**Soluções de tomadas de decisões inteligentes para
infraestruturas residenciais**

Geraldo Pereira Rocha Filho

Tese de Doutorado do Programa de Pós-Graduação em Ciências de
Computação e Matemática Computacional (PPG-CCMC)

SERVIÇO DE PÓS-GRADUAÇÃO DO ICMC-USP

Data de Depósito:

Assinatura: _____

Geraldo Pereira Rocha Filho

Soluções de tomadas de decisões inteligentes para infraestruturas residenciais

Tese apresentada ao Instituto de Ciências Matemáticas e de Computação – ICMC-USP, como parte dos requisitos para obtenção do título de Doutor em Ciências – Ciências de Computação e Matemática Computacional. *VERSÃO REVISADA*

Área de Concentração: Ciências de Computação e Matemática Computacional

Orientador: Prof. Dr. Jó Ueyama

USP – São Carlos
Junho de 2018

Ficha catalográfica elaborada pela Biblioteca Prof. Achille Bassi
e Seção Técnica de Informática, ICMC/USP,
com os dados inseridos pelo(a) autor(a)

R672s Rocha Filho, Geraldo Pereira
 Soluções de tomadas de decisões inteligentes para
 infraestruturas residenciais / Geraldo Pereira
 Rocha Filho; orientador JÓ Ueyama. -- São Carlos,
 2018.
 101 p.

 Tese (Doutorado - Programa de Pós-Graduação em
 Ciências de Computação e Matemática Computacional) --
 Instituto de Ciências Matemáticas e de Computação,
 Universidade de São Paulo, 2018.

 1. Sistema de automação residencial. 2. Rede de
 sensores sem fio. 3. Tomada de decisão. 4.
 Inteligência computacional. 5. Aprendizagem de
 máquina. I. Ueyama, JÓ, orient. II. Título.

Geraldo Pereira Rocha Filho

**Intelligent decision-making solutions for residential
infrastructures**

Doctoral dissertation submitted to the Institute of
Mathematics and Computer Sciences – ICMC-USP, in
partial fulfillment of the requirements for the degree of
the Doctorate Program in Computer Science and
Computational Mathematics. *FINAL VERSION*

Concentration Area: Computer Science and
Computational Mathematics

Advisor: Prof. Dr. Jó Ueyama

USP – São Carlos
June 2018

AGRADECIMENTOS

A jornada de um doutorando não é apenas quatro anos, costumo dizer que é necessário investir no mínimo 22 anos da vida, que vão desde o fundamental até a pós-graduação, para ser um Doutor. Foi uma jornada longa e árdua que exigiu muita persistência, mas o final é gratificante. Durante a trajetória, obtive o apoio de pessoas especiais que gostaria de deixar registrado meus singelos agradecimentos.

Agradeço à minha esposa Cristiane de Azevedo Guimarães que, com palavras sábias, sempre apoiou nas minhas decisões e incentivou a seguir em frente. Agradeço ainda pelo seu companheirismo incondicional, pela sua compreensão nos momentos que necessitei e por transformar os dias ruins em excelentes.

Agradeço à minha irmã Thiaquelliny Teixeira Pereira e aos meus pais Geraldo Pereira Rocha e Adenita Teixeira Pereira pelos inúmeros incentivos para realizar uma pós-graduação de excelência, digna da USP. Sem eles, essa conquista não seria possível. Ainda agradeço por mostrarem que com persistência, dedicação e esforço os objetivos desejados são alcançados.

Agradeço ao meu Orientador Prof. Jó Ueyama, que se tornou um grande amigo, por acreditar no meu potencial e pela confiança no desenvolvimento desta tese. Destaco os seus valorosos conselhos acadêmicos, e até mesmo os conselhos pessoais, que foram essenciais para a minha formação profissional. Ainda, agradeço pela paciência e atenção nos momentos que necessitei.

Agradeço ao Prof. Leandro A. Villas e Prof. Gustavo Pessin que, além de disponibilizar os seus preciosos tempos com discussões agradáveis, se tornaram grandes amigos. Agradeço também pelas inúmeras sugestões com a colaboração direta, as quais auxiliaram para o amadurecimento desta tese.

Agradeço aos colegas e amigos do LaSDPC (Laboratório de Sistemas Distribuídos e Programação Concorrente), Intermídia e a todos que colaboraram de maneira direta e indireta para o desenvolvimento desta tese.

Agradeço o apoio financeiro concedido da Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP, processo 2014/06330-5) para o desenvolvimento desta tese.

“A mente que se abre a uma nova ideia jamais volta ao seu tamanho original.”
(Albert Einstein)

RESUMO

ROCHA FILHO, G. P. **Soluções de tomadas de decisões inteligentes para infraestruturas residenciais**. 2018. 101 p. Tese (Doutorado em Ciências – Ciências de Computação e Matemática Computacional) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos – SP, 2018.

Nos últimos anos, um dos principais desafios globais está relacionado com a eficiência energética, sendo o desperdício de energia um dos fatores a ser destacado. Tal desperdício pode ser superado com o uso do Sistema de Automação Residencial (SAR). Vale frisar que os SARs são fortemente dependentes da sua infraestrutura interna, visto que esta é a base de uma casa inteligente. A Rede de Sensores e Atuadores sem Fio (RSASF) é uma solução promissora e de fácil implantação para ser utilizada como infraestrutura em um SAR. Entretanto, o uso das RSASFs como infraestrutura para monitorar e atuar (isto é, processo de tomada de decisão) no contexto de um SAR traz um novo problema. Tal problema remete não apenas a falta de um método para realizar a decisão dentro do próprio nó da RSASF, mas também a ausência em investigar um *trade-off* entre a precisão nas tomadas de decisões e o consumo de energia dos nós da rede. Além disso, a falta de uma infraestrutura distribuída, com baixo *overhead* e que reduza a latência do serviço são algumas das novas problemáticas para serem exploradas. Com isso, tem-se como desafio embarcar uma maior inteligência em dispositivos com recursos escassos, característica presente em uma RSASF. Para superar tais limitações, esta tese apresenta duas soluções de decisões inteligentes para uma infraestrutura residencial, nomeadas como ResiDI e ImPeRIum. O ResiDI é baseado em uma rede neural para atuar no processo de tomada de decisão dentro da RSASF, bem como em um mecanismo de correlação temporal para maximizar a eficiência energética da infraestrutura de comunicação. Já o ImPeRIum é baseado em um conjunto heterogêneo de dispositivos inteligentes para formar um ambiente computacional de *fog*, o qual gerencia as aplicações da residência por meio de uma rede neural. As soluções foram avaliadas extensivamente em diferentes cenários e comparadas com um trabalho da literatura. Os resultados reais e simulados, avaliados mediante uma análise estatística paramétrica e não-paramétrica, mostrou atingir o objetivo desta tese, sendo quatro deles notáveis: (i) aumento da precisão nas tomadas de decisões; (ii) redução no consumo de energia dos nós da rede; (iii) redução no tempo de resposta da atuação com baixa sobrecarga; e (iv) eficiência na disseminação das informações.

Palavras-chave: Sistema de automação residencial, Rede de sensores sem fio, Tomada de decisão, Inteligência computacional, Aprendizado de máquina.

ABSTRACT

ROCHA FILHO, G. P. **Intelligent decision-making solutions for residential infrastructures.** 2018. 101 p. Tese (Doutorado em Ciências – Ciências de Computação e Matemática Computacional) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos – SP, 2018.

In recent years, energy efficiency has become a major global challenge, and energy waste is a factor that needs to be highlighted. Such waste can be overcome with the use of Home Automation System (HAS). It should be stressed that the HASs are strongly dependent on its internal network, since this is the basis of a smart home. Wireless Sensor and Actuator Networks (WSANs) provide a modern and ubiquitous infrastructure for a smart home. However, the use of WSANs to monitor and act (i.e. decision-making process) as a control infrastructure within the context of HAS poses a new problem. Such problem refers not only to the lack of a method to execute the decision-making process within the WSAN, but also to the lack of investigating a trade-off between the decision-making accuracy and the extension of the WSAN node's life-time. In addition, the lack of a distributed infrastructure, with low overhead in processing and that reduces service latency are some of the new problems to be addressed in the literature. With this, one has as a challenge to embark on greater intelligence in devices with scarce resources, a feature present in a WSAN. To overcome such limitations, this thesis presents two intelligent decision-making solutions for residential infrastructures, named ResiDI and ImPeRIum. ResiDI was developed based on a neural network to act in the decision-making process within the network, as well as a temporal correlation mechanism to maximize the energy consumption in the network's nodes. ImPeRIum was based on a heterogeneous set of smart objects to form a fog computational environment, which manages the applications of the residence through a neural network. The solutions were evaluated extensively in different scenarios and compared with an approach in the literature. The real and simulated results, evaluated through parametric and non-parametric tests, show that solutions make four key contributions: (i) increased decision-making; (ii) reduction in node energy consumption; (iii) reduction in action response time with low overload; and (iv) efficiency in the transmission of information.

Keywords: Home Automation System, Wireless sensor network, Decision-making, Computational intelligence, machine learning.

LISTA DE ILUSTRAÇÕES

Figura 1 – Nós sensores espalhados em uma região de interesse com o intuito de senso- rear e enviar informações para uma estação de monitoramento.	26
Figura 2 – O consumo de energia de um nó sensor pode ser dividido em três componen- tes: (i) sensoriamento; (ii) processamento; e (iii) comunicação; os quais são realizados pelos sensores, CPU, e rádio, respectivamente.	27
Figura 3 – Nós sensores e atuadores espalhados em uma região de interesse com o intuito de sensoriamento, atuar e enviar informações para uma estação de monitoramento.	29
Figura 4 – Exemplo da arquitetura semi-automatizada e automatizada de uma RSASF	31
Figura 5 – Exemplo de um neurônio artificial de McCulloch e Pitts (1943).	33
Figura 6 – Exemplos de diferentes tipos de funções de ativações para processar as informações nos neurônios.	34
Figura 7 – Representação de uma RNA do tipo MLP com o algoritmo de aprendizado <i>Backpropagation</i>	35
Figura 8 – Exemplo de funcionamento da RNA para a tomada de decisão.	35
Figura 9 – Evolução da quantidade de publicações por ano de acordo com a primeira <i>string</i> de busca.	38
Figura 10 – Relação entre as aplicações e os tipos de sensores utilizados.	39
Figura 11 – Fluxo de processo das limitações identificadas nas infraestruturas de comuni- cação de dados no contexto residencial.	40
Figura 12 – Fluxo de processo das limitações identificadas nas tomadas decisões no contexto residencial.	44
Figura 13 – Exemplo de funcionamento do sistema de decisão inteligente para infraestru- turas residenciais	53
Figura 14 – Funcionamento da hierarquia do ResiDI e obtenção da distância como métrica para disseminar as mensagens no nosso modelo.	54
Figura 15 – Topologia da RNA modelada para a tomada de decisão e sua execução com diferentes configurações de neurônios na camada escondida para saber a melhor topologia.	57
Figura 16 – Protótipo do nó sensor (a), decisor (b) e atuador (c) desenvolvido para o ResiDI que permite a criação de uma RSASF que coleta, dissemina, processa e atua na aplicação desejada.	58

Figura 17 – Analisando a base de dados para observar o comportamento do usuário no final de semana em relação aos demais dias, bem como o consumo de energia gasto pelo morador em um período de 24 horas, identificando equipamentos ociosos, os quais gastam uma parte considerável do tempo em modo <i>standby</i> (ROCHA FILHO <i>et al.</i> , 2014).	60
Figura 18 – Gerenciamento de recursos da memória ROM, memória <i>flash</i> para programa e processador em modo ativo.	61
Figura 19 – Medidas de desempenho calculadas a partir da matriz de confusão.	62
Figura 20 – Análise de desempenho do ResiDI de acordo com a Tabela 3.	63
Figura 21 – Análise de desempenho da métrica consumo de energia de acordo com a Tabela 6.	66
Figura 22 – Mapa de energia residual dos nós na coleta de dados para uma área monitorada de 15x15 m. O eixo Z representa a energia consumida pelos nós.	66
Figura 23 – Análise de desempenho da métrica atraso de acordo com a Tabela 6.	67
Figura 24 – Análise de desempenho da métrica mensagem transmitida de acordo com a Tabela 6.	68
Figura 25 – Análise de desempenho da métrica taxa de entrega de acordo com a Tabela 6.	69
Figura 26 – Análise de desempenho do ResiDI em um ambiente real comparado com resultados simulados.	71
Figura 27 – ImPeRIum - Funcionamento do sistema de decisão inteligente para infraestruturas residenciais.	74
Figura 28 – ImPeRIum - Comunicação <i>Pub/Sub</i> por meio do MQTT.	76
Figura 29 – Análise exploratória dos algoritmos de classificação.	77
Figura 30 – Funcionamento da RNA modelada para o processo de tomada de decisão.	78
Figura 31 – Bloco de dados utilizados.	79
Figura 32 – Intensidade de uso das aplicações.	79
Figura 33 – Impacto de desempenho do ImPeRIum quando comparado com outras abordagens da literatura.	80
Figura 34 – Impacto de desempenho do consumo de memória, processador e tempo de processamento.	82

LISTA DE TABELAS

Tabela 2 – Resumo das lacunas identificadas nos trabalhos analisados analisados.	49
Tabela 3 – Conjunto de parâmetros escolhidos para serem avaliados	62
Tabela 4 – P-valores resultades do <i>Shapiro-Wilk normality test</i>	62
Tabela 5 – Influência dos parâmetros em função das medidas de desempenho. A, método; B, dataset; C, aplicação.	64
Tabela 6 – Conjunto de parâmetros escolhidos para serem avaliados.	65
Tabela 7 – P-valores resultantes do <i>Shapiro-Wilk normality test</i>	70
Tabela 8 – P-valores resultantes do <i>Wilcoxon rank sum test</i>	70
Tabela 9 – Conjunto de parâmetros para serem avaliados e os dispositivos físicos utiliza- dos nos experimentos.	82

SUMÁRIO

1	CAPÍTULO 1	21
1.1	Contextualização e problema	21
1.2	Objetivos	23
1.3	Estrutura da tese	23
2	FUNDAMENTAÇÃO TEÓRICA	25
2.1	Redes de sensores sem fio	25
2.2	Redes de sensores e atuadores sem fio	28
2.2.1	<i>Arquitetura da RSASF</i>	30
2.3	Aprendizagem de máquina	32
2.3.1	<i>Redes neurais artificiais</i>	33
2.4	Considerações finais	36
3	UMA REVISÃO SISTEMÁTICA EM SISTEMAS DE AUTOMA- ÇÃO RESIDENCIAL: INFRAESTRUTURA E PROCESSO DE TO- MADA DE DECISÃO	37
3.1	Tendência de crescimento dos sistemas residenciais inteligentes	37
3.2	Infraestruturas adotadas para comunicação de dados	40
3.2.1	<i>Infraestrutura cabeada para comunicação de dados</i>	40
3.2.2	<i>Infraestrutura híbrida para comunicação de dados</i>	41
3.2.3	<i>Infraestrutura sem fio para comunicação de dados</i>	42
3.3	Soluções adotadas para realizar o processo de tomada de decisão	43
3.3.1	<i>Soluções específicas e ações predeterminadas</i>	44
3.3.2	<i>Soluções com inteligência computacional</i>	46
3.4	Desafios e questões de pesquisa	47
3.5	Considerações finais	50
4	UM SISTEMA DE DECISÃO INTELIGENTE PARA INFRAESTRU- TURAS RESIDENCIAIS VIA SENSORES E ATUADORES SEM FIO	51
4.1	Instaurando o ResiDI	51
4.2	ResiDI - Sistema de decisão inteligente para infraestruturas residen- ciais	51
4.2.1	<i>Infraestrutura da Proposta</i>	53
4.2.1.1	<i>Construção da Tabela de Roteamento</i>	53

