da teoria de conjuntos *Fuzzy* (CARPENTER et al., 1992)(LIM, 1997).

Esta rede é composta por um par de módulos *Fuzzy*-ART, $ART_a - Fuzzy$ e $ART_b - Fuzzy$ conectados por um módulo de memória associativa denominado inter-ART (Figura 8). Esse módulo possui um mecanismo autorregulador interno, *match tracking*, que maximiza a generalização enquanto minimiza o erro da rede. Sempre que se faz um prognóstico errado, por meio de uma conexão associativa instruída, o parâmetro de vigilância do módulo $ART_a - Fuzzy$ (ρ_a) será incrementado em uma quantidade mínima necessária para corrigir o erro no módulo $ART_b - Fuzzy$. Assim, o módulo *ART-Fuzzy* ativará uma nova busca por uma categoria que melhor represente a entrada atual até que seja feito um prognóstico correto ou criada uma nova categoria em $ART_a - Fuzzy$ (CARPENTER et al., 1992)(LIM, 1997)(LOPES, 2005).


O módulo $ART_a - Fuzzy$ atua na classificação dos padrões de entrada apresentados na camada F_0^a , enquanto o módulo $ART_b - Fuzzy$, desenvolve categorias referentes aos padrões de saída desejado expostos na camada F_0^b . As camadas F_2^a e F_{ab} são conectadas por um vínculo associativo cujos pesos são ajustados através do treinamento. Cada nó de F_2^b é conectado com seu nó correspondente em F_{ab} e vice-versa (LIM, 1997).

Quando um padrão é apresentado à rede, a camada F_{ab} recebe entradas dos dois módulos. A entrada do módulo $ART_a - Fuzzy$ refere-se à conexão associativa $J \rightarrow K$ e a entrada do $ART_b - Fuzzy$ representa a categoria ativa de F_2^b . Na adaptação dos pesos, a conexão correspondente entre as categorias ativas dos módulos $ART_a - Fuzzy$ (J) e $ART_b - Fuzzy$ assumirá valor 1 (um) e as demais conexões referentes ao mesmo nó do módulo $ART_a - Fuzzy$ assumirão valor 0 (zero)(LIM, 1997).

4.2.1 Vetores de entrada e de atividade

O vetor de entrada do módulo $ART_a - Fuzzy$ é representado pelo vetor $A = [a_1 \dots a_{Ma}]$, Ma -dimensional e o vetor de entrada de $ART_b - Fuzzy$ (correspondente a saída desejada) é representado por $B = [b_1 \dots b_{Mb}]$, Mb -dimensional. Para evitar a proliferação de categorias, esses vetores são normalizados de acordo com (CARPENTER et al., 1992):

$$\bar{a} = \frac{a}{|a|} \quad (16)$$

Figura 8 – Arquitetura da RNA ARTMAP *Fuzzy*

Fonte: Autoria própria.

$$\bar{b} = \frac{b}{|b|} \quad (17)$$

Para preservar a amplitude dos dados é efetuada a codificação de complemento (CARPENTER et al., 1992):

$$I^a = [a \ a^c] \quad (18)$$

$$I^b = [b \ b^c] \quad (19)$$

Os vetores de atividade, para os módulos $ART_a - Fuzzy$, $ART_b - Fuzzy$ e inter-ART são (CARPENTER et al., 1992):

- $ART_a : x^a = [x_1^a \dots x_{2M_a}^a], y^a = [y_1^a \dots y_{2N_a}^a];$
- $ART_b : x^b = [x_1^b \dots x_{2M_b}^b], y^b = [y_1^b \dots y_{2N_b}^b];$
- $inter - ART : x^{ab} = [x_1^{ab} \dots x_{N_b}^{ab}].$

sendo:

- M_a número de componentes do vetor de entrada a em F_1^a ;
- M_b número de componentes do vetor de entrada b em F_1^b ;
- N_a dimensão do vetor de entrada a em F_2^a ;
- N_b dimensão do vetor de entrada b em F_2^b .

4.2.2 Vetores de peso

Os vetores peso dos módulos $ART_a - Fuzzy ART_b - Fuzzy$ e $inter-ART$ são (CARPENTER et al., 1992):

- $ART_a : w_j^a = [w_{j1}^a \dots w_{j,2M_a}^a];$
- $ART_b : w_k^b = [w_{k1}^b \dots w_{k,2M_b}^b];$
- $inter - ART : w_j^{ab} = [w_{j1}^{ab} \dots w_{j,N_b}^{ab}].$

Inicialmente todos os pesos possuem valor 1 (um) indicando que não há nenhuma categoria ativa.

$$w_{j1}^a(0) = \dots = w_{j,2M_a}^a(0) = 1$$

$$w_{k1}^b(0) = \dots = w_{k,2M_b}^b(0) = 1$$

$$w_j^{ab}(0) = \dots = w_{j,N_b}^{ab}(0) = 1$$

4.2.3 Parâmetros

Os parâmetros da rede ARTMAP $Fuzzy$ são (CARPENTER et al., 1992):

- Parâmetro de escolha ($\alpha > 0$);
- Parâmetro taxa de treinamento ($\beta \in [0, 1]$);
- Parâmetro de vigilância ρ : Cada módulo tem um ρ próprio: ρ_a , ρ_b e ρ_{ab} .

Inicialmente no treinamento, ρ_a assumirá um valor $\underline{\rho}_a$, *baseline*, que calibra o nível mínimo de semelhança necessário para que $ART_a - Fuzzy$ aceite uma categoria selecionada (CARPENTER et al., 1992).

4.2.4 Escolha de categoria

Para cada entrada dos módulos $ART_a - Fuzzy (I^a)$ e $ART_b - Fuzzy (I^b)$ calcula-se a função de escolha T_j^a e T_k^b (CARPENTER et al., 1992):

$$T_j^a = \frac{|I^a \wedge w_j^a|}{\alpha + |w_j^a|} \quad (20)$$

$$T_k^b = \frac{|I^b \wedge w_k^b|}{\alpha + |w_k^b|} \quad (21)$$

As categorias são escolhidas como ativas (J) e (K) se estiverem de acordo com:

$$J = \max \{T_j^a : j = 1 \dots, N_a\}; \quad (22)$$

$$K = \max \{T_k^b : k = 1 \dots, N_b\}; \quad (23)$$

Se existir mais de uma categoria ativa, *i.e.*, com valores iguais para a função de escolha, a categoria escolhida será aquela de menor índice.

Com as categorias ativas escolhidas, é possível atualizar o vetor de atividade (y^b) do módulo $ART_b - Fuzzy$:

$$y_k^b = \begin{cases} 1, \text{para } k = K \\ 0, \text{para } k \neq K \end{cases} \quad (24)$$

4.2.5 Ressonância e *reset*

A ressonância da rede ocorre se os critérios de vigilância dos módulos $ART_a - Fuzzy$ (equação 25), e $ART_b - Fuzzy$ (equação 26) forem satisfeitos. Caso contrário, é enviado um sinal de *reset*, no qual os nós J e K são excluídos do processo de busca, T_j^a e T_j^b assumem valor zero e são escolhidas novas categorias de acordo com as equações (20) e (21) (CARPENTER et al., 1992).

$$\frac{|I^a \wedge w_J^a|}{|I^a|} \geq \rho_a \quad (25)$$

$$\frac{|I^b \wedge w_K^b|}{|I^b|} \geq \rho_b \quad (26)$$

Se não existe outro nó j e k que atenda aos critérios de vigilância ρ_a e ρ_b , é feito um acréscimo ϵ em ρ_a , que resulta em um novo valor ligeiramente maior para ρ_a , que corrige o erro no módulo $ART_b - Fuzzy$ (CARPENTER et al., 1992).

$$\rho_a = \frac{|I^a \wedge w_j^a|}{|I^a|} + \epsilon \quad (27)$$

Uma vez que as categorias dos dois módulos estão ativas, utiliza-se o mecanismo regulador *match tracking* do módulo inter-ART com o parâmetro de vigilância ρ_{ab} para verificar se a categoria ativa em $ART_a - Fuzzy$ corresponde à saída desejada apresentada em $ART_b - Fuzzy$ por meio da equação (26) (CARPENTER et al., 1992).

$$\frac{|Y^b \wedge w_K^{ab}|}{|Y^b|} \geq \rho_{ab} \quad (28)$$

4.2.6 Aprendizagem

Durante o estado de ressonância se as categorias ativas J e K combinarem, a adaptação dos pesos do módulo inter-ART se dá por (31) e a do $ART_a - Fuzzy$ e $ART_b - Fuzzy$ por (29) e (30), respectivamente (CARPENTER et al., 1992).

$$w_J^{anovo} = \beta(I^a \wedge w_J^{avelho}) + (1 - \beta)w_J^{avelho} \quad (29)$$

$$w_K^{bnovo} = \beta(I^b \wedge w_K^{bvelho}) + (1 - \beta)w_K^{bvelho} \quad (30)$$

$$\begin{cases} w_{J,K}^{ab} = 1 \\ w_{j,k}^{ab} = 0, \text{ para } j \neq J \text{ e } k \neq K \end{cases} \quad (31)$$