4.2.1.2	<i>Comunicação do nó Sensor com o nó Decisor</i>	54
4.2.1.3	<i>Comunicação do nó Decisor com o nó Atuador</i>	55
4.2.2	Mecanismo para a Tomada de Decisão com Fusão de Dados	56
4.2.3	Protótipo desenvolvido para o ResiDI	57
4.3	Avaliação de desempenho	58
4.3.1	Metodologia	58
4.3.1.1	<i>A escolha do baseline para o ResiDI</i>	58
4.3.1.2	<i>Modelando a base de dados para a tomada de decisão</i>	59
4.3.1.3	<i>Métodos estatísticos utilizados para a avaliação</i>	60
4.3.2	Avaliação de Desempenho do Impacto da Gerência de Recursos	60
4.3.3	Avaliação de Desempenho na Tomada de Decisão	61
4.3.3.1	<i>Análise das influências dos parâmetros</i>	63
4.3.4	Avaliação de desempenho da infraestrutura	64
4.3.4.1	<i>Impacto da energia residual dos nós da rede de maneira homogênea</i>	65
4.3.4.2	<i>Impacto do tempo de resposta na tomada de decisão</i>	66
4.3.4.3	<i>Impacto das mensagens transmitidas na infraestrutura</i>	67
4.3.4.4	<i>Impacto da taxa de entrega das mensagens na infraestrutura</i>	68
4.3.5	Avaliação de Desempenho da Eficácia do ResiDI no Protótipo Desenvolvido	69
4.4	Considerações finais	71
5	UM SISTEMA DE CONTROLE NEURO-FOG PARA INFRAESTRUTURAS RESIDENCIAIS VIA OBJETOS INTELIGENTES	73
5.1	ImPeRlum - Um sistema de controle neuro-fog para infraestruturas residenciais	73
5.1.1	Funcionamento dos papéis e níveis do ImPeRlum	75
5.1.2	Comunicação Publish/Subscribe do ImPeRlum	75
5.1.3	Inteligência computacional para o processo de tomada de decisão	76
5.2	Avaliação de Desempenho e Metodologia	77
5.2.1	Avaliação de desempenho do ImPeRlum com outras soluções da literatura	78
5.2.1.1	<i>Análise dos resultados obtidos</i>	79
5.2.2	Avaliação de desempenho do ImPeRlum no ambiente de fog	81
5.2.2.1	<i>Análise dos resultados obtidos</i>	81
5.3	Considerações finais	83
6	CONCLUSÃO	85
6.1	Principais contribuições	85
6.2	Trabalhos futuros	88

REFERÊNCIAS	89
-----------------------	----

APÊNDICE A	PLANEJAMENTO DO PROTOCOLO PARA REVI-	
	SÃO SISTEMÁTICA	99

A.1	Objetivos da pesquisa	99
-----	---------------------------------	----

A.2	Questões de pesquisa	100
-----	--------------------------------	-----

A.3	Estratégias de busca para a seleção dos trabalhos	100
-----	---	-----

A.4	Critérios e procedimentos para a seleção dos trabalhos	100
-----	--	-----

CAPÍTULO 1

1.1 Contextualização e problema

Nos últimos anos, um dos principais desafios globais está relacionado com a eficiência energética, sendo o desperdício de energia um dos fatores a ser destacado. Nessa área, constatou-se que o consumo de energia no setor residencial tem aumentado de maneira significativa ao longo dos anos devido ao desenvolvimento econômico (MINENO *et al.*, 2010) e ao uso indiscriminado da energia por parte do morador (ROCHA FILHO *et al.*, 2014). Esse aumento, muitas vezes desordenado, atribuído à expansão do uso dos eletrodomésticos e eletrônicos, ocasiona um desperdício significativo no uso da energia. Por causa desse desperdício, os governos e organizações internacionais têm investigado políticas de conservação de energia para não enfrentar problemas no setor energético, como blecautes (ORESTIS *et al.*, 2013; ROCHA FILHO *et al.*, 2014; BOTMA; HANCKE; RAMOTSOELA, 2017; ABDMOULEH; GASTLI; BEN-BRAHIM, 2018).

O Sistema de Automação Residencial (SAR), também conhecido como *smart home*, integrado no sistema elétrico de potência e aliado à inteligência computacional, é um dos caminhos mais promissores para prover soluções relacionadas com a eficiência energética. O SAR permite o gerenciamento dos recursos habitacionais, tais como iluminação, aquecimento, ar condicionado e aparelhos eletrônicos, levando em consideração grandezas físicas do ambiente (por exemplo, temperatura, presença e umidade) para monitorar, bem como atuar de forma inteligente em benefício dos moradores (JIANG; LIU; YANG, 2004; CHENG; KUNZ, 2009; MEKIKIS; ATHANASIOU; FISCHIONE, 2013; LEE *et al.*, 2014).

Apesar dos avanços conquistados nessa área, os SARs são dependentes da sua infraestrutura interna, visto que esta é a base de uma casa inteligente. Há vários trabalhos na literatura (LIN *et al.*, 2002; JIANG; LIU; YANG, 2004; LEE; HONG, 2009) que usam infraestruturas cabeadas, juntamente com sensores analógicos, para sensorear o ambiente. Entretanto, tais infraestrutu-

ras são: (i) dependentes do ambiente; (ii) custosas devido a instalação da fiação que muitas vezes é escassa; e (iii) utilizadas, por exemplo, por um equipamento centralizador para gerenciar as informações da rede. Além disso, a falta de uma infraestrutura padronizada, flexível e com funcionalidades heterogêneas (que, por exemplo, não se comunicam em conjunto com outras aplicações) para atender as necessidades do usuário, representa um dos desafios a serem considerados na implantação de um SAR.

A Rede de Sensores sem Fio (RSSF) (AKYILDIZ *et al.*, 2002) surge como uma alternativa promissora para superar as limitações mencionadas anteriormente, permitindo flexibilidade na remoção e/ou adição de componentes, facilidade em integrá-la dentro de outros *backbones*, além de ser escalável, colaborativa e de baixo custo. No entanto, as RSSFs são formadas por dispositivos (nós sensores), limitados em recursos (memória, bateria e processamento, por exemplo), que apenas coletam e disseminam dados. Nesse sentido, a combinação de sensores e de atuadores em uma mesma rede, nomeada como Redes de Sensores e Atuadores sem Fio (RSASF) (AKYILDIZ; KASIMOGLU, 2004), aumenta o potencial das RSSFs no SAR, uma vez que as RSASFs possuem maior poder de processamento, comunicação e energia, podendo atuar no ambiente físico mediante os dados provenientes dos sensores. Por exemplo, através de sensores de movimento e umidade em um quarto é possível controlar o sistema de iluminação, bem como o de ar condicionado, com base nas preferências do usuário.

Neste contexto, as RSASFs fornecem uma infraestrutura moderna e ubíqua para uma casa inteligente. Entretanto, o uso das RSASFs para monitorar e atuar como infraestrutura de controle dentro do contexto de um SAR gera um novo problema, a saber: o desenvolvimento de soluções computacionais inteligentes para que o processo de tomada de decisão seja realizado de maneira distribuída dentro da própria RSASF, sendo ciente dos problemas decorrentes da energia residual dos nós e da precisão para as tomadas de decisões. Tal problema foi encontrado mediante uma revisão sistemática, a qual analisou os seguintes trabalhos: Lin *et al.* (2002), Mineno *et al.* (2010), Tomic, Fensel e Pellegrini (2010), Mantoro, Ayu e Elnour (2011), Tang e Ciuciu (2012), Dittawit e Aagesen (2013), Ramlee *et al.* (2013), Fensel *et al.* (2013), Farias *et al.* (2013), Baraka *et al.* (2013), Teich *et al.* (2014), Mahmood *et al.* (2014), Farias *et al.* (2014), Sendra *et al.* (2014), Lee *et al.* (2014), ROCHA FILHO *et al.* (2014), Mahmood *et al.* (2014), Ming *et al.* (2016), Khan, Silva e Han (2016), Wu *et al.* (2017), Irvan e Terano (2017), Kazarian *et al.* (2017).

Convém salientar que as soluções analisadas são dotadas de problemas locais, específicos e com investigações fragmentadas, indicando um campo de pesquisa promissor e sem consolidação, particularmente quando aliado com a inteligência computacional. É válido ressaltar também que mesmo com o crescimento quantitativo nessa área, os trabalhos analisados possuem limitações, sendo três principais: (i) a pré-configuração ou o uso de tecnologias semânticas para a tomada de decisão que, além de apresentar indicativos de aumento de memória a medida que novas regras são inseridas na rede tipicamente por um especialista, não representam na prática a

conduta do morador, o qual pode alterar o seu comportamento, por exemplo, no final de semana; (ii) o prolongamento da vida útil dos nós da RSASF com o intuito de manter um *trade-off* entre precisão nas tomadas de decisões e consumo de energia dos nós da rede, sem que haja perdas de confiabilidade na infraestrutura distribuída, uma vez que os nós deixam de operar por falta de energia; e (iii) a falta de esforços em investigar a interação (coordenação e/ou comunicação) entre o uso dos nós sensores e atuadores na formação de uma RSASF, com o intuito de evitar *overhead* na sua infraestrutura. Além disso, a falta de uma infraestrutura heterogênea, flexível, escalável e que reduza a latência do serviço, são algumas das novas problemáticas a serem exploradas na literatura.

1.2 Objetivos

Para superar os desafios e limitações mencionados anteriormente, esta tese propõe duas soluções inteligentes para uma infraestrutura de automação residencial distribuída baseadas em sensores sem fios. As soluções propostas são nomeadas como ResiDI e ImPeRIum. O ResiDI é baseado em uma rede neural para atuar no processo de tomada de decisão dentro da RSASF, bem como em um mecanismo de correlação temporal para maximizar a eficiência energética da infraestrutura de comunicação. Já o ImPeRIum é baseado em um conjunto heterogêneo de dispositivos inteligentes para formar um ambiente computacional de *fog*, o qual gerencia as aplicações da residência por meio de uma rede neural. As soluções apresentadas possuem como objetivo principal, garantir uma precisão na tomada de decisão ao mesmo tempo que provê uma redução no consumo de energia nos nós da infraestrutura de comunicação

1.3 Estrutura da tese

O restante desta tese está estruturado da seguinte maneira. No Capítulo 2, é apresentada a fundamentação teórica com o propósito de fornecer subsídios para o entendimento desta pesquisa. No Capítulo 3, é apresentada a proposta de uma revisão sistemática para identificar as lacunas de pesquisa para esta tese. Nos Capítulos 4 e 5, são apresentadas as soluções desenvolvidas para esta tese, nomeadas como ResiDI e ImPeRIum, respectivamente. Por fim, no Capítulo 6, são apresentadas as conclusões desta pesquisa, revisitando as principais contribuições desta tese e sugerindo novas ideias para o desenvolvimento de trabalhos futuros.

FUNDAMENTAÇÃO TEÓRICA

Neste capítulo, é apresentada a fundamentação teórica com a finalidade de fornecer subsídios aos capítulos posteriores. Inicialmente, é apresentado um embasamento teórico sobre as RSSFs e seus desafios. Subsequentemente, é realizado um estudo da RSASF. Além disso, uma discussão dos desafios e características únicas que as RSASFs possuem é apresentada. Finalmente, são apresentados e discutidos os conceitos de Aprendizagem de Máquina (AM) para o entendimento da solução proposta nesta tese.

2.1 Redes de sensores sem fio

De acordo com Govindan *et al.* (2001), Akyildiz *et al.* (2002), Loureiro *et al.* (2003), Krishnamachari e Govindan (2008), Prathap *et al.* (2012), Villas *et al.* (2013), Cardoso *et al.* (2014), Boubiche, Boubiche e Azzedine (2016), Kafi, Othman e Badache (2017), uma Rede de Sensores Sem Fio (RSSF) pode ser definida como uma rede cooperativa de nós sensores, cuja finalidade é transmitir os dados sensoreados de um ambiente para um nó *sink*, usando frequentemente a comunicação *multihop*, como ilustrada na Figura 1. Para tanto, os nós sensores são equipados com uma interface de comunicação sem fio, bateria, memória e processador, sendo dispersos em uma determinada região com o intuito de observar e transmitir eventos de interesse, como temperatura e presença, por exemplo. Já o nó *sink* é responsável por receber os dados dos nós sensores e enviá-los para um servidor (por exemplo, um servidor em uma nuvem), realizando assim a comunicação entre a rede interna e externa. Ainda, o nó *sink* possui maior poder computacional em relação aos nós sensores.

Tipicamente, cada nó sensor pode ser equipado com vários tipos de sensores, tais como temperatura, pressão, umidade, presença, luminosidade, vibração e ruído. Esses nós sensores são desenvolvidos para serem de baixo custo, devendo apresentar tamanhos reduzidos e normalmente possuem limitações computacionais, por exemplo, energia, memória, processamento e comunicação. No entanto, nos últimos anos, os avanços tecnológicos na área de micro sistemas eletro-mecânicos, bem como eletrônica digital e microprocessadores têm incentivado o desenvolvimento de nós sensores mais robustos (AKYILDIZ; VURAN, 2010; PRATHAP *et al.*, 2012; VILLAS *et al.*, 2013). Consequentemente, as RSSFs estão sendo

Figura 1 – Nós sensores espalhados em uma região de interesse com o intuito de sensorear e enviar informações para uma estação de monitoramento.

Fonte: Elaborada pelo autor.

cada vez mais empregadas em uma grande variedade de aplicações, tais como ambientais, rurais, urbanas, e domésticas.

A utilização das RSSFs nas áreas ambientais é importante para auxiliar na prevenção, bem como no controle de vítimas de catástrofes naturais, como enchente (FURQUIM *et al.*, 2016; FURQUIM *et al.*, 2018) e incêndio (GIUNTINI; BEDER; UEYAMA, 2017), por exemplo. Nas áreas rurais, as RSSFs podem ser utilizadas para auxiliar, controlar e monitorar o uso de defensivos químicos na pulverização de plantações (FAIÇAL *et al.*, 2014b; FAIÇAL *et al.*, 2016). Já nas áreas urbanas, é possível gerenciar o consumo de energia de toda rede desde o sistema elétrico de potência até os consumidores, e vice-versa (GUNGOR; LU; HANCKE, 2010). Ainda, é possível monitorar e controlar o tráfego de veículos, por exemplo, em malhas viárias urbanas, mediante a velocidade e densidade de veículos em suas vias (ARAUJO *et al.*, 2014; MENEGUETTE *et al.*, 2016; SOUZA *et al.*, 2017). Além das aplicações urbanas, os sensores sem fios são utilizados em residências para automatizar as tarefas domésticas, dando conforto e segurança para os usuários, de maneira inteligente (KIM *et al.*, 2008; ROCHA FILHO *et al.*, 2014; ROCHA FILHO *et al.*, 2015b; ROCHA FILHO; TORRES NETO; UEYAMA, 2017; OJUROYE *et al.*, 2017; FILHO *et al.*, 2018a). Para esta classe de aplicação, torna-se possível automatizar as tarefas domésticas, tais como iluminação, controle de equipamentos e monitoramento dos gastos de água e energia elétrica, proporcionando um ambiente mais inteligente com a integração dos sensores sem fio nos equipamentos residenciais usados no dia-a-dia.

Deve-se ressaltar que as RSSFs possuem características específicas conforme as áreas que são aplicadas, isto é, as atividades requeridas dependem do objetivo da aplicação (GOVINDAN; ESTRIN, 2002; AKYILDIZ *et al.*, 2002; LOUREIRO *et al.*, 2003; CORREA *et al.*, 2006; AKYILDIZ; VURAN, 2010). Assim, as principais tarefas típicas de uma RSSF são: (i) determinar o valor de algum parâmetro em um dado local; (ii) detectar eventos de interesse; (iii) estimar valores em razão do evento detectado;

(iv) detectar um objeto de interesse; (v) rastrear um objeto; (vi) prover comunicação de dados; (vii) prover escalabilidade; e (viii) prover agregação/correlação de dados quando necessário com o intuito de minimizar a quantidade de transmissões enviadas para o nó *sink*.

Em razão da diversidade das aplicações existentes, bem como suas tarefas típicas, as RSSFs vêm despertando interesse por parte da comunidade acadêmica nacional e internacional, tendo em vista que seus inúmeros desafios de pesquisa ainda estão sendo investigados (UEYAMA *et al.*, 2010; PAZZI *et al.*, 2011; PESSIN *et al.*, 2012; VILLAS *et al.*, 2013; VILLAS *et al.*, 2013; FAIÇAL *et al.*, 2014; FAIÇAL *et al.*, 2014b; UEYAMA *et al.*, 2014; ROCHA FILHO *et al.*, 2013; UEYAMA *et al.*, 2017; FILHO *et al.*, 2018c; FILHO *et al.*, 2018b). Um dos principais desafios que faz parte do contexto desta pesquisa, está relacionado com a restrição do recurso energético que os nós sensores possuem. Tal restrição é derivada mediante o uso da bateria como fonte de energia para os nós sensores, os quais podem ser depositados em ambientes de difícil acesso dependendo da aplicação. Consequentemente, a reposição/recarga da bateria torna-se muitas vezes inviável. Ainda dentro do contexto de restrição de energia, o componente que mais dissipa energia residual do nó é o seu rádio (AKYILDIZ; VURAN, 2010; VILLAS *et al.*, 2013), mais especificamente a transmissão de dados entre os nós, como ilustrado na Figura 2.