4.2.7 Algoritmo de treinamento da RNA ARTMAP *Fuzzy*

Feitas as considerações necessárias para entendimento das principais etapas do algoritmo, será apresentado nessa seção o algoritmo para treinamento da RNA ARTMAP *Fuzzy* na forma de passos sequenciais (CARPENTER et al., 1992)(LOPES, 2005)(DECANINI, 2012)(TONELLI-NETO, 2015):

1. Leitura de todos os parâmetros ARTMAP *Fuzzy* : α , β , $\underline{\rho}_a$, ρ_b , ρ_{ab} e ϵ ;
2. Inicialização das matrizes de pesos W_a , W_b e W_{ab} ;
3. Codificação de complemento das entradas $I^a = [a \ a^c]$ e $I^b = [b \ b^c]$;

4. Se a lista de padrões de treinamento foi concluída o treinamento é encerrado. Senão, continue ao passo seguinte;
5. ρ assume o valor de $\underline{\rho}_a$: $\rho = \underline{\rho}_a$;
6. Calcula-se a função de escolha T_k^b : $T_k^b = \frac{|I^b \wedge w_k^b|}{\alpha + |w_k^b|}$ para $k = 1, 2, \dots, N$;
7. Escolha da categoria da $ART_b - Fuzzy$ $K = \max \{T_k^b : k = 1 \dots, N_b\}$;
8. O critério de vigilância da $ART_b - Fuzzy$ é satisfeito? $\frac{|I^b \wedge w_K^b|}{|I^b|} \geq \rho_b$
 Se sim, vá ao passo seguinte.
 Senão, é ativado o *reset*; $T_K^b = 0$ e retorna ao Passo 7;
9. Calcula-se a atividade de $ART_b - Fuzzy$ $y^b = [y_1^b y_2^b \dots y_N^b]$;
10. Atualização dos pesos $ART_b - Fuzzy$ $w_K^{bnovo} = \beta(I^b \wedge w_K^{bvelho}) + (1 - \beta)w_K^{bvelho}$;
11. Calcula-se a função de escolha T_j^a : $T_j^a = \frac{|I^a \wedge w_j^a|}{\alpha + |w_j^a|}$ para $j = 1, 2, \dots, N$;
12. Escolha da categoria da $ART_a - Fuzzy$ $J = \max \{T_j^a : j = 1 \dots, N_a\}$;
13. O critério de vigilância da $ART_a - Fuzzy$ é satisfeito? $\frac{|I^a \wedge w_J^a|}{|I^a|} \geq \rho_a$;
 Se sim, vá ao passo seguinte.
 Senão, é ativado o *reset*; $T_J^a = 0$ e retorna ao Passo 12;
14. O critério de vigilância do inter-ART é satisfeito? $\frac{|Y^b \wedge w_J^{ab}|}{|Y^b|} \geq \rho_{ab}$
 Se sim, vá ao passo seguinte.
 Senão, incrementa-se o parâmetro de vigilância ρ_a : $\rho_a = \frac{|I^a \wedge w_J^a|}{|I^a|} + \varepsilon$ e $T_J^a = 0$.
 Retorna ao passo 12;
15. Atualização dos pesos $ART_a - Fuzzy$ $w_J^{anovo} = \beta(I^a \wedge w_J^{avelho}) + (1 - \beta)w_J^{avelho}$;
16. Atualização dos pesos do módulo Inter-ART: $w_J^{ab} = [w_{J,1}^{ab} w_{J,2}^{ab} \dots w_{J,N}^{ab}]$;
17. Retorna ao passo 4.

4.2.8 Algoritmo de teste da RNA ARTMAP *Fuzzy*

Na etapa de teste, a RNA ARTMAP *Fuzzy* já teve o seu conhecimento adquirido dos dados e armazenado em suas matrizes pesos. Na etapa de teste, insere-se como entradas da rede uma parte dos dados não utilizada durante o treinamento, *i.e.*, um conjunto de

dados desconhecidos. Então, é feita uma comparação da saída calculada pela rede e a saída real contida nos dados .

A etapa de teste da RNA ARTMAP *Fuzzy* para finalidades de classificação, pode ser feita com os seguintes procedimentos (DECANINI, 2012)(TONELLI-NETO, 2015):

1. Cria-se os vetores de teste, $\underline{a}$ e $\underline{I}^a$, que representam as novas entradas e sua respectiva codificação de complemento ($2M$ dimensional).
2. Identifica-se o neurônio vencedor na rede neural $ART_a - Fuzzy (J)$, sem realizar a atualização dos pesos.
3. Calcula-se $\underline{I}^b$ e consequentemente $\underline{b}$.

$$\underline{I}^b = w_J^{ab} w^b$$

$$\underline{I}^b = [\underline{b}_1 \ \underline{b}_2 \ \dots \ \underline{b}_{Mb} \ \underline{b}_1^c \ \underline{b}_2^c \ \dots \ \underline{b}_{Mb}^c]$$


$$\underline{b} = [\underline{b}_1 \ \underline{b}_2 \ \dots \ \underline{b}_{Mb}]$$

Em que $\underline{b}$ é a saída sem o complemento (M-dimensional) que representa a resposta calculada pela RNA ARTMAP *Fuzzy* em resposta ao padrão de entrada apresentado no início do procedimento de teste.

5 METODOLOGIA

Um algoritmo classificador alternativo ao que vem sendo apresentado na literatura especializada para detecção de presença de ocupantes com base de dados extraídos de sensores é proposto neste estudo. O trabalho se concentra na tarefa de classificar os dados recebidos dos sensores. É testada nessa pesquisa a adequação e desempenho da RNA ARTMAP *Fuzzy* para a classificação de dados obtidos de sensores ambientais. A Figura 9 apresenta as principais etapas da metodologia utilizada no desenvolvimento do estudo.

Figura 9 – Etapas da metodologia utilizada.




Fonte: Autoria própria.


5.1 OBTENÇÃO E ANÁLISE DOS DADOS

Utilizou-se, neste trabalho, o banco de dados proposto por Candanedo e Feldheim (2016) (CANDANEDO; FELDHEIM, 2016) para o problema de detecção da ocupação em um ambiente. No estudo, um escritório de dimensões $5,85\text{ m} \times 3,50\text{ m} \times 3,53\text{ m}$, ocupado por duas pessoas em horário comercial das (08:00 as 18:00), foi monitorado com sensores para medir as variáveis temperatura, umidade, luminosidade e níveis de CO_2 . O perfil de ocupação do escritório determina o comportamento das variáveis medidas. As Figuras 10, 11, 12, 13 e 14 mostram o comportamento das variáveis investigadas em relação ao tempo, iniciando as 07:00 horas de um dia e terminando as 10:00 horas do dia seguinte.

No experimento, foram usados sensores DHT22 para temperatura (medida em $^{\circ}\text{C}$) e umidade relativa (medida em %), sensor TSL2561 para luminosidade (Lux) e o Telaire 6613 para medir a quantidade de CO_2 no ambiente (em ppm). Também foi utilizado um microcontrolador Arduino para adquirir os dados, conectado a um rádio ZigBee que transferia os dados para uma estação de gravação. As informações de precisão e resolução e demais detalhes do sistema de coleta e construção do banco de dados se encontram em (CANDANEDO; FELDHEIM, 2016).

Figura 10 – Comportamento do CO₂ em função das horas do dia.


Fonte: Autoria própria.

Figura 11 – Comportamento da temperatura em função das horas do dia.


Fonte: Autoria própria.

Para compor o banco de dados de comparação, requerido por algoritmos supervisionados, foi utilizado uma câmera, que fotografou a sala a cada minuto, com dados do *timer*. Em seguida, fez-se um trabalho manual de verificar as imagens para a construção da variável ocupação. Quando não houvesse nenhum ocupante nas imagens, a variável ocupação recebia 0 e quando houvesse, recebia 1. Então, a variável ocupação é uma variável do tipo binária que representa o *status* da ocupação, sendo ocupado a resposta *on* e desocupado a resposta *off*).

Os dados foram amostrados uma vez por minuto, o que corresponde, por exemplo, a 1440 amostras em 24 horas de medição. O banco de dados para treinamento é composto

Figura 12 – Comportamento da umidade em função das horas do dia.

Fonte: Autoria própria.


Figura 13 – Comportamento da luminosidade em função das horas do dia.

Fonte: Autoria própria.

por 8143 entradas (o que corresponde aproximadamente a 5,65 dias de medições), com 6 variáveis: data/hora, CO₂, temperatura, luminosidade, umidade e ocupação.

As maiores variações nas medidas acontecem por volta das 08:00 horas quando o ambiente começa a ser ocupado e todos os sensores registram aumento e as 18:00 horas quando se inicia um decaimento gradual que se estende até as 08:00 horas do dia seguinte. O sensor de luminosidade, porém, não apresenta o mesmo comportamento, a diminuição e aumento acentuado nas medidas representam o momento em que as luzes são desligadas e ligadas, respectivamente.

É importante ressaltar que, as variáveis CO₂, temperatura e umidade apresentam

Figura 14 – Comportamento da ocupação do ambiente em função das horas do dia.

Fonte: Autoria própria.

um comportamento desafiador a detecção do status da ocupação, como discutido no capítulo 3: CO₂ e umidade pelo atraso de tempo em relação ao status real da ocupação e temperatura por flutuações gradualmente muito lentas (em ambiente controlado). Os sensores ambientais, dependendo da precisão e do perfil da ocupação do ambiente, podem apresentar limitações em captar bem essas pequenas variações.

No banco de dados não havia dados faltantes ou corrompidos, então não houve a necessidade de pré-processamento para correções e adequações. Os dados foram normalizados em outra etapa, como requisito de entrada da rede.

5.2 AJUSTE DE PARÂMETROS

A rede foi implementada no software MATLAB[®] R2015, de acordo com o algoritmo proposto por Carpenter (1992) (CARPENTER et al., 1992). Foram feitos testes iniciais com um número pequeno de dados para confirmar o funcionamento.

Os parâmetros da rede ARTMAP *Fuzzy* são de grande importância para o desempenho da classificação (CARPENTER et al., 1992). Foi desenvolvida uma rotina de variação dos parâmetros α , β_a , ρ_a e $\underline{\rho}_a$, mantendo os parâmetros β_b , ρ_b e ρ_{ab} fixos no valor 1 para encontrar o vetor de parâmetros ótimo da rede.

A rotina fixa um dos parâmetros variáveis e testa todas as combinações com os outros parâmetros, nas suas respectivas variações. É efetuado um treinamento da rede para cada vetor diferente de combinação de parâmetros. Comparou-se os resultados obtidos em cada treinamento, levando em consideração porcentagem de acerto, número de categorias criadas e tempo de processamento para eleger o vetor de parâmetros ótimo

para treinamento.

5.3 TREINAMENTO E TESTES

Uma vez que o vetor de parâmetros ótimos foi construído, foram feitas diferentes aplicações para testar o desempenho da RNA ARTMAP *Fuzzy*. Devido aos diferentes comportamentos das variáveis ambientais, foram testadas diferentes combinações de entradas na rede, para avaliar o desempenho individual de cada uma delas e em diferentes combinações. A seleção de variáveis com o melhor desempenho foi escolhida para testar normalizações diferentes que a feita por padrão na rede ARTMAP *Fuzzy*.

6 RESULTADOS E DISCUSSÃO

Nessa seção serão apresentados os resultados obtidos com a aplicação da metodologia. O banco de dados total (8143) foi dividido em 70% para treinamento (5700) e 30 % para testes (2443). Como entrada na rede, as variáveis CO_2 , temperatura (T), luminosidade (L) e umidade (U) assumiram valores entre 0 e 1 pela normalização do algoritmo ARTMAP *Fuzzy* e, da variável original data/hora foi utilizada apenas a hora (H), mas em formato binário. Como os dados estão em intervalo de tempo de um minuto, a hora foi codificada em um vetor de minutos do tipo binário: como 24 horas são compostas por 1440 minutos, o vetor utilizado tem 11 *bits*.

6.1 ANÁLISE DE DESEMPENHO DAS VARIÁVEIS

O vetor ótimo de parâmetros da RNA ARTMAP *Fuzzy* elegido através da rotina de treinamento e comparação, utilizando todas as variáveis para treinamento, pode ser visto na Tabela 5.

Na tarefa de detecção de ocupação por meio de dados de sensores, a combinação de variáveis utilizadas têm grande influência no desempenho do classificador. Alguns resultados mostraram grande variação no desempenho em resposta a diferentes combinações de variáveis (CANDANEDO; FELDHEIM, 2016). Nesse sentido, foram testadas combinações diferentes das variáveis de entrada data/hora, CO_2 , temperatura, luminosidade e umidade, inclusive individualmente, como entrada de treinamento da rede.

Como os vetores de entrada da RNA ARTMAP *Fuzzy* são apresentados em ordem aleatória no treinamento, foram realizadas 10 simulações para cada combinação de variáveis. Os resultados estão sintetizados na Tabela 6, contendo a combinação de variáveis utilizada e a acerto(%) médio e máximo.

Pode ser observado que os melhores resultados, em geral, foram alcançados por combinações de variáveis com baixa correlação entre as medidas, devido a natureza da variável: T com L, L com U e CO_2 com L. Em contrapartida, os piores desempenhos foram

Tabela 5 – Parâmetros ótimos utilizados na rede ARTMAP *Fuzzy*.

Parâmetros	Valores
α	0,01
ρ_a	0,90
ρ_b	1,00
ρ_{ab}	1,00
β_a	0,75
β_b	1,00

Fonte: Autoria própria.

Tabela 6 – Desempenho de diferentes combinações das variáveis de entrada.

Aplicação	Variáveis	Acerto (%)	
		Médio	Máximo
1	CO_2 , L, T, U, H	78,35	79,7
2	L, T, U, H	86,74	87,77
3	CO_2 , T, U, H	76,84	77,89
4	CO_2 , L, U, H	81,5	83,16
5	CO_2 , L, T, H	85,02	86,01
6	CO_2 , L, T, U	99,2	99,67
7	CO_2 , L, T	98,37	99,30
8	CO_2 , L, U	98,64	99,13
9	CO_2 , L, H	92,15	93,68
10	CO_2 , T, U	88,59	89,81
11	CO_2 , T, H	87,18	88,95
12	CO_2 , U, H	69,32	71,04
13	L, T, U	95,51	96,43
14	L, T, H	91,41	91,43
15	L, U, H	89,81	90,58
16	CO_2 , L	95,7	98,68
17	CO_2 , T	81,42	82,41
18	CO_2 , U	79,39	80,23
19	CO_2 , H	89,43	90,16
20	L, T	98,83	99,22
21	L, U	95,37	96,06
22	L, H	90,54	91,83
23	T, U	70,90	72,15
24	T, H	71,37	72,15
25	U, H	71,17	71,88
26	CO_2	90,12	91,16
27	L	92,4	93,11
28	T	71,3	73,1
29	U	71,72	73,84
30	H	69,70	69,70

Fonte: Autoria própria.

obtidos por combinações de variáveis mais correlacionadas entre si, em maior ou menor grau: CO_2 com U, CO_2 com T e T com U. CO_2 e U apresentam alta dependência, devido às duas variáveis serem produtos da respiração humana. Dessa forma, essas variáveis, quando utilizadas sem outra variável pouco correlacionada, apresentam menores desempenho na detecção. A combinação com melhor desempenho, CO_2 , L, T e U, consegue extrair melhor o comportamento dos dados, sem interferências negativas das dependências, que se tornam complementares na resposta final.

A variável H mostrou resultados menores quando utilizada em conjunto com as demais. A codificação binária da hora resulta em 1440 vetores diferentes, um para cada


minuto do período de 24 horas. Dessa forma, essa forma de codificação se mostrou atuando como generalizadora dos dados, como se fizesse uma pré-seleção, antes mesmo dos dados serem inseridos na rede, reduzindo o número de dados para cada uma das categorias referentes a variável H.

Foram testados, também, o treinamento da rede com apenas uma variável de entrada, para medir o desempenho isolado das variáveis em estudo. O melhor resultado foi alcançado pela variável L, com acerto médio de 93,11%, seguida da variável CO_2 com 91,16% de acerto máximo. A variável L, como discutido na análise dos dados, possui um comportamento menos variável e as suas mudanças de estado são bruscas (luzes acesas e apagadas). Porém, existem situações conflitantes na detecção de presença exclusivamente com medidas de luminosidade: as luzes podem ser deixadas acesas sem a presença de ocupantes, ou podem estar apagadas com a presença de ocupantes. Assim, é necessário adicionar uma variável que apresente maior correlação com a presença humana, como o CO_2 . Nos testes, a combinação de L e CO_2 alcançou 98,68% de classificações corretas.

As outras variáveis, utilizadas como entradas individualmente, T, U e H alcançaram desempenho máximo de 73,1%, 73,84% e 69,70%, respectivamente. A Figura 15 compara o desempenho individual das variáveis como entrada de treinamento no modelo de detecção de presença e a Figura 16 mostra a evolução do acerto (%) nas amostras de teste. As variáveis L (amarelo) e CO_2 (azul) apresentam um comportamento bem parecido na evolução do acerto, exceto no início do diagnóstico, antes de 250 amostras. Elas se mantêm na mesma curva e se distinguem no final do diagnóstico, em que L termina um pouco acima.

Outro par de variáveis com comportamento muito parecido no acerto das amostras, que resulta como no caso anterior, em porcentagens de acerto muito parecidas, são as variáveis T (roxo) e U (verde). Nesse caso, as variáveis sobrepoem seu comportamento nos acertos até pouco depois de 1000 amostras, e em seguida U fica um pouco acima. Já a variável H, inicia em 0 e oscila até chegar a seu valor máximo.