Figura 2 – O consumo de energia de um nó sensor pode ser dividido em três componentes: (i) sensoramento; (ii) processamento; e (iii) comunicação; os quais são realizados pelos sensores, CPU, e rádio, respectivamente.

Fonte: Adaptada de Akyildiz e Vuran (2010).

Uma solução para resolver esse problema, é os nós aproveitarem os recursos energéticos oferecidos pelo ambiente, usando, por exemplo, painéis solares para recarregá-los. Contudo, o uso do painel solar no nó possui desvantagens, sendo as principais: (i) dependência do sol, uma vez que períodos longos de chuvas juntamente com o período da noite afetam a recarga da bateria; (ii) custosa, pois há um problema de escalabilidade, haja vista que as RSSFs são compostas por um grande número de sensores; e (iii) inviável de ser instalada quando o local é de acesso inadequado aos seres humanos, por exemplo, ao redor de um vulcão. Outra alternativa, é a substituição periódica das baterias dos sensores, no entanto,

esta alternativa recai no problema de escalabilidade e ambientes inacessíveis (AKYILDIZ; VURAN, 2010; ESCOBAR, 2011), como descrito anteriormente. Outra alternativa utilizada na literatura, é desligar os componentes dos sensores quando há uma baixa atividade na RSSF (AKYILDIZ; VURAN, 2010; ESCOBAR, 2011). Com tal alternativa, entretanto, não é possível saber se os sensores se auto desligaram para economizar energia, ou se deixaram de funcionar por falha na comunicação no enlace.

Para solucionar tais problemas, algoritmos projetados para RSSF devem poupar energia residual dos nós em sua formulação (VILLAS *et al.*, 2012; VILLAS, 2012). Consequentemente, os trabalhos da literatura vêm explorando o uso da correlação temporal, integrada na RSSF, como uma das possíveis soluções para prover eficiência energética na rede. Por correlação temporal, entende-se, por exemplo, que um evento detectado só é transmitido para o nó *sink*, caso haja uma variação significativa da leitura atual comparada com as leituras anteriores. Desta forma, a correlação temporal tem como objetivo utilizar os recursos escassos dos sensores, sem sobrecarregá-los, para transmitir as informações em menor quantidade de maneira oportunista. Apesar desta solução ser viável para as RSSFs, no contexto desta pesquisa ainda há a necessidade dos nós atuarem no ambiente. Por isso, a RSASF surge como uma solução promissora para ser utilizada no SAR. Contudo, a implantação da RSASF como infraestrutura no SAR gera novos desafios. Por isso, os conceitos das RSASFs e os seus desafios são discutidos a seguir.

2.2 Redes de sensores e atuadores sem fio

Como dito anteriormente, as RSSFs oferecem soluções valiosas mediante as informações providas dos nós sensores. Geralmente, tais informações são processadas em um nó *sink* para detectar eventos de interesse. Entretanto, as informações são enviadas apenas em um sentido, isto é, dos nós sensores para o nó *sink*. Além disso, em algumas aplicações (por exemplo, automação residencial) é desejável que o nó atue ativamente no ambiente em que está inserido, em vez de apenas monitorá-lo passivamente. Nesse contexto, a inserção de nós atuadores faz surgir a Rede de Sensores e Atuadores sem Fio (RSASF) (AKYILDIZ; KASIMOGLU, 2004; VILLAS, 2007; BOUKERCHE; ARAUJO; VILLAS, 2007; VERDONE DAVIDE DARDARI; CONTI, 2008). Os objetivos de uma RSASF são: (i) observar um evento de interesse de uma aplicação; (ii) coletar os dados referente a esse evento; (iii) enviar os dados desse evento para um nó atuador usando normalmente a comunicação *multihop*; (iv) processar tais dados dentro e/ou fora da rede; (v) tomar decisões com base no evento; e (vi) executar as ações apropriadas. Consequentemente, a RSASF torna-se parte integrante de vários sistemas, tais como vigilância, monitoramento ambiental, automação residencial e predial, permitindo as trocas de informações nos dois sentidos, além de poder atuar ativamente no ambiente.

Na RSASF há duas classes de nós (sensor e atuador), diferentemente da RSSF (sensor) (AKYILDIZ; KASIMOGLU, 2004). Tipicamente, os nós sensores e atuadores têm responsabilidades distintas como monitorar e atuar, respectivamente. Além disso, tais nós possuem as seguintes características que os diferenciam:

- *Sensor*. Nesta classe, o nó sensor é um dispositivo de baixo custo, com limitações no consumo de energia, sensoreamento, processamento e comunicação sem fio, podendo consistir de diversos

sensores para observar n eventos de interesse. Por esses motivos, a quantidade de nós sensores espalhados em uma região de interesse geralmente é maior do que os nós atuadores.

- **Atuador:** Nesta classe, o nó atuador é um dispositivo equipado com capacidade de processamento elevada, potência de transmissão alta e maior durabilidade na vida útil da bateria. Além disso, os nós atuadores podem ser móveis, abrangendo sua área de atuação. Similar ao nó sensor, o nó atuador também pode ser integrado com diferentes nós atuadores para executar n tarefas. Através da comunicação sem fio, bem como da sua capacidade de processamento, os nós atuadores podem coordenar e decidir as ações apropriadas com base nas informações recebidas dos nós sensores.

A Figura 3 apresenta uma arquitetura típica de uma RSASF, na qual os sensores são espalhados em uma determinada região de observação para coletar dados de interesse. Os dados coletados são transmitidos para os nós atuadores que também são implantados na região de observação. Além disso, um nó *sink* pode ser integrado para monitorar, decidir e atribuir tarefas, bem como realizar a comunicação da RSASF com a aplicação, podendo disponibilizar as informações coletadas para outras redes. Com base na capacidade dos nós (por exemplo, potência de transmissão e capacidade de processamento), a quantidade de sensores e atuadores implantados em uma região é divergente. Ainda, robôs (PESSIN *et al.*, 2014a) e veículos aéreos não tripulados (FAIÇAL *et al.*, 2016), por exemplo, podem ser considerados como nós atuadores, os quais percorrem a região de interesse para coletar dados dos sensores e, em seguida, atuar no ambiente.

Figura 3 – Nós sensores e atuadores espalhados em uma região de interesse com o intuito de sensoriar, atuar e enviar informações para uma estação de monitoramento.

Fonte: Elaborada pelo autor.

Em razão disso, a RSASF possui uma arquitetura com vários desafios e características únicas que são amplamente discutidas pela comunidade acadêmica (AKYILDIZ; VURAN, 2010; VILLAS *et al.*, 2013; GUIDONI *et al.*, 2014; FAIÇAL *et al.*, 2014a; ROCHA FILHO *et al.*, 2015a; BAI *et al.*, 2016; BOUDRIOUA *et al.*, 2016; RODRIGUES *et al.*, 2017) e que estão dentro do contexto desta pesquisa, sendo as principais:

- *Heterogeneidade.* Como os componentes das RSASFs são heterogêneos (por exemplo, sensores com recursos escassos ou atuadores mais robustos), a comunicação, o processamento e a capacidade de memória de cada um dos nós da rede difere de maneira significativa. Dessa forma, esquemas de alocações de tarefas eficientes que exploram tal heterogeneidade são obrigatórios. Além disso, há vários tipos de tráfegos, sendo necessário conjuntos heterogêneos de protocolos de rede, por exemplo, coordenação das informações entre os atuadores e os sensores, e vice-versa.
- *Requisito em tempo real.* Essencialmente, as RSASFs são sistemas de circuito fechado, uma vez que as decisões dos atuadores são tomadas de acordo com as entradas de dados dos sensores. Nesse cenário, muitas são as aplicações que requerem respostas rápidas por parte dos atuadores, sendo que os dados coletados dessas aplicações devem ser validados antes de agir no ambiente. Logo, garantias de comunicação em tempo real devem ser fornecidas mediante os protocolos de rede. Por exemplo, em um sistema de incêndio para uma *smart home*, quando for detectada uma combustão, os sensores devem enviar a origem e intensidade do fogo para os atuadores mais adequados, com o intuito de extinguir o incêndio antes que se torne incontrolável.
- *Coordenação.* Ao contrário de uma RSSF em que há uma entidade centralizadora (nó *sink*), desempenhando as funções de coletar e coordenar os dados, na RSASF uma nova entidade (nó atuador) é possível. Neste caso, as funções de coletar e coordenar os dados pode ocorrer entre o sensor-atuador ou atuador-atuador. Uma vez que vários atuadores podem agir sobre o mesmo ambiente, a coordenação entre sensor-atuador deve permitir que o sensor envie os dados de um evento para o atuador mais adequado. Após receber tais dados, o atuador precisa coordenar com outros (atuador-atuador) para tomar a decisão mais adequada, executando uma determinada ação.

É fundamental destacar que os desafios e as características citadas anteriormente contemplam os principais endereçados pela comunidade acadêmica de RSASF. Com o intuito de um melhor entendimento dos desafios citados na RSASF, a seguir as características e limitações da sua arquitetura são apresentadas.

2.2.1 Arquitetura da RSASF

Segundo Akyildiz e Kasimoglu (2004), Villas (2007), Akyildiz e Vuran (2010), em uma RSASF os nós sensores ao detectarem um evento proveniente de algum fenômeno físico, por exemplo, temperatura, em seu ambiente, podem: (i) transmitir os dados para o nó *sink*, o qual envia comandos de ações para os nós atuadores; ou (ii) transmitir diretamente os dados para o nó atuador que, ao processá-los, inicia uma ação apropriada no ambiente. Em virtude disso, Akyildiz e Vuran (2010) definem dois tipos de arquiteturas, ilustradas na Figura 4, para RSASF, a saber: (i) arquitetura semi-automatizada; e (ii) automatizada.

- *Arquitetura semi-automatizada.* Neste tipo de arquitetura, apresentada na Figura 4a, o nó *sink* representa uma entidade centralizadora, o qual é responsável por receber dados dos nós sensores, bem como coordenar o processo de atuação de todos os nós atuadores.
- *Arquitetura automatizada.* Neste tipo de arquitetura, apresentada na Figura 4b, os nós sensores transmitem os dados em direção aos nós atuadores que estão em seu alcance. Com isso, os nós atuadores podem coordenar entre si para decidir e realizar uma ação adequada. Assim, devido à

Figura 4 – Exemplo da arquitetura semi-automatizada e automatizada de uma RSASF

Fonte: Adaptada de [Akyildiz e Vuran \(2010\)](#).

inexistência de um controlador central (por exemplo, nó *sink*), os eventos detectados são distribuídos entre os nós atuadores, demonstrando, portanto, um modo de interpretação descentralizada, na qual cada nó atuador é responsável por interpretar os dados de sua região de atuação.

Convém salientar, portanto, que dependendo do tipo de aplicação a ser implantada em uma RSASF, uma das arquiteturas citadas anteriormente pode ser adotada, cada uma com sua vantagem e limitação. Uma das principais vantagens da arquitetura semi-automatizada, é sua semelhança com a arquitetura já utilizada em aplicações para as RSSFs. Desta forma, a maioria das soluções propostas para as RSSFs podem ser utilizadas nas RSASFs. Por isso, é razoável afirmar que propostas de algoritmos, bem como protocolos para a realização de tarefas de comunicação e coordenação na arquitetura semi-automatizada não é tão inovador. Além disso, dentre as limitações dessa arquitetura, destaca-se: (i) o aumento no atraso de entrega das ações, uma vez que é necessário passar pelo nó *sink*; (ii) o consumo desigual dos recursos, devido ao fluxo de dados próximos do nó *sink* ser mais abundante; e (iii) a possibilidade de um ponto único de falha, na qual a falha do nó *sink* afeta todas as tarefas na rede.

Por outro lado, a arquitetura automatizada, quando comparada com a arquitetura semi-automatizada, destaca-se por possuir: (i) baixa latência, pois as informações observadas são transmitidas para os nós atuadores que, diferente do nó *sink*, estão localizados mais próximos da região de interesse; (ii) maior durabilidade na vida útil da rede, uma vez que não há o roteamento para o nó *sink*; e (iii) menor consumo de recursos da rede, visto que as informações sobre o evento são transmitidas localmente para os nós atuadores, os quais estão em maior quantidade do que o nó *sink* e, como consequência, a carga da rede é distribuída entre os nós, resultando assim, em uma economia de recursos, como largura de banda e energia, por exemplo.

No que diz respeito aos sistemas residenciais, a arquitetura automatizada traz vantagens importantes, como as citadas anteriormente. Contudo, apesar de tais vantagens, estabelecer uma distribuição mais homogênea na comunicação, mantendo uma baixa latência na atuação, com o intuito de reduzir o consumo de energia nos nós, é um campo de pesquisa promissor com grandes desafios que esta tese explora nos sistemas residenciais. Portanto, soluções projetadas para reduzir o consumo de energia, considerando

tais restrições devem ser consideradas na implantação de um sistema residencial. Além disso, devido às características de um ambiente doméstico (por exemplo, controle e tomada de decisão), as técnicas de Aprendizado de Máquina possuem aspectos particulares para o desenvolvimento desta tese, como apresentado a seguir.

2.3 Aprendizagem de máquina

Segundo [Mitchell \(1997\)](#), Aprendizado de Máquina (AM) é uma subárea da Inteligência Artificial cuja finalidade é desenvolver técnicas para adquirir conhecimento de forma automática em um sistema. O desenvolvimento de tais técnicas tem como objetivo aprender e realizar tarefas que sejam comparáveis, ou até mesmo superiores, à de um especialista na área em questão ([NIKOLOPOULOS, 1997](#); [PESSIN, 2013](#)).

Em termos gerais, há duas categorias de aprendizado, sendo elas: (i) o aprendizado supervisionado, no qual cada valor de entrada requer um valor alvo correspondente que represente o resultado desejado ([MITCHELL, 1997](#); [HAYKIN, 1998](#); [HAYKIN, 2009](#); [PRATAP; SHELJA, 2013](#)); e (ii) o aprendizado não-supervisionado, no qual cada valor de entrada não necessita de um valor alvo correspondente ([MITCHELL, 1997](#); [HAYKIN, 1998](#); [HAYKIN, 2009](#); [PRATAP; SHELJA, 2013](#)). Ainda dentro do contexto de categoria, [Monard e Baranauskas \(2003\)](#) organizam em cinco classes os paradigmas de AM, a saber: (i) Paradigma simbólico, o qual representa o problema mediante exemplos e contra-exemplos em uma estrutura simbólica para construir o conhecimento, tais como Árvore de Decisão, Expressões Lógicas e Regras; (ii) Paradigma estatístico, o qual utiliza modelos estatísticos para encontrar uma hipótese que se aproxima do conceito induzido, como Aprendizado Bayesiano; (iii) Paradigma baseado em exemplos, o qual classifica um exemplo nunca visto a partir de um padrão, como *K-Nearest Neighbor*; (iv) Paradigma conexionista, o qual desenvolve modelos computacionais de aprendizado inspirado no modelo biológico do sistema nervoso, como Redes Neurais Artificiais (RNA); e (v), por fim, o paradigma evolutivo, o qual desenvolve modelos computacionais de aprendizado baseado na evolução biológica das espécies, como Algoritmos Genéticos.

No contexto desta pesquisa, as técnicas de AM possuem características intrínsecas para as soluções desta tese. Além disso, nos últimos anos, as técnicas de AM têm sido usadas em vários problemas reais envolvendo a análise automática dos dados ([SPINOSA, 2008](#); [SOUZA et al., 2012](#); [PESSIN et al., 2014a](#); [CARVALHO et al., 2016](#); [JÚNIOR et al., 2017](#)), principalmente para a implantação de casas inteligentes ([BEGG; HASSAN, 2006](#); [ROCHA FILHO et al., 2014](#); [DAWADI; COOK; SCHMITTER-EDGEcombe, 2016](#); [JAVED et al., 2017](#); [SINGH et al., 2017](#)). Convém salientar, entretanto, que tais técnicas possuem limitações quando aliadas às RSASFs devido à escassez de recurso computacional. Por exemplo, o aprendizado Bayesiano apesar da sua rapidez, apresenta desempenho que depende dos recursos de entrada e da seleção da hipótese inicial para gerar o modelo ([BEGG; HASSAN, 2006](#)). Outro exemplo são os processos markovianos ([MARKOV, 1971](#)) que possuem ineficiência ao lidar com um grande número de sensores, gerando redes muito complexas ([RIVERA-ILLINGWORTH; CALLAGHAN; HAGRAS, 2005](#); [BEGG; HASSAN, 2006](#)). Já o uso de regra, além de apresentar indicativo de aumento de memória à medida que novas aplicações são inseridas na rede ([FARIAS et al., 2014](#)), possui a necessidade de um conhecimento especializado.