A análise dos resultados para uma, duas e três variáveis é uma ferramenta que auxilia na decisão de seleção das variáveis para o sistema de detecção de ocupação e qual desempenho se pode esperar. Para economia de recursos, como quantidade de dados e processamento, necessidade de diferentes tipos de sensores e infraestrutura existente, um sistema de detecção pode ter como entradas, por exemplo, apenas as variáveis L e CO_2 e apresentará um bom desempenho na detecção de presença. Deve-se, então, avaliar a infraestrutura e tecnologia disponível para coleta de dados e qual o percentual de acerto que se pretende alcançar com a utilização do sistema de detecção.

Figura 15 – Desempenho individual das variáveis na detecção de presença

Fonte: Autoria própria.


6.2 EFEITO DAS NORMALIZAÇÕES

A rede ARTMAP *Fuzzy* tem seu procedimento de normalização padrão, como apresentado no capítulo 4, $\bar{a} = \frac{a}{|a|}$, que aqui denomina-se Aplicação 1, uma vez que é necessário que os vetores de entrada estejam contidos no intervalo $[0,1]$. Para testar o efeito da normalização nos dados dos sensores foram utilizados outros dois tipos de normalização com a combinação de entradas que gerou os melhores resultados na etapa anterior (CO_2 , L, T e U). A partir da equação (32) foram normalizadas as entradas (a), de forma que o valor máximo é acrescido em 20 %.

$$a_{norm} = \frac{a}{1,2a_{max}} \quad (32)$$

em que a representa as entradas das quatro variáveis a cada amostra e a_{max} representa o maior de cada variável (maior valor de cada coluna da matriz de entradas).

A segunda normalização (denotada aqui por Aplicação 2) foi constituída pela normalização padrão da rede ARTMAP *Fuzzy* junto com o procedimento da equação (30). Por fim, a terceira normalização (Aplicação 3) foi constituída somente pela equação (32). Foram feitas 50 repetições de treinamento com os três tipos de normalização, no qual um vetor de entradas de ordem aleatória era gerado e executava o treinamento para cada Aplicação. A Tabela 7 apresenta um resumo do desempenho para cada normalização nas 25 primeiras repetições, com % de acerto e número de categorias criadas. A Tabela 8 apresenta o desempenho nas últimas repetições.

Figura 16 – Evolução do acerto (%) no teste com as variáveis CO_2 , L, T, U e H

Fonte: Autoria própria.

Como resultado, a Aplicação 2 alcançou a melhor média de acerto (99,10%), com o melhor valor de acerto global, de 99,75%. A Aplicação 1 (padrão da rede) também alcançou ótimos resultados, com média de acerto de 98,98% e acerto máximo de 99,71%. A Aplicação 3 teve a menor média e os menores valores individuais para cada conjunto de entradas de treinamento, mostrando que o procedimento de normalização padrão da rede ARTMAP *Fuzzy* é mais adequado para tratamento dos dados de entrada, alcançando uma maior porcentagem de acerto pelo controle da proliferação de categorias.

Em relação as categorias criadas, em média, a Aplicação 1 gerou menos categorias (16,80) e a Aplicação 2 teve um valor intermediário (17,18), que, pela porcentagem de acerto, representa a média de categorias adequada para um treinamento eficaz da rede. Com o aumento de 20% na dimensão dos dados, as relações entre as variáveis se tornaram mais "visíveis" para a rede, o que é importante nesse caso, dada a pequena variação no comportamento das variáveis CO_2 , T e U de uma amostra para outra.

A Aplicação 3 gerou, em média, mais categorias (18,26). Sua média não se manteve muito distante, mas por um efeito de ponderação do número de categorias em cada rodada de treinamento. Com a observação dos valores individuais, pode-se perceber que essa normalização ora criava poucas categorias e ora muitas, dependendo da distância do seu valor máximo para a média do conjunto de entradas.

Uma observação importante é que o número de categorias criadas não tem uma relação diretamente proporcional com a porcentagem de acerto da classificação (Figura 17). Uma rede com alta capacidade de generalização pode criar poucas categorias e não

Tabela 7 – Desempenho das normalizações testadas nas 25 primeiras repetições.

Testes N°	Aplicação 1		Aplicação 2		Aplicação 3	
	Acerto(%)	Categorias	Acerto(%)	Categorias	Acerto(%)	Categorias
1	98,93	15	99,09	16	97,74	18
2	99,71	17	99,38	17	98,19	15
3	98,85	15	98,11	16	96,47	18
4	99,18	18	99,46	19	97,05	16
5	99,63	17	99,75	17	96,23	19
6	97,99	19	98,36	18	96,06	20
7	98,64	19	99,09	18	97,37	17
8	99,54	18	99,67	19	98,27	16
9	99,46	19	99,18	18	97,05	16
10	99,26	18	99,5	17	98,03	20
11	98,60	16	98,93	18	96,35	15
12	99,46	17	99,63	19	97,17	16
13	98,36	19	98,20	20	95,45	22
14	99,18	18	99,46	19	97,33	16
15	99,26	18	99,67	17	97,41	15
16	99,38	17	99,54	19	98,07	14
17	98,27	16	98,77	18	96,47	15
18	98,79	17	98,83	17	97,66	20
19	98,77	18	98,27	16	96,47	15
20	99,26	19	99,59	17	97,45	13
21	97,99	16	98,36	18	96,06	14
22	99,05	16	99,42	17	97,54	15
23	98,72	18	98,93	16	96,10	13
24	99,18	18	99,46	19	97,58	16
25	99,46	19	99,30	18	98,03	15
Média	98,98	16,80	99,10	17,18	96,67	18,26

Fonte: Autoria própria.

representar bem o conjunto de dados a serem classificados, fazendo com que diminua o desempenho da classificação. O contrário pode ocorrer com uma rede com baixa capacidade de generalização, criar muitas categorias e se tornar excessivamente seletiva.

6.3 PERFIL DA OCUPAÇÃO

Como o desempenho máximo da classificação foi próximo de 100%, os perfis de ocupação (presença) durante um dia de utilização do ambiente dos dados reais e do calculado pela rede se sobrepõem em quase todos os pontos, exceto nos erros de classificação da rede. A Figura 18 mostra o perfil para os padrões de entrada da Aplicação 1, utilizando o desempenho máximo encontrado.

No melhor desempenho obtido, visualizando a sobreposição dos perfis calculado e real nos 2443 dados de testes, não é possível identificar com facilidade os pontos erros

Tabela 8 – Continuação da Tabela 7: Desempenho das normalizações testadas.


Testes N°	Aplicação 1		Aplicação 2		Aplicação 3	
	Acerto(%)	Categorias	Acerto(%)	Categorias	Acerto(%)	Categorias
26	98,31	17	97,21	19	95,08	16
27	99,22	19	99,46	18	97,70	15
28	98,93	18	98,60	16	96,35	15
29	99,05	15	99,54	17	97,17	22
30	99,26	17	99,34	18	97,66	21
31	99,5	18	99,09	19	97,09	20
32	99,05	16	99,63	17	97,04	21
33	97,82	15	98,31	18	95,16	23
34	98,93	14	99,18	16	97,09	21
35	98,64	16	99,22	18	96,27	21
36	98,40	14	98,77	15	95,45	22
37	99,09	14	99,38	16	96,27	19
38	98,85	15	98,27	14	96,06	20
39	99,30	15	99,5	17	96,72	22
40	99,63	17	99,05	15	95,49	21
41	99,26	17	99,46	18	95,86	19
42	99,05	19	99,59	17	97,00	18
43	99,34	15	99,54	16	96,76	20
44	98,93	16	99,22	18	94,30	23
45	99,63	17	99,05	16	97,74	21
46	98,44	15	98,23	14	95,81	19
47	99,13	19	99,54	17	97,25	22
48	97,78	16	97,95	16	95,16	20
49	99,09	15	99,63	16	95,20	20
50	99,13	14	99,46	15	94,30	23
Média	98,98	16,80	99,10	17,18	96,67	18,26

Fonte: Autoria própria.


da rede. Então, para melhor visualização, os pontos de erro foram aumentados (*zoom*) e estão apresentados na Figura 19 para a amostra da Aplicação 1 e na Figura 20 para a Aplicação 2.

No conjunto Aplicação 1 ocorreram 9 erros (taxa de erro de aproximadamente 0,37%) e no Aplicação 2 ocorreram 6 erros (taxa de erro de aproximadamente 0,25%). A Tabela 9 detalha os erros com horário de ocorrência e tipo de erro.

Os erros na classificação, em maioria absoluta, aconteceram em períodos de maior instabilidade da ocupação e, conseqüentemente, instabilidade nos dados coletados pelos sensores, como o intervalo para almoço (entre 12:30 e 14:35) e em pontos atípicos de mudança de *status*. Os horários de entrada e saída de pessoas (começo e fim de expediente) também são períodos de maior instabilidade. O conjunto Aplicação 2 não resultou em erros nesse período e Aplicação 1 obteve um erro as 17:44.

Figura 17 – Relação entre o desempenho da classificação e a quantidade de categorias criadas


Fonte: Autoria própria.

Figura 18 – Comparação da ocupação real e calculada pela rede.


Fonte: Autoria própria.