Em contraste com as outras técnicas, a RNA é relativamente simples de ser aplicada para a maioria dos problemas do mundo real (CASIMIR *et al.*, 2006; PESSIN *et al.*, 2014b; MENEGUETTE *et al.*, 2016; CARVALHO *et al.*, 2016). Além disso, a RNA possui uma melhor adaptabilidade com o problema de automatização (BEGG; HASSAN, 2006), tornando-a adequada para ser utilizada em ambientes domésticos inteligentes. Ainda, a RNA não apresenta indicativo de aumento de memória (veja Seção 4.3.2 do Capítulo 4) e, finalmente, o seu resultado em se tratando de eficiência na tomada de decisão em outras áreas de pesquisa é promissor, por exemplo, localização *indoor* (PESSIN *et al.*, 2014a; CARVALHO *et al.*, 2016). Em razão do exposto anteriormente, optou-se por explorar a RNA como solução para esta tese. Portanto, a seguir são apresentados os conceitos utilizados para agrupar os dados disseminados da RSASF com o intuito de atuar no ambiente residencial.

2.3.1 Redes neurais artificiais

A Rede Neural Artificial (RNA), também conhecida simplesmente como Rede Neural, é um método de classificação inspirado no conceito de neurônios biológicos (MITCHELL, 1997; MCCULLOCH; PITTS, 1943; BEGG; HASSAN, 2006; HAYKIN, 2009). Uma das principais características que a RNA possui está relacionada com a sua capacidade de aprendizagem, generalização e adaptação para novas situações (MITCHELL, 1997).

Tipicamente, uma RNA é caracterizada pela: (i) maneira como os neurônios são ligados uns aos outros; (ii) o método utilizado para determinar as forças de conexão, conhecido como pesos; e (iii) a função de ativação, a qual é utilizada para processar as informações. A Figura 5 apresenta um modelo de um neurônio que serve como base para projetar uma RNA.

Figura 5 – Exemplo de um neurônio artificial de McCulloch e Pitts (1943).

Fonte: Adaptada de Braga, Carvalho e Ludermir (2000).

De acordo com McCulloch e Pitts (1943), um neurônio k contém n terminais de entrada ($e_1, e_2, e_3, \dots, e_n$), os quais possuem um peso $\{W_i, i \in E\}$ correspondente. Em outras palavras, um neurônio pode compor várias entradas, no entanto fornece apenas uma saída. A menos que indicado de outra maneira, o conjunto E é a quantidade de terminais de entrada denotado pelo conjunto dos números inteiros não negativos $\{E \subset \mathbb{Z}^+\}$. Dessa forma, é possível gerar uma saída linear net_k (Equação 2.1) mediante a soma ponderada das entradas e_i com os seus respectivos pesos w_i . Com a saída linear net_k , aplica-se uma função $f_k(net_k)$, conhecida na literatura como função de ativação, para gerar a saída y do neurônio k , ou seja y_k (Equação 2.2).

$$net_k = \sum_i w_{ki} e_i \quad (2.1)$$

$$y_k = f_k(net_k) \quad (2.2)$$

Convém salientar, como apresentado na Figura 6, que há diferentes tipos de funções de ativação, sendo as principais: (i) linear; (ii) sigmóide logística; e (iii) tangente hiperbólica. A função linear (Figura 6a) pode ser restringida para gerar valores constantes entre $[-1, 1]$. Já a função sigmóide logística (Figura 6b) possui valores constantes em uma faixa de $[0, 1]$. Por fim, a função tangente hiperbólica (Figura 6c) possui valores constantes entre $[-1, 1]$.

Figura 6 – Exemplos de diferentes tipos de funções de ativações para processar as informações nos neurônios.

Fonte: Elaborada pelo autor.

Após a formulação das unidades básicas dos neurônios de McCulloch e Pitts (1943), Rosenblatt (1958) propôs o conceito de aprendizado com o *Perceptron*. Por ser um classificador que lida com problemas que sejam linearmente separáveis e devido às críticas recebidas de Minsky e Papert (1987) pelo *Perceptron*, o aprendizado em redes neurais entrou em inércia, como ressaltado por Braga, Carvalho e Ludermir (2000). Entretanto, com o intuito de permitir soluções mais usuais que não sejam linearmente separáveis, Rumelhart, McClelland e Group (1986) apresentaram com o algoritmo de aprendizado *Backpropagation* uma RNA do tipo *Multi-Layer Perceptron* (MLP).

A Figura 7 apresenta uma arquitetura típica de uma RNA do tipo MLP com três camadas, sendo a camada de entrada responsável por inserir os dados na rede, a camada escondida por determinar padrões de regiões de aprendizado, e a camada de saída por fornecer o resultado dos dados inseridos. Além disso, é necessária uma etapa de aprendizado para correlacionar os dados de entrada com a saída desejada. Em outras palavras, é necessário estimar os pesos w dos neurônios que conectam a rede. Para isso, são utilizados algoritmos de aprendizado como o *Backpropagation*, o qual baseia-se nos neurônios de entrada e saída para ajustar os pesos da rede (RUMELHART; MCCLELLAND; GROUP, 1986).

Basicamente, o aprendizado do algoritmo *Backpropagation* consiste em duas etapas (revisita a Figura 7), a saber: (i) *forward*; e (ii) *backward*. Na etapa de *forward*, os dados são propagados da camada de entrada até a camada de saída para obter, dado um padrão de entrada, a saída fornecida y_f da rede. Já na etapa de *backward*, utiliza-se a saída fornecida da etapa anterior subtraída da saída desejada y_d para encontrar o erro, o qual é propagado, em sentido contrário ao *forward*, para ajustar os pesos da rede. Esse

Figura 7 – Representação de uma RNA do tipo MLP com o algoritmo de aprendizado *Backpropagation*.

Fonte: Elaborada pelo autor.

processo pode ocorrer por várias épocas ou até encontrar uma condição de parada, por exemplo, um erro quadrático menor do que um valor pré-determinado.

Um dos principais problemas dessa abordagem é o grau de generalização. Se o aprendizado for feito por uma quantidade elevada de épocas (PESSIN, 2013) ou se a condição de parada for muito pequena, pode gerar o chamado *overfitting* (REED, 1993). Isso é, a RNA começa a fixar saídas que não estão na base de treino. Assim, a RNA não obterá características essenciais para generalizá-la, equivocando sua saída para casos que não foram praticados. Para resolver tal problema, os trabalhos da literatura usam como solução uma base de validação (PESSIN, 2013) juntamente com métodos de amostragem (ROCHA FILHO *et al.*, 2015b), tais como *k-fold cross-validation* ou *hold-out*.

Figura 8 – Exemplo de funcionamento da RNA para a tomada de decisão.

Fonte: Elaborada pelo autor.

Para entender como uma RNA pode ser utilizada nesta pesquisa, considere o exemplo da Figura 8. Nesse cenário, há vários sensores implantados em uma casa para coletar dados do residente, inclusive pode-se utilizar o *smartphone* para obter a sua preferência. A partir dos dados coletados dos sensores

e/ou do *smartphone*, utiliza-se a classificação da RNA como medida para a tomada de decisão. Logo, essa informação é utilizada para propagar a disseminação do evento com o intuito de atuar na aplicação desejada mediante nós atuadores.

2.4 Considerações finais

Neste capítulo, foram abordados os principais conceitos para fornecer subsídios a esta tese. Em razão disso, foi dada uma maior ênfase nos conceitos de sensores e atuadores sem fio, bem como em exemplos e técnicas de Aprendizado de Máquina que estão diretamente relacionados com esta pesquisa. A partir dos conceitos apresentados, os principais desafios a serem superados de cada tema foram elencados. Além disso, convém salientar que algumas características particulares de cada tema, tais como parâmetros, métodos e sensores utilizados, serão apresentados e justificados nos Capítulos 4 e 5. No próximo capítulo, será apresentada uma revisão sistemática na área de automação residencial com o intuito de identificar e validar as lacunas para esta pesquisa.

UMA REVISÃO SISTEMÁTICA EM SISTEMAS DE AUTOMAÇÃO RESIDENCIAL: INFRAESTRUTURA E PROCESSO DE TOMADA DE DECISÃO

Neste capítulo, é apresentada uma investigação do estado da arte em sistemas residenciais inteligentes, bem como os seus desafios com o objetivo de **i)** identificar lacunas para esta tese; e **ii)** nortear novos projetos de pesquisa na área de automação residencial. Para isso, realizou-se uma revisão sistemática para analisar as publicações científicas, classificando-as e agrupando-as de acordo com suas semelhanças e diferenças por meio da elaboração de um protocolo. Ao elaborar o protocolo, houve a preocupação de incluir o máximo possível de estudos para evitar o risco de qualquer distorção que pudesse levar a conclusões errôneas, considerado um problema típico de uma revisão bibliográfica não sistemática (BIOLCHINI *et al.*, 2005). Inicialmente, é apresentada a tendência de crescimento dos sistemas residenciais inteligentes e a maneira como foi conduzida esta revisão sistemática. Em seguida, são analisados os trabalhos selecionados, seguida de uma discussão das lacunas de pesquisa identificadas. Finalmente, são apresentadas as considerações finais deste capítulo.

3.1 Tendência de crescimento dos sistemas residenciais inteligentes

Esta seção apresenta a tendência de crescimento dos sistemas residenciais inteligentes e como foi realizada a condução desta revisão sistemática. Inicialmente, foi definida uma *string* de busca com o propósito de auxiliar no entendimento dos sistemas de automação residencial, bem como obter um panorama sobre o estado da arte. Para isso, utilizou-se a seguinte *string* de busca:

“home automation” OR domotic OR “smart home”

Após aplicar essa *string* de busca, notou-se que há uma ascensão para publicações nos últimos anos na área de sistema de automação residencial, como ilustrado na Figura 9. Particularmente no último ano, houve um crescimento de 23,9% para publicação quando comparado com o ano anterior (Figura 9). Essa tendência de crescimento ratifica a importância do sistema de automação residencial na comunidade acadêmica, a qual vêm adicionando novos esforços para investigar soluções nessa área. Vale frisar que a maioria das soluções estão concentradas em melhorar o conforto dos moradores, ao mesmo tempo em que maximiza a eficiência energética das suas casas. Para selecionar trabalhos mais relevantes, condizente com os objetivos desta tese, a *string* de busca foi reformulada como:

("home automation" OR domotic OR "smart home") AND infrastructure AND "decision-making" AND (sensor OR actuator) AND ("energy consumption" OR "energy efficiency" OR "energy management")

Figura 9 – Evolução da quantidade de publicações por ano de acordo com a primeira *string* de busca.

Fonte: Elaborada pelo autor.

Com base na *string* de busca reformulada, observou-se que as bases de dados retornaram um número expressivo de trabalhos para serem analisados. Para seleção e, posteriormente, análise dos trabalhos, foram utilizados os seguintes Critérios de Inclusão (CI): (i), CI 1, trabalhos que apresentaram o modelo da infraestrutura adotada para a coleta de dados; (ii), CI 2, trabalhos que apresentaram soluções para o processo de tomada de decisão; (iii), CI 3, trabalhos que apresentaram a integração do processo de tomada de decisão com a infraestrutura; e (iv), CI 4, trabalhos que apresentaram as aplicações e os tipos de sensores.

A partir dos trabalhos retornados, 30 estudos primários foram identificados para serem lidos na íntegra com base nos títulos e resumos. Em virtude de uma leitura mais aprofundada, 11 trabalhos foram excluídos ao serem confrontados com o objetivo desta revisão sistemática. Dessa forma, 19 trabalhos foram selecionados como sendo os mais relevantes. Os trabalhos analisados são apresentados na Tabela 1 de acordo com os CIs. Na Tabela 1, considerando o CI 1, observa-se que 28% dos trabalhos usam a infraestrutura da rede para coleta de dados. Considerando o CI 2, 28% dos trabalhos apresentam soluções para o processo de tomada de decisão. Entretanto, vale salientar que apenas 09% dos trabalhos realizam a integração do processo de tomada de decisão com a infraestrutura de controle da rede, CI 3. Além disso, os resultados da análise indicam que 35% dos trabalhos apresentaram as aplicações e os tipos de

sensores utilizados, CI 4. A Figura 10 apresenta a relação entre as aplicações e os tipos de sensores mais usados (KANG *et al.*, 2016).

Tabela 1 – Conjunto de trabalhos selecionados que foram analisados.

Critério de Inclusão	Trabalhos Selecionados
CI 1	(LIN <i>et al.</i> , 2002), (MINENO <i>et al.</i> , 2010), (MANTORO; AYU; ELNOUR, 2011), (FENSEL <i>et al.</i> , 2013), (BARAKA <i>et al.</i> , 2013), (MAHMOOD <i>et al.</i> , 2014), (FARIAS <i>et al.</i> , 2014), (KHAN; SILVA; HAN, 2016), (WU <i>et al.</i> , 2017)
CI 2	(TOMIC; FENSEL; PELLEGRINI, 2010), (TANG; CIUCIU, 2012), (FENSEL <i>et al.</i> , 2013), (LEE <i>et al.</i> , 2014), (ROCHA FILHO <i>et al.</i> , 2014), (FARIAS <i>et al.</i> , 2014), (MING <i>et al.</i> , 2016), (IRVAN; TERANO, 2017), (KAZARIAN <i>et al.</i> , 2017)
CI 3	(TOMIC; FENSEL; PELLEGRINI, 2010), (SENDRA <i>et al.</i> , 2014), (FARIAS <i>et al.</i> , 2014)
CI 4	(DITTAWIT; AAGESEN, 2013), (BARAKA <i>et al.</i> , 2013), (RAMLEE <i>et al.</i> , 2013), (MAHMOOD <i>et al.</i> , 2014), (SENDRA <i>et al.</i> , 2014), (FARIAS <i>et al.</i> , 2014), (MING <i>et al.</i> , 2016), (KHAN; SILVA; HAN, 2016), (IRVAN; TERANO, 2017), (WU <i>et al.</i> , 2017), (KAZARIAN <i>et al.</i> , 2017)

Deve-se ressaltar que os trabalhos selecionados para análise possuem poucas pesquisas colaborativas e estão sendo desenvolvidos por grandes grupos de pesquisa. Isso traz alternativas promissoras para investigação nessa área. Por exemplo, por meio de uma visão holística, observou-se que as RSASFs podem ser usadas como infraestruturas de controle no processo de tomada de decisão. Entretanto, nesta revisão sistemática notou-se que a implantação de uma RSASF como uma infraestrutura de controle nos sistemas residenciais geraram novos desafios. Tais desafios foram analisados em duas frentes: (i) soluções de infraestruturas adotadas para a comunicação de dados, Seção 3.2; e (ii) soluções adotadas para realizar o processo de tomada de decisão, Seção 3.3. Além disso, a Seção 3.4 apresenta uma discussão dos desafios e questões de pesquisas que esta tese investiga. No Apêndice A, são apresentados os detalhes adicionais do protocolo elaborado para esta revisão sistemática.

Figura 10 – Relação entre as aplicações e os tipos de sensores utilizados.

Fonte: Kang *et al.* (2016).

3.2 Infraestruturas adotadas para comunicação de dados

Por meio da análise da revisão sistemática, convém salientar que os sistemas de automação residencial possuem uma forte dependência em relação a sua rede interna. Além disso, fornecer uma infraestrutura adequada para gerenciar os diferentes recursos habitacionais em uma residência não é uma tarefa trivial, principalmente quando os moradores não são especialistas nessa área. Nesta sistemática, as infraestruturas para gerenciar os sistemas residenciais foram classificadas em cabeada, híbrida e sem fio, como apresentada na Figura 11. Cada infraestrutura possui limitações que são fundamentais para decidir sobre o seu uso. A seguir são apresentados os tipos de infraestruturas utilizadas nos sistemas residenciais inteligentes.

Figura 11 – Fluxo de processo das limitações identificadas nas infraestruturas de comunicação de dados no contexto residencial.

Fonte: Elaborada pelo autor.

3.2.1 Infraestrutura cabeada para comunicação de dados

Inicialmente, a infraestrutura da rede interna de uma residência era totalmente cabeada (LIN *et al.*, 2002; FENSEL *et al.*, 2013; JIANG; LIU; YANG, 2004), gerando uma série de dependências no ambiente, além de ser custosa e com topologia irregular. Por exemplo, o uso de uma infraestrutura cabeada como um meio de comunicação limita o grau de flexibilidade para suportar novas aplicações de diferentes fornecedores. Isso ocorre porque os fornecedores não propõem um padrão comum entre eles. Além disso, o limite de comunicação do cabo afeta o alcance da infraestrutura de controle (GöKCELI; KURT; ÖRS, 2016) no interior da residência. Consequentemente, as atualizações em amplas escalas tornam a implementação da infraestrutura cabeada difícil de ser completada (GöKCELI; KURT; ÖRS, 2016), além de poder causar problemas na estrutura da residência. Portanto, redirecionar os cabos já existentes na residência ou acrescentá-los na infraestrutura é um processo oneroso. Outro ponto que pode

ser levado em consideração, é a falta de mobilidade da infraestrutura cabeada com os dispositivos móveis, por exemplo *smartphone* e *smartwatch*. Isso ocorre pois cada vez mais há uma necessidade dos sistemas residenciais inteligentes alcançarem uma maior cobertura e mobilidade, ao invés de possuir somente um grupo de dispositivos cabeados conectados a um concentrador. Portanto, a infraestrutura cabeada tornou-se menos usada como infraestrutura de controle em um ambiente residencial.

Especificamente em [Lin et al. \(2002\)](#), é proposta uma infraestrutura com o uso de *Power Line Communication* (PLC) para a construção de casas inteligentes, nas quais os equipamentos eletrônicos estão interligados pelos próprios fios que lhes fornecem energia. O intuito é investigar o uso da fiação elétrica existente como meio de comunicação para os equipamentos eletrônicos. Como o PLC utiliza a linha de energia como meio de comunicação, consequentemente vários dispositivos compartilham um único meio de comunicação para disseminar dados ao mesmo tempo. Nesse cenário, o PLC além de poder ser passível de interferência nos dispositivos que estão ao seu redor, possui uma alta atenuação de sinal ([USMAN; SHAMI, 2013](#)), ([ZHILENKOV et al., 2017](#)). Tais características tornam o PLC problemático de ser implantado na prática, pois é realístico admitir que há vários dispositivos que disseminam dados e estão localmente próximos em um ambiente residencial. Em razão disso, haverá uma alta taxa de perda de dados, problemas de interoperabilidade e compatibilidade com outras tecnologias de comunicação, tornando o PLC pouco promissor em um ambiente residencial.

Já em [Fensel et al. \(2013\)](#), é apresentada uma arquitetura de *hardware* que possui diferentes tipos de sinais de entrada (por exemplo, analógico, digital, saída de relé) para aquisição de dados, os quais são transmitidos via Ethernet para serem processados em um controlador. O controlador por sua vez possui um módulo para conectar diferentes sensores e atuadores, além de gerenciar o controle da casa remotamente e fornecer respostas mais rápidas em caso de emergência. Entretanto, como ressaltado anteriormente, o uso da infraestrutura cabeada como meio de comunicação limita a flexibilidade da infraestrutura para suportar novas aplicações dos fornecedores. Além disso, há uma limitação para implantar a rede internamente, caso a fiação seja escassa, e consequentemente um custo adicional. Neste último caso, a infraestrutura cabeada pode tornar-se impraticável, haja vista que o seu custo é de 50% a 90% maior quando comparado com uma infraestrutura sem fio ([MANTORO; AYU; ELNOUR, 2011](#)).

3.2.2 Infraestrutura híbrida para comunicação de dados

Com os avanços na área de micro sistemas eletro-mecânicos, a rede interna de uma residência passou a ser composta por tecnologia de rede com fio (X10, PLC e LAN) e sem fio (ZigBee, Bluetooth e Wi-Fi), formando uma infraestrutura híbrida ([MINENO et al., 2010](#); [BARAKA et al., 2013](#); [RAMLEE et al., 2013](#)). Tal infraestrutura surgiu como uma solução atraente para sanar alguns dos problemas da infraestrutura cabeada, por exemplo, a falta de mobilidade. Entretanto, a capacidade de integração limitada entre as infraestruturas, a escassez de padronização entre os dispositivos (cabeado e sem fio) e o possível problema de escalabilidade são alguns dos assuntos que ainda necessitam de investigações.

Particularmente em [Mineno et al. \(2010\)](#), é proposto um sistema de gerenciamento de energia adaptativo usando a convergência de redes de sensores/atuadores heterogêneas baseada em tecnologia de comunicação com fio (PLC) e sem fio (Wi-Fi e ZigBee). Para tanto, desenvolveu-se um protótipo com o intuito do morador configurar por meio de um dispositivo móvel, um trabalho cooperativo entre os

eletrodomésticos e a infraestrutura. Para realizar a integração dos eletrodomésticos com a infraestrutura, utilizou-se o *Peer-to-Peer Universal Computing Consortium* (PUCC) (SUMINO *et al.*, 2007). O PUCC permite que os sensores/atuadores e todos os outros dispositivos se conectem uns aos outros, descobrindo o serviço e o dispositivo utilizado através de uma rede *Peer-to-Peer*.

Também considerando uma infraestrutura híbrida, Baraka *et al.* (2013) propõem a concepção, o desenvolvimento e a implementação de um sistema de automação residencial para controlar remotamente o ambiente de uma residência. Para tanto, nós sensores e atuadores são utilizados, os quais se comunicam mediante protocolo de comunicação ZigBee sem fio e X10 com fio. Os dados coletados dos sensores são encaminhados para um controlador central, o qual pode interagir com o morador por meio de uma aplicação para a plataforma Android. Além disso, o controlador central pode sugerir o agendamento de tarefas, caso tarifas de energia elétrica diferenciadas sejam empregadas.

Apesar das abordagens citadas sanarem alguns problemas relacionados à infraestrutura cabeada, suas soluções possuem duas principais limitações que são comuns e merecem ser destacadas. A primeira limitação está relacionada após a implantação da infraestrutura, a qual dificulta tanto a interoperabilidade com outros *backbones* quanto a integração com novos dispositivos. Em outras palavras, possui um comportamento específico, e não genérico, dificultando assim sua adaptação a mudanças no ambiente. Já a segunda limitação recai no problema de complexidade do sistema, e possivelmente de escalabilidade, a medida que novos dispositivos e tecnologias de comunicação são adicionados na infraestrutura.

3.2.3 Infraestrutura sem fio para comunicação de dados

Atualmente, tem-se investigado o potencial uso da tecnologia de rede sem fio, presente na RSASF como infraestrutura interna de uma residência (MANTORO; AYU; ELNOUR, 2011; MAHMOOD *et al.*, 2014; ROCHA FILHO *et al.*, 2014; KHAN; SILVA; HAN, 2016; WU *et al.*, 2017). A infraestrutura sem fio tem sido uma alternativa promissora para comunicação de dados nos sistemas residenciais inteligentes. Tal infraestrutura não requer fiação para conectar um novo dispositivo ou integrar-se a outra rede. Além disso, é possível garantir mobilidade e escalabilidade no ambiente monitorado.

Em Mantoro, Ayu e Elnour (2011), é proposto um *framework* modelado com base em uma infraestrutura sem fio. Para uma prova de conceito do *framework*, foi desenvolvido um protótipo chamado *Integ's smart home*. O *Integ's smart home* permite ao morador monitorar e controlar as condições da sua residência por meio de um dispositivo móvel (por exemplo, *smartphone*, *iPhone* e PDA) habilitado para a Internet. Para tanto, são utilizados três componentes de *hardware*: (i) o nó cliente, o qual é colocado em pontos estratégicos de energia; (ii) o nó mestre/servidor, o qual delega comandos para a rede; e (iii) o roteador/*switch*, o qual comunica-se com qualquer dispositivo habilitado para o Wi-Fi. Desta forma, cria-se uma RSASF para coletar dados do ambiente e controlá-lo de acordo com a estratégia do morador. A escalabilidade dessa solução é possível, no entanto, pode ocorrer perda de mensagens devido ao problema de desvanecimento múltiplo (*multipath fading*). Além disso, a antena omnidirecional tem o fenômeno da reflexão, podendo gerar múltiplos caminhos entre o transmissor e o receptor.

Ainda considerando a infraestrutura sem fio como solução para os SARs, Mahmood *et al.* (2014) propõem o *Home Appliances Coordination Scheme for Energy Management* (HACS4EM). O HACS4EM tem como objetivo reduzir o custo da energia da casa do morador, deslocando o funcionamento

dos eletrodomésticos mediante o valor das tarifas de energia. Para isso, o HACS4EM estabelece uma comunicação entre os eletrodomésticos e uma unidade de gestão de energia central que é responsável pelo processamento da infraestrutura. Para realizar a comunicação, utilizou-se o protocolo ZigBee para transmitir as mensagens entre as entidades envolvidas no HACS4EM. Portanto, o consumidor pode ligar qualquer eletrodoméstico a qualquer momento e, em seguida, o HACS4EM sugere a hora de uso mais adequada. Tipicamente, no ambiente residencial, os dados disseminados são inesperados devido a interação do usuário com o ambiente. Portanto, a solução analisada poderia propor o desenvolvimento de padrões que permitam lidar de maneira dinâmica com a disseminação confiável dos dados para o sistema.

Em [Khan, Silva e Han \(2016\)](#), é apresentado um sistema de controle para resolver três desafios enfrentados por casas inteligentes que são baseadas na comunicação sem fio. O primeiro desafio está relacionado com a alta taxa de perda de pacotes, o qual é resolvido com um mecanismo de controle ciente de interferência. O segundo desafio está relacionado com o uso da luz natural para o processo de economia de energia, o qual é resolvido pela relação da localização dos moradores e da luz solar para otimizar o uso dos aparelhos eletrônicos, bem como a luz interna da residência. Por fim, o terceiro desafio está relacionado com o consumo indevido de energia dos aparelhos eletrônicos, o qual é resolvido por um sistema de gerenciamento central que controla o tempo de funcionamento dos aparelhos. A proposta, nomeada de CoZNET, usa dados históricos para ligar/desligar os aparelhos eletrônicos de acordo com a localização dos moradores. O CoZNET considera aparelhos eletrônicos comuns, por exemplo, geladeira, máquina de lavar, televisão e HVAC. Para cada aparelho, o ciclo de operação e o consumo de energia de cada fase são considerados para o problema de otimização. Com isso, é possível estabelecer uma agenda dinâmica de acordo com o uso do morador e o perfil de energia dos aparelhos eletrônicos da residência. O CoZNET usa a distância entre os pontos de acesso do Wi-Fi e sensores ZigBee para minimizar a interferência. Uma limitação do CoZNET é a comparação com outras soluções de agendamento, uma vez que utilizou-se uma RSSF pura para comparar os resultados obtidos.

[Wu et al. \(2017\)](#) propõem o uso de uma rede ZigBee em um roteador sem fio para monitorar e controlar as aplicações dos sistemas residenciais inteligentes. O roteador sem fio permite que os dados dos dispositivos sejam gerenciados de maneira eficiente e com interoperabilidade. Ainda, o roteador sem fio é um concentrador de dados. Assim, quando um dispositivo inteligente é adicionado na rede, a sua informação básica é transmitida para o roteador. Consequentemente, o roteador pode monitorar ou controlar o dispositivo adicionado. A solução adota uma arquitetura centralizada e, devido a essa característica, duas limitações podem ser destacadas: (i) se o roteador falhar, todo o sistema fica inoperante; e (ii) se os dispositivos transmitirem dados ao mesmo tempo ou se houver uma alta densidade de dispositivo, pode haver sobrecarga no roteador e, consequentemente, perdas de dados.

3.3 Soluções adotadas para realizar o processo de tomada de decisão

Um sistema de automação residencial deve ter a capacidade de identificar a preferência do morador, propondo tomadas de decisões para auxiliá-lo, de forma inteligente, em seu benefício ([SIANO et al., 2013](#)). Em virtude disso, o SAR deve otimizar o seu funcionamento para a escolha da melhor ação,

a qual é gerada por meio dos dados providos pelos sensores e aplicada através dos atuadores. Contudo, convém salientar que o processo para a escolha da melhor ação não é uma tarefa trivial. Cada aplicação possui um padrão comportamental diferente, o qual pode ser alterado dependendo da sua interação com o morador ou do período do ano em que é utilizada. A Figura 12 apresenta as limitações encontradas no processo de tomada de decisão no contexto residencial. As subseções 3.3.1 e 3.3.2 apresentam as soluções analisadas com uma discussão das limitações encontradas que esta tese investiga.

Figura 12 – Fluxo de processo das limitações identificadas nas tomadas decisões no contexto residencial.

Fonte: Elaborada pelo autor.

3.3.1 Soluções específicas e ações predeterminadas

Os trabalhos descritos em Sendra *et al.* (2014), Teich *et al.* (2014) e Ramlee *et al.* (2013) propõem sistemas específicos para apenas uma aplicação, tais como temperatura, iluminação e eletrodomésticos. Particularmente em Sendra *et al.* (2014), é apresentado um sistema de automação residencial para gerenciar os eletrodomésticos. O sistema é baseado em um aplicativo móvel (por exemplo, *smartphone* ou *tablet*) que pode atuar como servidor. O aplicativo além de permitir a programação do eletrodoméstico (neste caso, a máquina de lavar), também é capaz de gerenciar o estado do aparelho e o custo do seu consumo energético. No cenário de sistemas cibernéticos, presente em um SAR, explorar dados heterogêneos de outras fontes (dados web e mídias sociais) auxilia a melhorar o processo de tomada de decisão (FARIAS *et al.*, 2017). Com isso, o uso dos dados locais com outras fontes externas podem ser utilizados para realizar predição na programação de um eletrodoméstico ou detecção de mau uso dos aparelhos para tomadas de decisões.

Ainda voltado para os sistemas de uma aplicação específica, os autores em Ramlee *et al.* (2013) propuseram um sistema de automação residencial de baixo custo voltado para os eletrodomésticos. O sistema é projetado para auxiliar os moradores a satisfazer suas necessidades em sua casa. Para tanto, uma placa de controle principal (nó *sink*) é desenvolvida para gerenciar a comunicação entre os eletrodomésticos

e os moradores. Dessa forma, o nó *sink* disponibiliza as informações para os moradores, os quais decidem sobre as ações no ambiente. Tais informações são disponibilizadas por meio de dispositivos móveis (*laptop* ou *smartphone*, por exemplo) que possuem conexão sem fio *Bluetooth* e/ou com fio USB. Entretanto, o sistema poder ser vulnerável a sobrecarga de dados por ser centralizado.

Embora haja trabalhos sobre a composição de mais de uma aplicação, tais trabalhos utilizam os sensores apenas como infraestrutura para a coleta de dados, como propostos por [Dittawit e Aagesen \(2013\)](#), [Lee et al. \(2014\)](#) e [Tomic, Fensel e Pellegrini \(2010\)](#). Por isso, essas soluções não aproveitam os benefícios (por exemplo, processamento), ainda que reduzido, que os dispositivos possuem para a tomada de decisão. Em [Lee et al. \(2014\)](#), é proposto um sistema sensível ao contexto para ambientes residências ubíquos. Para tanto, os sensores são utilizados para monitorar as atividades dos moradores, a fim de atender suas necessidades com base em suas preferências. O objetivo dos sensores é representar o contexto do ambiente que é um elemento distinto de um serviço, neste caso o comportamento do morador. Portanto, utiliza-se os dados dos sensores como infraestrutura base para analisar os padrões dos moradores, gerando regras mediante as interpretações obtidas do ambiente. Nesse cenário, as aplicações poderiam ser utilizadas como elemento sensoreador virtual (modelo computacional capaz de fornecer uma informação lógica) para interagir com o ambiente monitorado. Consequentemente, tais aplicações poderiam intercomunicar-se para coletar dados e correlacioná-los com o propósito de melhorar a ação.