6.4 ANÁLISE DE DESEMPENHO

Nas Aplicações 1 e 2, as porcentagens de FN e FP foram, respectivamente, de 33,33% ($\frac{1}{3}$) e 66,66 ($\frac{2}{3}$). Pensando no contexto de aplicação de um sistema de detecção de ocupação, os resultados FP são mais prejudiciais a eficiência do sistema. Se aplicado em sistema BECM, por exemplo, o diagnóstico de FP levaria a uma ação de manter o sistema ligado e funcionando da mesma forma, apesar do ambiente se encontrar desocupado, ocasionando gastos desnecessários de energia.

Figura 19 – Pontos de erro da rede ARTMAP *Fuzzy* para Aplicação 1.

Fonte: Autoria própria.

Figura 20 – Pontos de erro da rede ARTMAP *Fuzzy* para Aplicação 2.

Fonte: Autoria própria.

Como pode ser observado na Figura 19 e Figura 20 o perfil de ocupação calculado pela rede acompanha bem o perfil dos dados reais e a maioria dos pontos de erros acontecem nos primeiros instantes após mudanças de *status* da ocupação, a rede apresenta um atraso na detecção. Esse resultado corrobora com a hipótese levantada na análise dos dados e discutida no Capítulo 2, na qual a variação gradualmente lenta das variáveis temperatura, nível de CO₂ e umidade, causada pela lenta taxa de mistura de gases no ambiente, seria causa de limitações nas medidas dos sensores utilizados.

A Tabela 10 apresenta a matriz de confusão para o melhor resultado obtido na classificação. Os erros foram 4 do tipo FP e 2 do tipo FN.

Tabela 9 – Momento e classificação dos erros.

Hora	Aplicação 1		Aplicação 2	
	Erro	Tipo	Erro	Tipo
10:38	1	FP	1	FP
12:42	2	FN		
12:56	3	FP		
13:24	4	FN	2	FN
13:27	5	FP	3	FP
13:36	6	FP	4	FP
14:32	7	FN	5	FN
16:09	8	FP	6	FP
17:44	9	FP		

Fonte: Autoria própria.**Tabela 10** – Matriz de confusão para o melhor resultado da Aplicação 2.

Presença	Ocupado (1)	Desocupado (0)	Soma
Ocupado (1)	730	4	734
Desocupado (0)	2	1707	1709
			2443

Fonte: Autoria própria.

Em sistemas de detecção de presença, a maior quantidade de aplicações são relacionadas a conforto térmico dos usuários e utilização mais eficiente de energia. Os erros FP são mais prejudiciais a utilização de energia elétrica, pois se um sinal falso positivo é gerado na resposta, o sistema se manterá em funcionamento e o ambiente estará desocupado. Já os erros FN são mais nocivos aos ocupantes, pois um sinal de FN levaria a um desligamento dos aparelhos de conforto térmico, podendo causar imprevistos e diminuindo o conforto térmico e confiabilidade do sistema.

O F-score é uma medida de desempenho de um modelo em um conjunto de dados, usado para avaliar sistemas de classificação binários. Para o melhor resultado, o F-score obtido na classificação feita pela RNA ARTMAP *Fuzzy* foi de 0,9945, mostrando que rede tem um ótimo desempenho em identificar corretamente as classes.

$$F - score = \frac{730}{730 + \frac{1}{2}(4 + 2)} = 0,9959 \quad (33)$$

7 CONCLUSÕES E TRABALHOS FUTUROS

Este trabalho teve por objetivo o desenvolvimento de uma metodologia, alternativa as que estão sendo apresentadas na literatura especializada, de utilização da RNA ARTMAP *Fuzzy* como algoritmo de detecção e classificação de presença de ocupantes em um ambiente a partir de dados obtidos de sensores ambientais. Foram realizados testes em um banco de dados desenvolvido na literatura para tarefas de classificação.

Pelo teste de diferentes combinações de variáveis como entradas de treinamento na rede, pode-se verificar que a combinação de variáveis medidas dos sensores ambientais têm grande influência no desempenho do sistema de detecção. A utilização de variáveis ambientais que apresentam alta correlação entre si diminui o desempenho do sistema, quando utilizada em combinações de duas ou três variáveis. Individualmente, as variáveis ambientais com melhor desempenho como entradas em um sistema de detecção de presença são luminosidade e CO_2 . Foi mostrado que a combinação de variáveis com melhor desempenho global foi CO_2 , luminosidade, temperatura e umidade.

Os testes realizados com as diferentes variáveis mostram qual o potencial esperado na aplicação de cada uma delas em sistemas de detecção de presença em tempo real. Para a construção de um sistema de detecção de presença, na prática, deve-se, então, avaliar a infraestrutura e tecnologia disponível para coleta de dados e qual o percentual de acerto que se pretende alcançar com a utilização do sistema.

Pelos treinamentos com diferentes tipos de normalizações, notou-se que a normalização dos dados tem influência significativa no desempenho da RNA ARTMAP *Fuzzy* e que a normalização padrão utilizada por esta rede alcança bons resultados. Porém, com a adição de uma normalização que incrementa o maior valor de cada variável, o desempenho da rede é melhorado. Foi possível observar também, o número de categorias criadas pela rede (capacidade de generalização da rede) não tem uma relação diretamente proporcional com o acerto da classificação. Contudo, os melhores resultados obtidos nos testes tenderam a mesma média de categorias criadas.

Pode ser comprovada pelos resultados obtidos a hipótese de que, pela lenta taxa de mistura de gases no ambiente, utilizar variáveis como CO_2 e umidade como entradas em sistemas de detecção de ocupação, apesar de apresentarem bons desempenhos combinadas com outras variáveis ou individualmente, acarretam em um atraso nas medidas dos sensores quando comparadas ao valor real dos parâmetros ambientais.

Apesar desse comportamento das variáveis, a RNA ARTMAP *Fuzzy* manteve sua porcentagem de acerto em uma amplitude com poucas variações percentuais, o que demonstra a adequação da metodologia e de seu uso como algoritmo classificador em sistemas de detecção de presença. A melhor configuração de variáveis, parâmetros e

normalização alcançou uma porcentagem de acerto mínima de 97,21%, média de 99,10% e máxima de 99,75%. Dessa forma, pelo desempenho apresentado e pelo tempo de diagnóstico, média de 0,008 segundos por entrada, o algoritmo pode ser agregado em um sistema inteligente de detecção de presença em tempo real viável comercialmente.

7.1 SUGESTÕES PARA TRABALHOS FUTUROS

Como sistema de detecção de presença, a metodologia proposta alcançou desempenho satisfatório, considerando porcentagem de acerto e tempo de processamento. Pode-se evoluir o algoritmo para um sistema de contagem da ocupação e até de rastreamento ou localização, mas é necessário ter dados reais de contagem e localização espacial dos ocupantes.

Algumas sugestões para trabalhos futuros:

- Estabelecer a quantificação da ocupação com alguma metodologia que simule o comportamento das variáveis ambientais em relação a presença humana;
- Testar o algoritmo em um sistema de detecção real;
- Avaliar a quantidade mínima de amostras necessárias para atingir um bom desempenho em um sistema de detecção de ocupação.

REFERÊNCIAS

- AHMAD, J. et al. Occupancy detection in non-residential buildings – A survey and novel privacy preserved occupancy monitoring solution. *Applied Computing and Informatics*, Amsterdam, p. 1–9, 2018.
- AKBAR, A. et al. Contextual occupancy detection for smart office by pattern recognition of electricity consumption data. *IEEE International Conference on Communications*, Piscataway, v. 2015-Sept, p. 561–566, 2015.
- ALAM, A. G. et al. Uncertainties in neural network model based on carbon dioxide concentration for occupancy estimation. *Journal of Mechanical Science and Technology*, Heidelberg, v. 31, n. 5, p. 2573–2580, 2017.
- AMORIM, D. G. *Redes ART com categorias internas de geometria irregular*. 2006. 352 f. Tese (Doutorado em Física) — Universidade de Santiago de Compostela, Santiago de Compostela, 2006.
- BENYA, J. et al. *Advanced Lighting Guidelines*. White Salmon, 2003. 445 p.
- BEYMER, D. Person counting using stereo. In: WORKSHOP ON HUMAN MOTION, 2000, Austin. **Anais [...]**. [S.l.]: IEEE, 2000. p. 127–133.
- BOSER, B. E.; GUYON, I. M.; VAPNIK, V. N. Training algorithm for optimal margin classifiers. In: WORKSHOP ON COMPUTATIONAL LEARNING THEORY, 5., 1992, Pittsburgh, USA. **Anais [...]**. [S.l.]: Association for Computing Machinery, 1992. p. 144–152.
- BROOKS, J. et al. An experimental investigation of occupancy-based energy-efficient control of commercial building indoor climate. In: IEEE CONFERENCE ON DECISION AND CONTROL, 53., 2014, Los Angeles. **Anais [...]**. [S.l.]: IEEE, 2014. p. 5680–5685.
- BROOMHEAD, D. S.; LOWE. Multivariable Functional Interpolation and Adaptive Networks. *Complex Systems*, Champaign, v. 2, p. 321–355, 1988.
- CALISKAN, M. et al. Predicting parking lot occupancy in vehicular ad hoc networks. In: IEEE VEHICULAR TECHNOLOGY CONFERENCE, 66., 2007, Baltimore. **Anais [...]**. [S.l.]: IEEE, 2007. p. 277–281.
- CANDANEDO, L. M.; FELDHEIM, V. Accurate occupancy detection of an office room from light, temperature, humidity and CO2 measurements using statistical learning models. *Energy and Buildings*, Amsterdam, v. 112, n. June, p. 28–39, 2016.
- CARPENTER, G.; GROSSBERG, S. A self-organizing neural network for supervised learning, recognition, and prediction. *IEEE Communications Magazine*, Piscataway, v. 30, n. 9, p. 38–49, 1992.
- CARPENTER, G. A.; GROSSBERG, S. A Massively Parallel Architecture for a Self-Organizing Neural Pattern Recognition Machine. *Pattern Recognition*, Amsterdam, v. 37, p. 54–115, 1987.