[Dittawit e Aagesen \(2013\)](#) propõem um *framework* funcional e um modelo de arquitetura abstrato para sistemas de gerenciamento de energia residencial. O objetivo do sistema é auxiliar os moradores a atingir o consumo de energia otimizado em sua residência, além de prover simplicidade e escalabilidade para uma rápida implantação. Para isso, um sistema central cujas as funções são realizadas por uma máquina de estados finitos e, um mecanismo de raciocínio baseado em políticas que faz parte do *framework* é responsável pela gestão de energia. Nesse contexto, não é uma tarefa simples determinar quais equipamentos eletrônicos têm maior influência em casa de acordo com o perfil do residente. Uma maneira seria monitorar individualmente cada equipamento eletrônico por meio de uma RSSF, conforme proposto por [ROCHA FILHO et al. \(2014\)](#). Com isso, é possível encorajar os consumidores a empregar estratégias eficientes para a redução do consumo de energia em cada equipamento eletrônico monitorado.

Outras soluções são limitadas a detectar algo ou controlar uma ação preestabelecida, tornando-as não versáteis para o processo de tomada de decisão. Em todo caso, analisam-se apenas os dados brutos obtidos dos sensores, como apresentado em [Teich et al. \(2014\)](#) e [ROCHA FILHO et al. \(2014\)](#). Nesse caso, os autores em [ROCHA FILHO et al. \(2014\)](#) propõem um método para detectar novidades no consumo de energia dos equipamentos eletrônicos, chamado Novelty Detection Power Meter (NodePM). Por novidade, entende-se que são anomalias que podem surgir quando um equipamento consome mais energia do que o esperado, ou quando um equipamento começa a apresentar um padrão comportamental anormal de acordo com o perfil do morador. O NodePM detecta dois tipos de novidades: (i) a qualitativa, a qual ocorre quando há uma mudança abrupta no comportamento padrão do equipamento eletrônico; e (ii) a quantitativa, a qual ocorre quando o equipamento eletrônico começa a consumir mais energia que o esperado durante um determinado período de tempo. Para isso, considera-se o grau de incerteza do consumo de energia de cada equipamento eletrônico, o qual é obtido mediante um modelo de cadeia de Markov que é gerado por meio do *K-Nearest Neighbors*. Portanto, é possível detectar novidades alertando os moradores quando é identificada uma anomalia no consumo de energia dos equipamentos eletrônicos.

3.3.2 Soluções com inteligência computacional

Outras linhas de pesquisas utilizam tecnologias semânticas, tais como ontologia, inferência e regras, como solução para o processo de aprendizagem na tomada de decisão. Particularmente em [Tomic, Fensel e Pellegrini \(2010\)](#) é proposto o SESAME, um sistema flexível que utiliza ontologias e raciocínio baseado em regras para gerenciar o sistema de gestão de energia residencial. O SESAME utiliza um *gateway* que é o núcleo do sistema para implantar a base de conhecimento. Nesse sentido, utilizou-se o *framework* Jena¹ para modelar a base de conhecimento, a qual utiliza dados reais de diferentes fontes de informações, tais como sensores, eletrodomésticos e perfil do usuário/fornecedor. Além disso, tal conhecimento é a base para gerar regras que complementam a ontologia nas atividades de automação da residência. Entretanto, o sistema pode necessitar de um especialista para gerar as regras. Além disso, adicionar novas regras na rede pode levar ao aumento de memória. Isso não é uma tarefa trivial de ser implantada dentro dos dispositivos que possuem recursos computacionais limitados, atributo presente nesta pesquisa.

No estudo de [Tang e Ciuciu \(2012\)](#), é proposto um *framework* voltado para a modelagem de uma Tabela de Decisão Semântica (TDS). O problema é como o *framework* proposto pode usar as ontologias para regras de decisão baseadas na comunidade, que precisam ser consistentes com base na agregação dos dados e no contexto coletado. Para sanar o problema, modelou-se uma TDS composta por uma base de ontologia para proporcionar regras de decisão. Neste caso, por exemplo, uma regra pode representar a decisão sobre se deve ou não ligar o ar condicionado com base na temperatura ou na presença de moradores. Para isso, uma ação é encaminhada para uma caixa de controle universal que é habilitada com uma TDS, a qual possui um motor de inferência baseado no TDS para o processo de tomada de decisão. Um dos caminhos para melhorar a solução é a distribuição dos serviços ou da SDT na infraestrutura. Entretanto, para não sobrecarregar a infraestrutura distribuída, é necessário identificar a situação do recurso computacional do dispositivo e, em seguida, determinar qual dispositivo é o ideal para processar os dados ou armazená-los. Outro caminho para melhorar a solução é a escolha do ambiente de execução (local ou remoto). Isso é viável para aplicações que necessitam de alto custo computacional. Assim, é possível aproveitar os recursos disponíveis do servidor remoto ou aproveitar os ciclos ociosos dos dispositivos locais para processar os dados e transformá-los em uma ação.

Outros trabalhos relacionados que merecem destaques no que diz respeito ao uso de tecnologias semânticas são apresentados em [Soares et al. \(2012\)](#), [Farias et al. \(2013\)](#) e [Farias et al. \(2014\)](#), sendo [Farias et al. \(2014\)](#) baseado nos trabalhos realizados por [Soares et al. \(2012\)](#) e [Farias et al. \(2013\)](#). Em contraste com as soluções que utilizam tecnologias semânticas, é válido ressaltar que [Farias et al. \(2014\)](#) distribuem o processo de controle e decisão das aplicações entre os nós da RSASF. Por isso [Farias et al. \(2014\)](#) propõem um sistema de CONtrole e DECisão (CONDE) para automatizar as tomadas de decisões em um ambiente usando uma RSASF como infraestrutura. O CONDE é desenvolvido para coletar e manipular os dados sensoreados, processando-os dentro da própria infraestrutura, e por isso, é considerado um sistema descentralizado. Para realizar as ações referentes às aplicações (nesse caso específico foram iluminação e AVAC - Aquecimento, Ventilação e Ar Condicionado), os autores utilizaram o processo de

¹ Jena é um framework de código aberto Java para a construção de web semântica, ou seja, para criar e ler Framework de Descrição de Recursos (FDR). Para obter mais informações, consulte jena.sourceforge.net

inferência como método para a tomada de decisão. Nesse caso, modelou-se um conjunto de parâmetros e regras para as decisões serem tomadas em cada aplicação ativa na RSASF. Dessa forma, o CONDE explora a capacidade de processamento da RSASF, promovendo uma integração das aplicações para alcançar a eficiência energética no ambiente a ser gerenciado. Entretanto, a solução poderia explorar os recursos energéticos dos nós de maneira homogênea para prolongar o tempo de vida útil RSASF e, consequentemente, evitar o problema, por exemplo, de *energy hole* (LI; MOHAPATRA, 2007).

Outra linha de pesquisa utiliza um modelo multidimensional para a tomada de decisão. Ming *et al.* (2016) propõem um modelo multidimensional para o controle de serviços em um ambiente inteligente, com ênfase na eficiência energética. No modelo multidimensional, cada parâmetro físico é abstraído em uma dimensão. Com isso, os serviços são formulados como um espaço de serviço multidimensional. Com base no modelo multidimensional, é proposto um algoritmo de ajuste de potência mínima para o agendamento da eficiência energética em um ambiente inteligente. Entretanto, o modelo não descreve um gerenciamento de serviços sem conflitos. Ainda, o modelo proposto não considera a informação de uma aplicação (comunicação aplicação-aplicação) para melhorar a eficiência energética do ambiente, apenas os parâmetros físicos.

Outros grupos de pesquisa utilizam técnicas de aprendizado de máquina como solução para o processo de aprendizagem na tomada de decisão (ROCHA FILHO *et al.*, 2015a; IRVAN; TERANO, 2017; KAZARIAN *et al.*, 2017). Em Irvan e Terano (2017), é proposto um método de aprendizado de máquina distribuído para automatizar o processo de aprendizagem nos dispositivos inteligentes. Cada dispositivo pode auto-aprender a identificar as configurações favoritas dos usuários durante um certo período de tempo. Em seguida, compartilhar as informações entre outros dispositivos para encontrar padrões. Padrões estes que possam identificar as melhores configurações ao estilo de vida de cada morador da casa. Para isso, foi implementado um sistema de classificador distribuído por meio da combinação de um método de classificação de aprendizado com uma abordagem multi-agente. Tal implementação é leve o suficiente para ser implantada em um dispositivo com recurso computacional escasso.

Ainda voltado para as soluções que utilizam aprendizado de máquina, Kazarian *et al.* (2017) desenvolveram um sistema automatizado para o controle dos dispositivos domésticos por meio de um algoritmo de aprendizado de máquina. O algoritmo utilizado para a tomada de decisão foi uma rede neural artificial. Para isso, o sistema foi desenvolvido em módulos, sendo o módulo de decisão responsável por identificar a ação a ser realizada. Destaca-se que há um módulo de armazenamento que é responsável por armazenar os dados dos sensores e os resultados do módulo de decisão. Neste caso, o módulo de decisão utiliza os dados do módulo de armazenamento para realizar o treinamento da rede neural. Entretanto, o sistema proposto além de não apresentar o tipo de infraestrutura adotada, não descreve os tipos de dispositivos que a solução pode ser implantada.

3.4 Desafios e questões de pesquisa

Esta seção apresenta os desafios e as questões de pesquisa que foram identificadas nos trabalhos analisados. Para tanto, foram definidas as seguintes características qualitativas:

- *Eficiência Energética*. Esta característica indica quais são os trabalhos que se preocupam em poupar

energia residual dos nós em sua formulação.

- *Tomada de Decisão*. Esta característica indica quais são os trabalhos que utilizam técnicas inteligentes para atuar no processo de decisão de maneira distribuída.
- *Processo de Atuação*. Esta característica refere-se à capacidade dos trabalhos em incorporar o processo de tomada de decisão dentro do próprio nó.
- *Overhead*. Esta característica refere-se à capacidade dos trabalhos em prevenir a sobrecarga na infraestrutura, como processamento e armazenamento em excesso.
- *Estrutura Heterogênea*. Esta característica retrata quais são os trabalhos que determinam as funções, também conhecidas como papéis, que cada nó em especial deve cumprir. Nesse tipo de estrutura, diferentes nós podem apresentar requisitos de *hardware* específicos conforme a sua necessidade.
- *Reutilização de Grandeza Física*. Esta característica indica se as aplicações reutilizam da mesma grandeza física para atuar no ambiente, independente do tipo de função da aplicação.

A extração dessas características além de fornecer uma análise entre os trabalhos, permite identificar lacunas que fazem frente ao estado da arte para pesquisas futuras. Em razão disso, convém salientar que essa extração de características contribuiu, ainda mais, para prover uma visão geral do estado da arte nos sistemas residenciais inteligentes.

A Tabela 2 apresenta as lacunas identificadas com base nos trabalhos analisados anteriormente. Através das informações obtidas da Tabela 2, observa-se que apenas um trabalho (FARIAS *et al.*, 2014) preocupa-se com a eficiência energética da rede, distribuindo o processo de tomada de decisão entre os nós. Ainda, evidencia-se que não há trabalhos com a capacidade de evitar o *overhead* no sistema, e nenhum deles determinam estratégias de estruturas heterogêneas com funções específicas para cada nó. Além disso, alguns trabalhos são voltados apenas para o sistema de automação residencial, podendo não funcionar para outros sistemas de automação (por exemplo, predial e detecção de incêndios) que têm os mesmos problemas citados anteriormente. Outro fator importante está relacionado com a validação das propostas, as quais, em sua maioria, não são validadas com outros trabalhos da literatura, limitando o entendimento/viabilidade das soluções propostas nos cenários avaliados. Além disso, as soluções analisadas são dotadas de problemas locais, específicos e com investigações fragmentadas, indicando um campo de pesquisa promissor e sem consolidação, particularmente quando aliado com a inteligência computacional.

Convém salientar, no entanto, que nos trabalhos analisados, utilizar tecnologias semânticas como solução para a tomada de decisão no contexto dos SARs possuem limitações por: (i) serem projetadas para domínios específicos, não representando na prática o comportamento do morador que pode alterar o seu comportamento, por exemplo, no final de semana; (ii) dependerem de *feedbacks* dos moradores quando envolvidos no processo de tomada de decisão, violando um dos princípios da computação ubíqua; (iii) necessitarem de profissionais especializados para a base de conhecimento; e (iv) tornarem inviáveis o seu uso nas RSASFs devido a limitação de recurso, como memória, para armazenar a base de conhecimento no próprio nó, haja vista a necessidade de criar novas regras de inferência e integração para cada aplicação adicionada no sistema.

Tabela 2 – Resumo das lacunas identificadas nos trabalhos analisados.

Trabalhos	Características					
	Eficiência energética	Tomada de decisão	Processo de atuação	Overhead	Estrutura heterogênea	Reutilização de grandeza física
(LIN <i>et al.</i> , 2002)	—	Não	Não	—	Não	Não
(MINENO <i>et al.</i> , 2010)	Não	Não	Não	Não	Não ¹	Não
(TOMIC; FENSEL; PELLEGRINI, 2010)	Não	Não	Não	Não	Não	Sim
(MANTORO; AYU; ELNOUR, 2011)	Não	Não	Não	Não	Não	Não
(TANG; CIUCIU, 2012)	Não	Não	Não	Não	Não	Sim
(BARAKA <i>et al.</i> , 2013)	Não	Não	Não	Não	Não	Não
(FENSEL <i>et al.</i> , 2013)	Não	Não	Não	Não	Não	Sim
(DITTAWIT; AAGESEN, 2013)	Não	Não	Não	Não	Não	—
(RAMLEE <i>et al.</i> , 2013)	—	Não	Não	Não	Não	—
(FARIAS <i>et al.</i> , 2014)	Sim	Sim	Sim	Não ²	Não ³	Sim
(LEE <i>et al.</i> , 2014)	—	Não	Não	Não	Não	Sim
(ROCHA FILHO <i>et al.</i> , 2014)	—	Não	—	Não	Não	Sim
(SENDRA <i>et al.</i> , 2014)	—	Não ⁴	Não	Não	Não	Não
(MAHMOOD <i>et al.</i> , 2014)	—	Não	—	Não	Não ¹	Não
(MING <i>et al.</i> , 2016)	Não	Não	Sim	—	Não	Sim
(KHAN; SILVA; HAN, 2016)	Não	Não	—	Não	—	Sim
(WU <i>et al.</i> , 2017)	Não	Não ⁵	Sim	Não	—	Sim
(IRVAN; TERANO, 2017)	Não	Sim	Sim	Não	Não	Sim
(KAZARIAN <i>et al.</i> , 2017)	Não	Não ⁵	Sim	Não	—	Sim

¹ Apenas para a interface de comunicação; ² Dispositivos com armazenamento escasso pode ser sobrecarregado a medida que aumenta a complexidade de novas regras de inferência; ³ Apesar de preocuparem com a distribuição de papéis, utilizam nós com *hardware* homogêneos da plataforma MicaZ; ⁴ Apenas a comunicação entre os nós é distribuída; ⁵ O processo de decisão é realizado em um dispositivo.

É fundamental destacar que tecnologia de rede sem fio como infraestrutura no SAR vem ganhando destaque por apresentar: (i) flexibilidade em agregar novos dispositivos, ao contrário da infraestrutura cabeada que normalmente é rígida; (ii) interoperabilidade com outras redes; e (iii) disponibilidade a baixo custo. Contudo, deve-se ressaltar que os trabalhos analisados apresentaram uma infraestrutura fortemente centralizada, e devido a essa natureza, o sistema pode ser vulnerável a sobrecarga de dados, além de apresentar atrasos nas tomadas de decisões. Ainda, os estudos apontam indicativos que o equipamento centralizador é sempre mais robusto do que os nós convencionais. Em razão disso, as propostas podem se tornar, muitas vezes, inviáveis de serem implantadas na prática em uma RSASF devido a sua limitação em recursos computacionais, tais como memória, bateria e processamento. Além disso, vale ressaltar que tais soluções não exploram os recursos energéticos da RSASF como infraestrutura para prolongar o tempo de vida útil da rede. Por fim, outra limitação que deve ser salientada, é o consumo desigual dos recursos energéticos e computacionais (isto é, processamento, transmissão e memória) entre os nós da infraestrutura, surgindo mais rapidamente o problema de *energy hole*.

Como observação final, notou-se que os grupos de pesquisas têm buscado diferentes soluções para os mais diversos problemas na área de sistemas de automação residencial. É fundamental destacar que mesmo com o crescimento quantitativo nessa área, ponto considerado fator positivo, destaca-se que há vários desafios e problemas em aberto que esta pesquisa identificou, a saber: (i) a proposta de um sistema de tomada de decisão em uma infraestrutura residencial distribuída com baixo *overhead* e ciente do consumo de energia dos nós da rede; (ii) a proposta de soluções inteligentes para atuar no processo de decisão de maneira distribuída e autônoma dentro do próprio nó da rede; e (iii) a proposta de métodos para manter um *trade-off* entre a precisão das tomadas de decisão e o consumo de energia dos nós, sem

que haja perdas de confiabilidade na infraestrutura distribuída.