- CARPENTER, G. A.; GROSSBERG, S. ART2: Stable self-organization of pattern recognition codes for analog input patterns. *Applied Optics*, Washington, v. 26, p. 4919–4930, 1987.
- CARPENTER, G. A. et al. Fuzzy ARTMAP: A Neural Network Architecture for Incremental Supervised Learning of Analog Multidimensional Maps. *IEEE Transactions on Neural Networks*, Piscataway, v. 3, n. 5, p. 698–713, 1992.
- CARPENTER, G. A.; GROSSBERG, S.; REYNOLDS, J. H. ARTMAP: Supervised real-time learning and classification of nonstationary data by a self-organizing neural network. *Neural Networks*, Oxford, v. 4, p. 341–342, 1991.
- CARPENTER, G. A.; GROSSBERG, S.; ROSEN, D. B. Fuzzy ART: Fast stable learning and categorization of analog patterns by an adaptive resonance system. *Neural Networks*, v. 4, n. 6, p. 759–771, 1991.
- CHAN, M. et al. A review of smart homes-Present state and future challenges. *Computer Methods and Programs in Biomedicine*, Amsterdam, v. 91, n. 1, p. 55–81, 2008.
- CHEN, D. et al. Non-Intrusive Occupancy Monitoring using Smart Meters. In: WORKSHOP ON EMBEDDED SYSTEMS FOR ENERGY-EFFICIENT BUILDINGS, 5., 2013, Roma. **Anais**[...]. [S.l.]: Association for Computing Machinery, 2013. p. 1–8.
- CHEN, Z.; JIANG, C.; XIE, L. Building occupancy estimation and detection: A review. *Energy and Buildings*, Oxford, v. 169, p. 260–270, 2018.
- CHEN, Z.; XU, J.; SOH, Y. C. Modeling regular occupancy in commercial buildings using stochastic models. *Energy and Buildings*, Elsevier B.V., v. 103, p. 216–223, 2015.
- COOK, D. J.; DAS, S. K. How smart are our environments? An updated look at the state of the art. *Pervasive and Mobile Computing*, Amsterdam, v. 3, n. 2, p. 53–73, 2007.
- COVER, T.; HART, P. Nearest Neighbor Pattern Classification. *IEEE Transactions on Information Theory*, Piscataway, v. 1, p. 21–27, 1967.
- DECANINI, J. G. M. S. *Detecção, classificação e localização de faltas de curto-circuito em sistemas de distribuição de energia elétrica usando sistemas inteligentes*. 114 f. Tese (Doutorado em Engenharia Elétrica) — Universidade Estadual Paulista, 2012.
- D'OCA, S.; HONG, T. Occupancy schedules learning process through a data mining framework. *Energy and Buildings*, Oxford, v. 88, p. 395–408, 2015.
- DODIER, R. H. et al. Building occupancy detection through sensor belief networks. *Energy and Buildings*, Oxford, v. 38, n. 9, p. 1033–1043, 2006.
- DONG, B.; ANDREWS, B. Sensor-based occupancy behavioral pattern recognition for energy and comfort management in intelligent buildings. *IBPSA 2009 - International Building Performance Simulation Association 2009*, p. 1444–1451, 2009.
- ELKHOUKHI, H. et al. Towards a Real-time Occupancy Detection Approach for Smart Buildings. *Procedia Computer Science*, Amsterdam, v. 134, p. 114–120, 2018.

- ERICKSON, V. L.; CARREIRA-PERPIÑÁN, M. Á.; CERPA, A. E. OBSERVE: Occupancy-based system for efficient reduction of HVAC energy. In: INTERNATIONAL CONFERENCE ON INFORMATION PROCESSING IN SENSOR NETWORKS, 10., 2011, Chicago. **Anais**[...]. [S.l.]: Association for Computing Machinery, 2011. p. 258–269.
- FAYYAD, U.; PIATETSKY-SHAPIO, G.; SMYTH, P. From data mining to knowledge discovery in databases. *AI Magazine*, Palo Alto, v. 17, n. 3, p. 37–53, 1996.
- GARETH, J. et al. *An Introduction to Statistical Learning with Applications in R*. [S.l.: s.n.], 2013. v. 1. 441 p.
- GHAHRAMANI, Z. An introduction to hidden Markov models and Bayesian networks. *International Journal of Pattern Recognition and Artificial Intelligence*, Singapore, v. 15, n. 1, p. 9–42, 2001.
- GOLESTAN, S.; KAZEMIAN, S.; ARDAKANIAN, O. Data-Driven models for building occupancy estimation. In: INTERNATIONAL CONFERENCE ON FUTURE ENERGY SYSTEMS, 9., 2018, Karlsruhe. **Anais**[...]. [S.l.]: Association for Computing Machinery., 2018. p. 277–281.
- GRANGER, E. et al. A VLSI Architecture for Fast Clustering with Fuzzy ART Neural Networks. *International Journal of Microelectronics System Integration*, Tamil Nadu, v. 5, n. 1, p. 117–125, 1996.
- GROSSBERG, S. Adaptive Pattern Classification and Universal Recoding: I. Parallel Development and Coding of Neural Feature Detectors. *Biological Cybernetics*, Heidelberg, v. 23, p. 121–134, 1976.
- GROSSBERG, S. How does a brain build a cognitive code? *Psychological Review*, Washington, v. 87, n. 1, p. 1–51, 1980.
- HAILEMARIAM, E. et al. Real-time occupancy detection using decision trees with multiple sensor types. In: SYMPOSIUM ON SIMULATION FOR ARCHITECTURE AND URBAN DESIGN, 11., 2011, Boston. **Anais**[...]. [S.l.]: Society for Computer Simulation International, 2011. p. 141–148.
- HAN, Z.; GAO, R. X.; FAN, Z. Occupancy and indoor environment quality sensing for smart buildings. In: INTERNATIONAL INSTRUMENTATION AND MEASUREMENT TECHNOLOGY CONFERENCE, 2012, Graz. **Anais**[...]. [S.l.]: IEEE, 2012. p. 882–887.
- HAYKIN, S. *Neural Networks: A Comprehensive Foundation*. 2. ed. New Jersey, USA: Prentice-Hall, 1999. 823 p.
- HOBSON, B. W. et al. Opportunistic occupancy-count estimation using sensor fusion: A case study. *Building and Environment*, Amsterdam, v. 159, n. October, 2019.
- JIANG, C. et al. Indoor occupancy estimation from carbon dioxide concentration. *Energy and Buildings*, Amsterdam, v. 131, p. 132–141, 2016.
- JIANG, L. et al. Survey of improving K-nearest-neighbor for classification. In: INTERNATIONAL CONFERENCE ON FUZZY SYSTEMS AND KNOWLEDGE DISCOVERY, 4., 2007, Haikou, China. **Anais**[...]. [S.l.]: IEEE, 2007. p. 679–683.

- KEYVAN, S.; SONG, X.; KELLY, M. Nuclear fuel pellet inspection using artificial neural networks. *Journal of Nuclear Materials*, Amsterdam, v. 264, n. 1-2, p. 141–154, 1999.
- KLEIMINGER, W. et al. Occupancy Detection from Electricity Consumption Data. p. 1–8, 2013.
- KOTSIANTIS, S. B. Decision trees: A recent overview. *Artificial Intelligence Review*, v. 39, n. 4, p. 261–283, 2013.
- KRAIPEERAPUN, P.; AMORNSAMANKUR, S. Room occupancy detection using modified stacking. In: ACM INTERNATIONAL CONFERENCE PROCEEDING SERIES, 2017. **Anais[...]**. [S.l.]: Association for Computing Machinery, 2017. p. 162–166.
- KROSE, B.; SMAGT, P. V. *An introduction to neural networks*. Eighth edi. [S.l.]: Online Book, University of Amsterdam, 1996.
- LAM, K. P. et al. Occupancy detection through an extensive environmental sensor network in an open-plan office building. In: INTERNATIONAL BUILDING PERFORMANCE SIMULATION ASSOCIATION, 19., 2009, Glasgow. **Anais[...]**. [S.l.], 2009. p. 1452–1459.
- LEE, S.; HA, K. N.; LEE, K. C. A pyroelectric infrared sensor-based indoor location-aware system for the smart home. *IEEE Transactions on Consumer Electronics*, Piscataway, v. 52, n. 4, p. 1311–1317, 2006.
- LEVERMORE, G. *Building Energy Management Systems: Applications to Low-energy HVAC and Natural Ventilation Control*. London: E & FN Spon, 2000.
- LI, R.; LIU, Z.; TAN, J. A survey on 3D hand pose estimation: Cameras, methods, and datasets. *Pattern Recognition*, Amsterdam, v. 93, p. 251–272, 2019.
- LIM, C. P. Modified Fuzzy ARTMAP Approaches Bayes Optimal Classification Rates: An Empirical Demonstration. *Neural Networks*, Oxford, v. 10, n. 4, p. 755–774, 1997.
- LOPES, M. L. M. *Desenvolvimento de redes neurais para previsão de cargas elétricas de sistemas de energia elétrica*. 169 f. Tese (Doutorado em Engenharia Elétrica) — Faculdade de Engenharia, Universidade Estadual Paulista "Julio de Mesquita Filho- UNESP, Ilha Solteira, 2005.
- MASOOD, M. K.; SOH, Y. C.; CHANG, V. W. Real-time occupancy estimation using environmental parameters. In: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS, 2015. **Anais [...]**. [S.l.]: IEEE, 2016. v. 2015-Sept, p. 1–8.
- MASOOD, M. K.; SOH, Y. C.; JIANG, C. Occupancy estimation from environmental parameters using wrapper and hybrid feature selection. *Applied Soft Computing*, Amsterdam, v. 60, p. 482–494, 2017.
- MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, New York, v. 5, n. 4, p. 115–133, 1943.
- MELFI, R. et al. Measuring building occupancy using existing network infrastructure. In: INTERNATIONAL GREEN COMPUTING CONFERENCE AND WORKSHOPS, 2., 2011, Orlando. **Anais[...]**. [S.l.]: IEEE, 2011. p. 1–8.

- MOR, B.; GARHWAL, S.; KUMAR, A. A Systematic Review of Hidden Markov Models and Their Applications. *Archives of Computational Methods in Engineering*, Dordrecht, 2020.
- NGUYEN, N. T.; ZHENG, R.; HAN, Z. UMLI: An unsupervised mobile locations extraction approach with incomplete data. In: WIRELESS COMMUNICATIONS AND NETWORKING CONFERENCE, 2013, Shanghai, China. *Anais[...]*. [S.l.]: IEEE, 2013. p. 2119–2124.
- NGUYEN, T. A.; AIELLO, M. Energy intelligent buildings based on user activity: A survey. *Energy and Buildings*, Amsterdam, v. 56, p. 244–257, 2013.
- PHUA, P. K.; MING, D. Parallel nonlinear optimization techniques for training neural networks. *IEEE Transactions on Neural Networks*, Piscataway, v. 14, n. 6, p. 1460–1468, 2003.
- POWERS, D. M. W.; AILAB. Evaluation : From Precision , Recall and F-Factor to ROC , Informedness , Markedness & Correlation. *Journal of Machine Learning Technologies*, Tupe Nagar, v. 2, n. December, p. 37–63, 2007.
- QAMAR, F. et al. Interference management issues for the future 5G network: a review. *Telecommunication Systems*, New York, v. 71, n. 4, p. 627–643, 2019.
- RAHMAN, H.; HAN, H. Occupancy estimation based on indoor CO2 concentration: Comparison of neural network and Bayesian methods. *International Journal of Air-Conditioning and Refrigeration*, Singapore, v. 25, n. 3, 2017.
- RASHIDI, P.; COOK, D. J. Mining and monitoring patterns of daily routines for assisted living in real world settings. In: INTERNATIONAL HEALTH INFORMATICS SYMPOSIUM, 1., 2010, Heidelberg, Germany. *Anais[...]*. [S.l.]: Association for Computing Machinery, 2010. p. 336–345.
- RAYKOV, Y. P. et al. Predicting room occupancy with a single Passive infrared (PIR) sensor through behavior extraction. In: *ACM INTERNATIONAL JOINT CONFERENCE ON PERVASIVE AND UBIQUITOUS COMPUTING, 2016*. [S.l.]: *Anais [...]*, 2016. p. 1016–1027.
- SAHA, H. et al. Occupancy sensing in buildings: A review of data analytics approaches. *Energy and Buildings*, Amsterdam, v. 188-189, p. 278–285, 2019.
- SCH, B. et al. Input space versus feature space in Kernel-Based Methods. *IEEE Transactions on Neural Networks*, Piscataway, v. 10, n. 5, p. 1000–1017, 1999.
- SHARKEY, N. E.; SHARKEY, A. J. An Analysis of Catastrophic Interference. *Connection Science*, Oxfordshire, v. 7, n. 3-4, p. 301–330, 1995.
- SIMPSON, P. K. *Artificial neural systems : foundations, paradigms, applications, and implementations*. 1. ed. [S.l.]: Pergamon, 1990. 823 p.
- SO, A. T.; WONG, A. C.; WONG, K. C. A new definition of intelligent buildings for Asia. *Facilities*, v. 17, n. December, p. 485–491, 1999.
- SUN, K.; ZHAO, Q.; ZOU, J. A review of building occupancy measurement systems. *Energy and Buildings*, Amsterdam, v. 216, p. 109965, 2020.

- TOMASTIK, R.; LIN, Y.; BANASZUK, A. Video-based estimation of building occupancy during emergency egress. In: AMERICAN CONTROL CONFERENCE, 2008, 9., 2008, Seattle, USA. **Anais**[...]. [S.l.], 2008. p. 894–901.
- TONELLI-NETO, M. D. S. *Desenvolvimento de um sistema inteligente para o diagnóstico e prognóstico de falhas em sistemas de distribuição de energia elétrica*. 111 f. Tese (Doutorado em Engenharia Elétrica) — Universidade Estadual Paulista, 2015.
- TSAKANIKAS, V.; DAGIUKLAS, T. Video surveillance systems-current status and future trends. *Computers and Electrical Engineering*, Oxford, v. 70, p. 736–753, 2018.
- TUTUNCU, K.; CATALTAS, O.; KOKLU, M. Occupancy Detection Through Light, Temperature, Humidity, and CO2 Sensors Using ANN. In: INTERNATIONAL SOCIETY FOR ENGINEERS AND RESEARCHERS INTERNACIONAL CONFERENCE, 2016, 45., 2016, Rabat. **Anais**[...]. [S.l.], 2016. v. 112, p. 16–20.
- WAHL, F.; MILENKOVIC, M.; AMFT, O. A distributed PIR-based approach for estimating people count in office environments. In: INTERNATIONAL CONFERENCE ON COMPUTATIONAL SCIENCE AND ENGINEERING, 15., 2012, Vancouver, Canada. **Anais**[...]. [S.l.]: IEEE, 2012. p. 640–647.
- WAIBEL, A. Phoneme recognition using time-warping neural networks. *IEEE Transactions on Acoustics, speech and Signal Processing*, Piscataway, v. 37, n. 3, p. 328–339, 1989.
- WASSERMAN, P. *Neural Computing: Theory and Practice*. [S.l.]: Van Nostrand Reinhold, 1989.
- WEENINK, D. Category Art: a Variation on Adaptive Resonance Theory Neural Networks. In: IFA PROCEEDINGS, 21., 1997, Amsterdam. **Anais**[...]. [S.l.]: IEEE, 1997. v. 21, p. 117–129.
- WERBOS, P. Beyond Regression : New Tools for Prediction and Analysis in the Behavioral. n. January 1974, 1974.
- WIGGINTON, M.; HARRIS, J. *Intelligent Skins*. 1. ed. [S.l.]: Architectural Press, Oxford, 2002. 184 p.
- WOLPERT, D. H. Stacked generalization. *Neural Networks*, Oxford, v. 5, n. 2, p. 241–259, 1992.
- YANG, Z. et al. A systematic approach to occupancy modeling in ambient sensor-rich buildings. *Simulation*, London, v. 90, n. 8, p. 960–977, 2014.
- YANG, Z. et al. A multi-sensor based occupancy estimation model for supporting demand driven HVAC operations. *Simulation Series*, v. 44, n. 8, p. 100–107, 2012.
- YANG, Z. et al. A non-intrusive occupancy monitoring system for demand driven HVAC operations. In: CONSTRUCTION RESEARCH CONGRESS, 1., 2012, Indiana, USA. **Anais**[...]. [S.l.], 2012. p. 828–837.
- ZOU, H. et al. A fast and precise indoor localization algorithm based on an online sequential extreme learning machine. *Sensors*, Basel, v. 15, n. 1, p. 1804–1824, 2015.

ZOU, H. et al. Device-free occupancy detection and crowd counting in smart buildings with WiFi-enabled IoT. *Energy and Buildings*, Amsterdam, v. 174, p. 309–322, 2018.