3.5 Considerações finais

Este capítulo apresentou uma revisão sistemática que além de investigar a evolução da literatura na área de sistema de automação residencial, teve como objetivo identificar lacunas para esta pesquisa. Para alcançar esse objetivo, elaborou-se um protocolo (revisite o Apêndice A) para conduzir a revisão sistemática. Através do protocolo, foram selecionados os principais trabalhos que fazem frente a esta pesquisa, analisando-os de acordo com o planejamento proposto. Assim, identificou-se as vantagens e limitações de cada trabalho, ressaltando os principais desafios. Ainda, foi realizada uma proposição de características qualitativas extraídas dos trabalhos selecionados, as quais permitiram uma análise entre eles para delinear novas propostas, bem como esta pesquisa.

Por meio de uma visão holística na área, notou-se que vários trabalhos dependem de uma ampla gama de abordagens para superar os desafios no domínio dos sistemas residenciais inteligentes. Tais trabalhos além de apresentarem contribuições reais para a sociedade, empresa e o meio acadêmico, possuem importantes desafios e propostas que vão desde a concepção até a implantação. Além disso, observou-se que a maior parte dos trabalhos não abordam a questão da eficiência energética da infraestrutura de comunicação de maneira satisfatória e, portanto, é necessário embarcar mais inteligência na arquitetura para preencher essa lacuna. Diante disso, esta tese propõe soluções para a infraestrutura de controle da residência com inteligência computacional, embarcando a inteligência em dispositivos com recursos computacionais escassos. Destaca-se que esta questão (isto é, embarcar inteligência computacional em dispositivos com recursos computacionais escassos) é um grande desafio de pesquisa que este grupo de pesquisa vem investigando em seus projetos (ROCHA FILHO *et al.*, 2014; ROCHA FILHO *et al.*, 2015a; FAIÇAL *et al.*, 2016; FURQUIM *et al.*, 2016; MENEGUETTE *et al.*, 2016; GIUNTINI; BEDER; UHEYAMA, 2017; FAIÇAL *et al.*, 2017; UHEYAMA *et al.*, 2017) que também é pesquisado nesta tese, como apresentado nos capítulos 4 e 5.

UM SISTEMA DE DECISÃO INTELIGENTE PARA INFRAESTRUTURAS RESIDENCIAIS VIA SENSORES E ATUADORES SEM FIO

Neste capítulo, é apresentado o ResiDI (*Residential Distributed Infrastructure*). Inicialmente, as perguntas para nortear o desenvolvimento do ResiDI são formuladas. Em seguida, é descrita a estratégia utilizada para o desenvolvimento do ResiDI, bem como sua validação por meio de uma avaliação de desempenho. Finalmente, as considerações finais deste capítulo são apresentadas.

4.1 Instaurando o ResiDI

Para nortear o desenvolvimento do ResiDI, foram formuladas duas perguntas com base nas lacunas deixadas por outros trabalhos da literatura, sendo elas:

- Pergunta 1: Como utilizar os recursos da infraestrutura para reduzir a energia residual dos nós de maneira homogênea?
- Pergunta 2: Como não afetar a energia residual dos nós, mantendo uma alta precisão na tomada de decisão?

Convém salientar que ao responder tais perguntas, as lacunas apresentadas na Tabela 2 do Capítulo 3 são preenchidas. Por esta razão, a seguir é apresentada a estratégia utilizada para o desenvolvimento do ResiDI e o seu funcionamento.

4.2 ResiDI - Sistema de decisão inteligente para infraestruturas residenciais

Esta seção apresenta a proposta de um sistema de decisão inteligente para uma infraestrutura de automação residencial distribuída baseado em sensores e atuadores sem fio: ResiDI. Para tanto, uma

solução baseada em rede neural para atuar no processo de tomada de decisão dentro da rede, bem como um mecanismo de correlação temporal para maximizar a eficiência energética da infraestrutura foi desenvolvida. A inteligência chave do ResiDI foi distribuída nos nós, que são capazes de tomar decisões localmente e com baixo *overhead* na sua infraestrutura de comunicação. Com isso em mente, o principal objetivo do ResiDI é garantir uma precisão na tomada de decisão, ao mesmo tempo em que provê uma redução no consumo de energia de maneira homogênea nos nós da rede. Além disso, mediante as informações distribuídas e reutilizações dos dados sensoreados, o sistema permite associar diversas aplicações (ar condicionado e/ou iluminação, por exemplo) no processo de decisão, maximizando a eficiência energética da casa do morador. A Figura 13a sumariza o funcionamento do ResiDI que, para alcançar tais objetivos considera os seguintes papéis:

- *Nó Sensor* (Rótulo 1, Figura 13a). Coleta dados de diferentes grandezas físicas do ambiente (por exemplo, temperatura, presença e luminosidade), transmitindo-os para o nó decisor (linha tracejada, Figura 13a). Além disso, é executado um mecanismo de correlação temporal ponderada.
- *Nó Decisor* (Rótulo 2, Figura 13a). Recebe os dados coletados dos nós sensores, processa tais dados para a tomada de decisão, e encaminha a decisão para o nó atuador (linha contínua, Figura 13a).
- *Nó Atuador* (Rótulo 3, Figura 13a). Recebe a ação a ser realizada do nó decisor e atua na aplicação desejada. Para tanto, o componente de atuação pode conter mais de um atuador, tais como chaves elétricas, relés, transistores e LEDs. Consequentemente, um nó atuador atua em diferentes aplicações (por exemplo, iluminação, ar-condicionado e aparelhos eletrônicos), as quais estão em seu alcance.
- *Nó Sink* (Rótulo 4, Figura 13a). Responsável por realizar a comunicação externa e possíveis atualizações vindas de fora da rede, além de treinar a topologia da rede neural para a tomada de decisão. Além disso, é possível capturar estados comportamentais dos moradores mediante, por exemplo, um *smartphone*. Nesse cenário, o nó *sink* pode permanecer ativo por mais tempo, e por essa conveniência a sua implantação pode ser próxima de um roteador ou uma tomada, tendo como fonte alternativa de energia o *Power over Ethernet* ou um carregador, respectivamente.

A Figura 13b ilustra a arquitetura de componentes do ResiDI, na qual realiza a instância e a conexão dos componentes para cada nó com seus respectivos papéis por meio de um *microkernel* (UEYAMA *et al.*, 2009). Isso significa que é possível lidar em tempo de execução com os papéis de cada nó, uma característica presente em dispositivos com recursos computacionais escassos. Como já é constatado que acumular mais de um papel em um nó é energeticamente ineficiente (BHARDWAJ; CHANDRAKASAN, 2002; FARIAS *et al.*, 2014), as funcionalidades do ResiDI foram distribuídas em papéis. Para o desenvolvimento do ResiDI, algumas etapas são necessárias, sendo as principais: (i) a infraestrutura, Subseção 4.2.1; e (ii) a tomada de decisão, Subseção 4.2.2. Tais etapas são apresentadas a seguir para um melhor entendimento do seu funcionamento.

Figura 13 – Exemplo de funcionamento do sistema de decisão inteligente para infraestruturas residenciais

Fonte: Elaborada pelo autor.

4.2.1 Infraestrutura da Proposta

Esta seção apresenta como foi definida a infraestrutura da proposta, haja vista que a sua infraestrutura é distribuída com diferentes papéis. Para tanto, dividiu-se a solução desta etapa em três fases. Na primeira, os nós cooperam entre si para a construção da tabela de roteamento. Na segunda, os dados são sensorados e a correlação temporal é aplicada. Finalmente, na terceira, a tomada de decisão é transmitida para o nó atuador.

4.2.1.1 Construção da Tabela de Roteamento

A tabela de roteamento construída, contém a distância dos nós vizinhos e foi gerada com base nos papéis de cada nó. Para isso, o roteamento foi modelado em uma hierarquia de 3 níveis, como ilustrado na Figura 14a. Na visão *bottom-up* tem-se: (i) os nós sensores e atuadores que são os dispositivos finais que podem ser especializados; (ii) os nós decisores que são responsáveis por uma determinada região de detecção e atuação, sendo associado com um certo número de nós sensores e atuadores; e (iii) o nó *sink* que é único na rede, comunicando-se exclusivamente com todos os nós decisores. Há várias técnicas para estimar a distância de um nó, como *angle of arrival* e *time difference of arrival*, por exemplo, apresentadas em (KUPPER, 2005). Contudo, a obtenção da distância como métrica para encaminhar as mensagens no nosso modelo foi realizada mediante a intensidade do sinal recebido (RSSI). A utilização do RSSI é preferível em RSASF por ser uma técnica simples, eficaz e uma das mais utilizadas na literatura por não necessitar de *hardware* extra, aproveitando as mensagens dos próprios nós para aferir a distância entre eles.

Para facilitar o entendimento da técnica, a Figura 14b ilustra como é estimada a distância entre os nós e suas associações. Durante a fase de configuração de cada um dos nós sensores/atuadores, é necessário criar uma entrada de roteamento para associar ao nó decisor. O processo de associação é iniciado pelos nós sensores/atuadores, os quais escutam os *beacons* enviados dos nós decisores, escolhendo aquele com maior valor de RSSI. Em outras palavras, quando um nó recebe uma mensagem, a força do sinal captada

Figura 14 – Funcionamento da hierarquia do ResiDI e obtenção da distância como métrica para disseminar as mensagens no nosso modelo.

Fonte: Elaborada pelo autor.

por ele é utilizada para estimar a distância do nó que transmitiu a mensagem. Assim, quanto mais próximo o nó sensor/atuator está do nó decisor, maior é a potência do sinal e consequentemente menor é a sua distância. Destaca-se que esse processo é realizado mediante um *handshake* de três vias, no qual os nós sensores/atuadores solicitam associação ao nó decisor que aceita as requisições. Além disso, cada nó decisor precisa ter uma entrada de roteamento para o nó *sink*. Para isso, o nó *sink* transmite *beacons* para os nós decisores a fim dos nós decisores se associarem ao nó *sink*. Dessa forma, os nós comunicam-se em um único salto, e quando não é possível utilizam a rota mais adequada.

4.2.1.2 Comunicação do nó Sensor com o nó Decisor

Para sensorar os dados do ambiente e transmiti-los para o nó decisor com maior eficiência energética, foi necessário propor um mecanismo de correlação temporal ponderada, apresentado no Algoritmo 1. Por correlação temporal, entende-se que os dados coletados são correlacionados ao tempo, comparando o padrão de leitura atual com as leituras anteriores para transmitir, ou não, o dado coletado. Desta forma, é possível reduzir o consumo de energia da rede, eliminando transmissões desnecessárias, além de prover uma entrega dos dados em tempo hábil na área monitorada. Para tanto, esse processo ocorre depois dos nós sensores descobrirem os nós decisores mediante o RSSI (Linhas 2 a 5, Algoritmo 1). Após a descoberta, cada nó n mantém um conjunto S das leituras reportadas R_{old} , $\{R_{old}, old \in S\}$, em seu *buffer* (Linha 6, Algoritmo 1). Com o intuito de oferecer prioridade aos dados de leitura mais novos, atribui-se um conjunto de pesos $P(w) = \{1, 2, 3, \dots, w\}$ aos índices mais recentes de acordo com o tamanho do conjunto S (Linha 7, Algoritmo 1). Com isto, foi possível formular um *threshold*: $\frac{\sum_{w=1}^S R_{oldw} * P_w}{\sum P_w}$ (Linha 8, Algoritmo 1). Assim, a cada leitura realizada R_{new} , o nó verifica se a R_{new} é maior que o *threshold* (Linha 9,

Algoritmo 1). Caso a condição seja satisfeita, o valor sensorado (R_{new}) é transmitido para o nó decisor, utilizando a tabela de roteamento (Linha 10, Algoritmo 1). Por fim, a R_{new} é adicionada no conjunto S com maior prioridade, enquanto que o valor (R_{old}) de menor prioridade é suprimido (Linha 12, Algoritmo 1).

Algoritmo 1: Mecanismo de correlação temporal e transmissão dos dados monitorados

```

Entrada:  $R_{new}$  // Leitura atual
Dados:  $S$  // Conjunto das leituras reportadas,  $R_{old}$  // Última leitura,  $P_w$  // Conjuntos de pesos de acordo com o tamanho do  $S$ 
1 para cada  $n_i$  faça
    // Associação entre os nós
2   se  $Flag$  então
3     Informações  $\leftarrow$  handshake();
4     TabelaRoteamento  $\leftarrow$  UpdateRoteamento(Informações);
5   fim
6    $S_n \leftarrow GetR_{old}()$ ; // Leituras reportadas no buffer
7    $P_w \leftarrow SetIndex(S)$ ; // Atribui pesos aos dados reportados
8   Threshold  $\leftarrow \frac{\sum_{w=1}^S R_{old_{dw}} * P_w}{\sum P_w}$ ; // Calcula a correlação temporal ponderada mediante um  $S_n$  das  $R_{old}$ 
    // verifica se o  $R_{new}$  passa o Threshold
9   se  $R_{new} > Threshold$  então
10    | ToSend( $R_{new}$ , TabelaRoteamento); // Envia dados para o nó decisor
11  fim
12   $S_n \leftarrow UpdateS(S_n, R_{new})$ ; // Atualiza o Threshold adicionando o  $R_{new}$  e suprimindo o  $R_{old}$ 
13 fim para

```

4.2.1.3 Comunicação do nó Decisor com o nó Atuador

Os nós decisores decidem e coordenam as ações na residência. Ainda, é nessa etapa que os dados coletados são associados às aplicações (por exemplo, iluminação e equipamentos eletrônicos, para maximizar a eficiência energética da casa do morador). Para tanto, modelou-se uma rede neural (descrita com mais detalhes na Seção 4.2.2), a qual é capaz de dar sentido mais amplo para os dados sensorados.

No Algoritmo 2, é descrito o funcionamento do nó decisor. Antes de inicializar tal fase, cada nó decisor descobre os nós atuadores mediante o RSSI. Ainda nessa fase, são obtidas as informações dos *Mac Address* dos atuadores, bem como suas respectivas aplicações que eles podem atender. A próxima fase do Algoritmo 2 está relacionada com o processo de tomada de decisão dentro do próprio nó decisor. Esse processo só é iniciado quando o nó decisor recebe um conjunto de dados dos nós sensores mediante uma correlação temporal. O nó decisor ao receber esses dados toma a decisão com base na proposta de uma rede neural já treinada, como descrita na próxima seção. Desta forma, a informação da aplicação e sua respectiva decisão são obtidas (Linha 3, Algoritmo 2). Com tais informações, encaminha-se a decisão para o nó atuador. Deve-se ressaltar, portanto, que a decisão é transmitida para o nó atuador mais próximo (Linhas 4 a 6, Algoritmo 2), com o intuito de encaminhar a mensagem mais rápida, bem como poupar energia residual do nó decisor, uma vez que uma comunicação mais longa possui um gasto maior no consumo de energia do nó. Em outras palavras, constatou-se, durante os testes empíricos, que o consumo de energia ao longo de um *link*, $Consumo_{total} = (d_1 + \dots + d_n)^{Channel}$, é muito maior que o consumo total de energia ao longo de vários *links* curtos, $Consumo_{total} = d_1^{Channel} + \dots + d_n^{Channel}$.

Algoritmo 2: Coordena as tomadas de decisões e transmite para o nó atuador

```

1  $R_n \leftarrow \text{ReadSet}()$ ; // Conjunto de dados dos nós sensores
2 para cada  $d \in R_n$  faça
3    $\text{DecisionMaking} \leftarrow \text{RNA}(R_n)$ ; // toma a decisão
   // verifica tomada de decisão
4   se  $\text{DecisionMaking.Act} = \text{True}$  então
5      $\text{ToSend}(\text{DecisionMaking}, \text{TabelaRoteamento})$ ; // Envia a decisão para o nó atuador
6   fim
7 fim para

```

4.2.2 Mecanismo para a Tomada de Decisão com Fusão de Dados

Para realizar o processo de tomada de decisão de maneira inteligente, é necessário identificar, detectar e classificar a preferência do morador. Vale frisar, entretanto, que o processo para a escolha da melhor ação para a tomada de decisão não é trivial, haja vista a necessidade de tratar e correlacionar informações qualitativas (estado comportamental do morador) e quantitativas (quantidade de moradores em um ambiente). Além disso, cada aplicação possui um padrão comportamental diferente, o qual pode ser alterado dependendo da sua interação com o morador ou do período do ano em que é utilizada.