ZURAIMI, M. S. et al. Predicting occupancy counts using physical and statistical Co2-based modeling methodologies. *Building and Environment*, Amsterdam, v. 123, p. 517–528, 2017.

APÊNDICE A – REDES NEURAIS ARTIFICIAIS

O cérebro pode ser considerado um computador (sistema de processamento de informações) altamente complexo, não-linear e paralelo. Ele tem a capacidade de organizar seus constituintes estruturais, os neurônios, de forma a realizar processamentos como percepção, reconhecimento de padrões e controle motor com uma rapidez muito superior quando comparada a qualquer computador existente atualmente (HAYKIN, 1999).

Uma RNA é um processador massivamente distribuído em paralelo, constituído de unidades de processamento mais simples (os neurônios), que armazenam conhecimento experimental e o tornam disponível para o uso. Se assemelha ao cérebro humano nos aspectos de adquirir conhecimento do ambiente por meio de um processo de aprendizagem, conhecido como treinamento, e em armazenar o conhecimento adquirido por meio das conexões entre os neurônios, chamadas de pesos sinápticos (HAYKIN, 1999).


As duas principais características que conferem poder computacional as RNAs são o massivo processamento em paralelo, garantido pela arquitetura da rede e a sua capacidade de generalização. Devido a essa capacidade, a RNA produz saídas adequadas para entradas desconhecidas (diagnóstico), que não estavam presentes durante a fase de aprendizagem (treinamento) (SIMPSON, 1990). Por essas características, elas têm aplicações em problemas complexos de várias áreas do conhecimento humano e em tarefas como reconhecimento de padrões, processamento de sinais e imagens, regressão, previsão, diagnóstico, otimização, filtragem, reconhecimento de erros e outras.

O processamento de dados com RNAs possui algumas propriedades e capacidades que não são encontradas em outras estruturas de processamento como generalização, robustez, adaptabilidade, não-linearidade, processamento paralelo e informação contextual (HAYKIN, 1999).

A.1 NEURÔNIO ARTIFICIAL

A era moderna das RNAs teve seu início com a publicação de McCulloch e Pitts em 1943 (MCCULLOCH; PITTS, 1943), na qual os autores apresentaram um cálculo lógico de redes neurais que unificava estudos de fisiologia e matemática. Propuseram que, com quantidade adequada de neurônios e conexões sinápticas sincronizadas e propriamente ajustadas, a rede proposta realizaria, a princípio, o cálculo de qualquer função computável. O modelo do neurônio artificial proposto (Figura 21) utilizou-se das principais estruturas e suas respectivas funções no neurônio biológico para construir a base da modelagem matemática.

O treinamento do neurônio artificial pode ser agrupado em etapas de acordo com o fluxo dos dados nas estruturas neurais (WASSERMAN, 1989):

Figura 21 – Modelo de um neurônio artificial

Fonte: Adaptado de (HAYKIN, 1999).

- Um conjunto de sinais de entrada $[x_1, x_2, \dots, x_n]$ são multiplicados por seu respectivo peso associado $[w_1, w_2, \dots, w_m]$. As entradas do modelo neural artificial correspondem aos sinais emitidos e transmitidos nas sinapses do neurônio biológico. Ao contrário de uma sinapse biológica, o peso sináptico do neurônio artificial pode estar em um intervalo que inclui valores negativos e positivos (HAYKIN, 1999).
- Na sequência, a combinação linear das entradas e dos pesos entra em uma componente somatória (símbolo soma): se a soma ponderada das entradas for maior que w_0 (peso *bias*) o neurônio é ativado e provoca um sinal de saída (s_i) (equação 34). Se não for maior, o neurônio não é ativado. O *bias* é combinado com uma entrada arbitrária x_0 , e tem o efeito de aplicar uma transformação afim à saída do combinador linear (HAYKIN, 1999), atuando como controle do nível de saída do neurônio.

$$s_i = \sum_j^n w_{ij} x_j \quad (34)$$

- Por fim, uma função de ativação $f(s)$ é utilizada para ativar o neurônio artificial e limitar sua amplitude de saída, de acordo com o tipo de função utilizada. Pode-se

identificar três tipos básicos de funções: a função relé, que assume somente valores 0 ou 1; a função linear e a função sigmoide, que é utilizada tanto em sistemas binários como contínuos (LOPES, 2005).

A.2 ESTRUTURA

Uma rede neural artificial pode ser graficamente representada como grafos orientados, ou grafos de fluxo de sinal, interligados em pontos chamados nós. Cada neurônio é representado por um único nó chamado de nó computacional. (HAYKIN, 1999). A composição estrutural mais básica de uma RNA é formada por camada de entrada, camada intermediária e camada de saída (LOPES, 2005). Dessa forma, os neurônios artificiais individuais se combinam em maiores números e em várias camadas com conexões entre si para formar estruturas de redes diversas. Pode-se classificar e enxergar uma RNAs de acordo com o fluxo de dados em sua estrutura em redes recorrentes (*feedback*) e não recorrentes (*feedforward*) (KROSE; SMAGT, 1996).

Nas redes não recorrentes não existem laços de realimentação, *i.e.*, os dados da camada de entrada fluem para a camada intermediária (que pode ser única ou múltipla) e em sequência para a camada de saída, sem realimentação (KROSE; SMAGT, 1996). Essa categoria de RNAs não possuem memória a longo prazo, somente a curto prazo, pois a saída é determinada considerando somente as entradas e seus respectivos valores de pesos (WASSERMAN, 1989).

Já nas redes recorrentes estão incorporadas conexões do tipo *feedback*, *i.e.*, laços de realimentação que fluem de saída da rede ou de determinados neurônios para as camadas anteriores. A rede recalcula os valores de saída e por meio das conexões *feedback* atualiza os valores dos pesos. Esse processo de adaptação pode ser repetido até que um ponto de estabilidade seja atingido, no qual os valores de ativação deixarão de apresentar variações (KROSE; SMAGT, 1996). Por esse processo de atualização a rede recorrente é capaz de desenvolver uma memória a longo prazo nos neurônios internos (WASSERMAN, 1989).

A.3 TREINAMENTO

As RNAs absorvem conhecimento do ambiente e melhoram seu desempenho através de um processo de aprendizagem. Aprendizagem para o contexto de redes neurais pode ser definido como um processo pelo qual os parâmetros livres (pesos) de uma RNA são adaptados por meio de um processo de adaptação do ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado pela maneira pela qual a modificação dos pesos ocorre (HAYKIN, 1999). Os pesos da rede convergem gradualmente a determinados valores, à medida que o vetor de entrada produz o vetor de saída desejado (WASSERMAN, 1989).

O treinamento é finalizado quando todos os pesos da rede, derivados do conjunto de entradas fornecidas, são atualizados pelo processo de aprendizagem empregado. Um algoritmo de aprendizagem é um conjunto pré-estabelecido de regras bem definidas no processo de aprendizado de uma RNA (HAYKIN, 1999). O processo de treinamento pode ser feito por uma variedade de algoritmos de aprendizado, cada um com suas características e vantagens específicas. Podemos agrupar os treinamentos em: supervisionado, não supervisionado, híbrido e competitivo (LOPES, 2005).

No treinamento supervisionado é necessário um “professor” na fase de aprendizado da rede, para checar a combinação dos padrões de entrada e de saída (na forma de mapeamento) e informar sobre o desempenho da rede. Então, para acontecer o treinamento é necessário um conjunto de entradas e um conjunto de saída desejada, que será comparada com a saída calculada pela RNA. Como exemplo de RNAs que utilizam esse treinamento pode-se citar a rede ARTMAP e ARTMAP *Fuzzy* e a rede Madaline com algoritmo de aprendizagem backpropagation (WASSERMAN, 1989)(KROSE; SMAGT, 1996).

No treinamento não supervisionado (*self-organization*) o aprendizado acontece de forma autônoma, os pesos da rede se auto organizam à medida que extraem informações relevantes e suficientes dos dados de entrada, já que nesse tipo de treinamento não existe uma resposta de comparação. Como exemplo desse treinamento estão as redes ART e ART *Fuzzy*, Kohonen e Hopfield (WASSERMAN, 1989)(KROSE; SMAGT, 1996).

O treinamento híbrido utiliza as técnicas supervisionadas e não supervisionadas ao mesmo tempo (LOPES, 2005), aproveitando-se das características de funcionamento dos dois tipos para construir um aprendizado combinado.

O treinamento competitivo pode ser considerado semelhante ao supervisionado por também apresentar uma saída desejada. Geralmente, as redes que utilizam esse tipo de treinamento têm muitos neurônios de saída e a competição dita qual neurônio de saída melhor representará a saída desejada. Um exemplo é a rede *counterpropagation* (KROSE; SMAGT, 1996).

Como algoritmos de treinamento muito utilizados na literatura no desenvolvimento das RNAs pode-se citar regra de Hebb, delta de Widrow e Hoff, regra delta generalizada e o algoritmo *backpropagation*. O algoritmo *backpropagation* pode visto como uma generalização da regra delta generalizada para funções de ativação não lineares (KROSE; SMAGT, 1996).