O modelo para a tomada de decisão tem como objetivo o aprendizado das aplicações mediante uma rede neural do tipo *Multi-Layer Perceptron*. A escolha da rede neural utilizada no nosso modelo é justificada por alguns motivos, sendo os principais: (i) capacidade de generalização na tomada de decisão; (ii) auto-aprendizado baseado apenas nos exemplos históricos; (iii) imunidade a ruídos para dados reais; e (iv) adaptabilidade por não necessitar, a cada atualização, alterar a topologia da rede (MITCHELL, 1997). Além disso, durante os experimentos empíricos, notou-se que a rede pode ser executada de maneira eficiente mesmo em nós convencionais.

Para facilitar o entendimento da rede neural em nosso modelo, a Figura 15a ilustra a topologia da rede neural e como os dados de entrada (isto é, dados provenientes dos nós sensores) são utilizados para a tomada de decisão. Para tanto, a topologia da rede foi modelada com as seguintes configurações: (i) camada de entrada com sete neurônios, os quais correspondem aos dados transmitidos pelos nós sensores; (ii) camada escondida com quinze neurônios, os quais representam a capacidade de aprendizagem para a tomada de decisão; e (iii) camada de saída com três neurônios, representando a tomada de decisão a ser enviada para o nó atuador e sua aplicação, sendo esta composta por uma combinação de neurônios, uma vez que é possível ter mais de uma decisão para diferentes aplicações. A Figura 15b apresenta a convergência da topologia da rede neural com 10, 15 e 20 neurônios na camada escondida, tendo uma taxa de acerto de 95% para 20000 épocas de treinamento. Neste caso, a melhor configuração foi para a topologia com 15 neurônios na camada escondida que estabilizou nas primeiras 10000 épocas.

Deve-se ressaltar, portanto, que com a rede treinada e transmitida para os nós decisores, é possível realizar o processo de tomada de decisão por meio das grandezas físicas compartilhadas. Para melhorar o processo de tomada de decisão, a rede treinada correlaciona os dados obtidos dos sensores para gerar uma informação de atuação. Isso auxilia a dar um sentido mais amplo para a tomada de decisão. Isto é, um único sensor de presença pode ser utilizado para o sistema de ar condicionado e iluminação. Desta forma, os dados coletados não são associados apenas a uma aplicação. Por exemplo, quando o sensor de presença detecta ausência de moradores, o sistema de ar condicionado pode desligar ou aumentar a temperatura, enquanto, paralelamente, o sistema de iluminação pode ser desligado.

Figura 15 – Topologia da RNA modelada para a tomada de decisão e sua execução com diferentes configurações de neurônios na camada escondida para saber a melhor topologia.

Fonte: Elaborada pelo autor.

É fundamental destacar que para treinar a rede, optou-se por realizar o treinamento no nó *sink*. Para tanto, utilizou-se o Raspberry Pi por ser uma plataforma de prototipagem aberta, portátil, flexível e de baixo consumo de energia. No nó *sink*, encontra-se a base de dados que foi utilizada para treinar a nossa rede. Após o treinamento, deve-se ressaltar que o nó *sink* transmite o modelo da rede treinada para os nós decisores. Assim, há um baixo *overhead* (isto é, processamento e/ou armazenamento em excesso) na nossa solução. Com isto, é possível re-treinar a rede, caso necessário, mediante o comportamento do(s) morador(es), sem prejuízos na eficiência energética do sistema.

4.2.3 Protótipo desenvolvido para o ResiDI

Com o intuito de demonstrar a viabilidade e a eficácia da solução proposta, construímos um protótipo para o ResiDI que foi testado e validado (Subseção 4.3.5) em um ambiente real. Como a primeira etapa desta pesquisa é coletar as grandezas físicas da casa do morador, desenvolveu-se o protótipo do nó sensor, ilustrado na Figura 16a, com poder de comunicação sem fio, considerando as funcionalidades das RSASFs. Para tanto, integrou-se como módulo de comunicação o padrão 802.11, podendo ser extensível para o padrão 802.15.4. Além do módulo de comunicação, integrou-se os sensores de temperatura, umidade, presença e luminosidade. Para coletar o consumo de energia dos equipamentos eletrônicos, há a necessidade do nó sensor está conectado na tomada. Para este caso específico, adaptou-se o wattímetro Kill-a-Watt da empresa P3 com o módulo XBee (802.15.4) para coletar o consumo de energia dos equipamentos eletrônicos.

Para enviar os dados disseminados do nó sensor e transmiti-los para o nó atuador, foi desenvolvido o protótipo do nó decisor a partir da montagem de um Raspberry Pi, ilustrado na Figura 16b. Com o intuito de realizar a orquestração da disseminação das informações presentes na rede, foi necessário expandir o uso do Raspberry Pi através dos padrões 802.11 e 802.15.4.. Dessa forma, o Raspberry Pi recebe os dados sensoreados, processa tais dados para a tomada de decisão e transmite para o nó atuador realizar a ação. Para prover a atuação, construímos o protótipo do nó atuador, apresentado na Figura 16c. Tal protótipo possui a capacidade de receber ações para ligar ou desligar uma aplicação. Para isso, integrou-se o XBee

Figura 16 – Protótipo do nó sensor (a), decisor (b) e atuador (c) desenvolvido para o ResiDI que permite a criação de uma RSASF que coleta, dissemina, processa e atua na aplicação desejada.

Fonte: Elaborada pelo autor.

e o TRIAC para atuar como chave eletrônica nos equipamentos. Além disso, foi adicionado um LED para informar, independente do tipo de atuação, que a ação foi realizada com êxito.

4.3 Avaliação de desempenho

Esta seção apresenta a metodologia utilizada nos experimentos com o intuito de validar o método proposto. Desta forma, é possível comprovar o objetivo desta tese. Para isso, a validação foi dividida em quatro etapas. Inicialmente, na Subseção 4.3.2, é avaliada a viabilidade de implantar o ResiDI em nós sensores reais. Em seguida, na Subseção 4.3.3, é avaliada a inteligência do ResiDI em atuar no processo de tomada de decisão. Subsequentemente, na Subseção 4.3.4, é avaliada a infraestrutura do ResiDI em obter soluções energeticamente eficientes. Por fim, na Subseção 4.3.5, é avaliado o desempenho do ResiDI no protótipo desenvolvido.

4.3.1 Metodologia

De acordo com Jain (1991), cada sistema computacional possui a sua particularidade. Dessa forma, a avaliação de desempenho torna-se algo peculiar para cada sistema avaliado. Nesse sentido, não é comum usar a mesma metodologia de avaliação para sistemas computacionais diferentes. A finalidade é manipular de maneira planejada certas variáveis independentes (fatores), definindo os valores mais prováveis que essas variáveis podem assumir (níveis), e, portanto, analisar a influência que tal manipulação provoca na variável de resposta (métricas). Para esta solução três etapas compõem a metodologia da avaliação realizada, sendo elas: (i) a escolha do *baseline*; (ii) a modelagem da base de dados; e (iii) os métodos estatísticos para a avaliação dos resultados. A seguir, cada uma dessas etapas é descrita.

4.3.1.1 A escolha do *baseline* para o ResiDI

O desempenho do ResiDI é avaliado comparando-o com o CONDE (FARIAS *et al.*, 2014). O CONDE (CONtroll and DECision) é um sistema de controle e decisão para automatizar as tomadas

de decisões em um ambiente usando uma RSASF como infraestrutura. Por isso, é possível coletar e manipular os dados sensoreados, processando-os dentro da própria infraestrutura. Para realizar as ações, o CONDE utiliza tecnologias semânticas (neste caso, inferência) como método para a tomada de decisão nas aplicações. Convém salientar, portanto, que a escolha do CONDE é justificada por três motivos: (i) pode ser utilizado em qualquer aplicação independente da base de dados; (ii) obteve melhor desempenho quando comparado com outra solução da literatura (FENG *et al.*, 2008; FORTINO *et al.*, 2012); e (iii) é um dos trabalhos que mais se assemelha com a proposta desta pesquisa. Outro fator importante que deve ser frisado está relacionado com a validação dos trabalhos apresentados no Capítulo 3, os quais, em sua maioria, não validam com outros trabalhos da literatura, limitando o entendimento/viabilidade das soluções propostas nos cenários avaliados. Com tais motivos, portanto, será possível avaliar e validar o desempenho do ResiDI frente a um dos trabalhos da literatura, entendendo o seu funcionamento em diversos cenários.

4.3.1.2 Modelando a base de dados para a tomada de decisão

Com o intuito de obter dados mais confiáveis para os experimentos, utilizou-se dados de um ambiente real para gerar os resultados, adquiridos em Bache e Lichman (2013) e ROCHA FILHO *et al.* (2014). A coleta de dados foi realizada durante 3 meses em ROCHA FILHO *et al.* (2014) e 40 dias em Bache e Lichman (2013), ambos em um ambiente residencial. Com isto, foi modelada uma base de dados com os seguintes atributos: (i) temperatura do ambiente em graus Celsius; (ii) presença de pessoas no ambiente; (iii) data e horário de utilização da aplicação; (iv) potência da aplicação em Watt; (v) estado da aplicação; (vi) tipo de aplicação; e (vii) tomada de decisão. As aplicações utilizadas na base de dados são iluminação e equipamentos eletrodomésticos (televisão, computador e geladeira). Deve-se ressaltar que as atividades de atuação estão relacionadas em ligar/*standby*/desligar as aplicações, bem como controlar a intensidade da iluminação para reduzir o gasto energético da residência.

Após a formação da base de dados, oito partições das amostras do conjunto de dados foram feitas, as quais contêm informações sobre a interação do morador com as aplicações. Cada partição contém um conjunto de dados de 1 e 2 semanas, objetivando contemplar os diferentes comportamentos que o morador possui. Isto foi feito pois, conforme observado na Figura 17, notou-se que o morador possui comportamentos diferentes no final de semana em relação aos demais dias. Para treinar a rede, foi utilizado o algoritmo *back-propagation* (RUMELHART; MCCLELLAND; GROUP, 1986). Além disso, para evitar o problema de mínimo local, bem como predizer/estimar o quão correto o ResiDI será executado na prática, a técnica *k-fold cross-validation* com $k=4$ foi utilizada para separar o conjunto de treino e teste em cada partição de maneira disjunta. Desta forma, foram utilizados $k-1$ subconjunto para treino, enquanto o restante do subconjunto foi usado para teste. Convém salientar, por fim, que algumas particularidades de cada experimento, tais como as métricas selecionadas, os cenários usados, os parâmetros escolhidos, os sensores utilizados juntamente com os resultados gerados são apresentados e justificados nas próximas subseções.

Figura 17 – Analisando a base de dados para observar o comportamento do usuário no final de semana em relação aos demais dias, bem como o consumo de energia gasto pelo morador em um período de 24 horas, identificando equipamentos ociosos, os quais gastam uma parte considerável do tempo em modo *standby* (ROCHA FILHO *et al.*, 2014).

Fonte: Adaptada de ROCHA FILHO *et al.* (2014).

4.3.1.3 Métodos estatísticos utilizados para a avaliação

Com o intuito de comprovar o objetivo desta solução, uma série de análises estatísticas foram realizadas para validar os resultados mediante os p-valores. Neste caso, os p-valores são medidas utilizadas para: (i) verificar a distribuição das amostras de dados; ou (ii) certificar se os resultados são ou não estatisticamente diferentes entre si. Para isso, inicialmente, foi utilizado o *Shapiro-Wilk normality test* sobre as amostras de dados para analisar a normalidade das suas distribuições. Em seguida, pode-se utilizar métodos paramétricos (*t-student*) ou não-paramétricos (*Wilcoxon rank sum test*) para a comparação entre as amostras de dados de acordo com os p-valores obtidos do *Shapiro-Wilk normality test*. Em outras palavras, caso as amostras de dados tenham a hipótese de adequação à normalidade rejeitada, utiliza-se métodos não-paramétricos e, em caso contrário, métodos paramétricos. A seguir são apresentados os resultados da avaliação de desempenho.

4.3.2 Avaliação de Desempenho do Impacto da Gerência de Recursos

Esta seção avalia a viabilidade de implantar o ResiDI em uma RSASF real, considerando os recursos limitados dos nós: (i) memória; e (ii) processamento. Dessa forma, é possível avaliar o *overhead* de recursos relativo ao ResiDI. Para isso, a plataforma MicaZ composta de um microcontrolador ATmega128L, com 4KB de memória ROM e 128KB de memória *flash* para programa foi utilizada para todos os nós, com exceção do nó *sink* que utilizou o Raspberry Pi (conforme visto na Seção 4.2.2). O ambiente de desenvolvimento utilizado para o MicaZ foi o sistema operacional TinyOS. Além disso, o componente *Integrated Concurrency and Energy Management* (KLUES *et al.*, 2007) foi utilizado para sincronizar a transmissão dos nós, semelhante ao CONDE. A sincronização é realizada quando um nó é

iniciado na rede. Por esta razão, a CPU irá passar o menor tempo possível em modo ativo.

Figura 18 – Gerenciamento de recursos da memória ROM, memória *flash* para programa e processador em modo ativo.

Fonte: Elaborada pelo autor.

A Figura 18 apresenta o gerenciamento de recursos da memória ROM, memória *flash* de programa e processador em modo ativo, realizando uma análise comparativa entre o ResiDI e o CONDE. Como pode ser deduzido a partir da Figura 18a, observa-se que ambas as propostas não ultrapassam os 60% de memória ROM. Especificamente para o nó decisor, o ResiDI usou 78.47% (Figura 18a) e 45.86% (Figura 18b) menos memória quando comparado com o CONDE. Essa redução pode ser atribuída devido ao fato de que o ResiDI armazena apenas o aprendizado gerado da topologia da rede neural, diferente do CONDE que armazena a base de dados e os parâmetros de inferências no nó decisor, sobrecarregando-o. Em outras palavras, o uso de inferência apresenta indicativo de aumento de memória a medida que novas aplicações são inseridas na rede, haja vista a necessidade de criar novas regras de inferência e integração. Contudo, o ResiDI tem um aumento na utilização do processador (Figura 18c) quando comparado com o CONDE, independentemente dos nós. Convém salientar, entretanto, que essa diferença é pequena, tendo como maior valor 13% (Figura 18c), encontrado no nó *sink*. Tal fato não afetou o desempenho do consumo de energia do ResiDI (como avaliado nas seções 4.3.4 e 4.3.5), uma vez que o componente que mais dissipa energia residual do nó é a comunicação de dados, e não o processamento. Portanto, conclui-se a viabilidade de implantar o ResiDI em nós sensores reais.

4.3.3 Avaliação de Desempenho na Tomada de Decisão

Esta subseção avalia o desempenho do ResiDI em determinar a sua capacidade na tomada de decisão. Para isso, considerou-se as seguintes medidas de desempenho: (i) sensibilidade; (ii) precisão; e (iii) especificidade. Tais medidas são obtidas mediante uma matriz de confusão que avalia os resultados com base nas perdas causadas, ilustrada na Figura 19.

Os conjuntos de parâmetros estabelecidos para realizar a avaliação de desempenho são sumarizados na Tabela 3. Para possibilitar que todas as combinações dos conjuntos de parâmetros fossem realizadas, utilizou-se o planejamento fatorial completo. Nesse sentido, o sistema é avaliado com o uso dos métodos (ResiDI e CONDE), com a mudança do *dataset* (1 semana e 2 semanas), e, com a troca das aplicações (controle de iluminação e equipamentos). Ressalta-se que tais métodos utilizam o *dataset* que contém informações reais da interação do usuário com a sua residência. Cada conjunto de parâmetros foi

Figura 19 – Medidas de desempenho calculadas a partir da matriz de confusão.

		Classe Predita	
		Positivo	Negativo
Classe Verdadeira	Positivo	Verdadeiro Positivo (VP)	Falso Negativo (FN)
	Negativo	Falso Positivo (FP)	Verdadeiro Negativo (VN)

• Sensibilidade: $VP/(VP+FN)$
 • Precisão: $VP/(VP+FP)$
 • Especificidade: $VN/(VN+FP)$

Fonte: Elaborada pelo autor.

executado 12 vezes. Com o intuito de verificar a adequação a normalidade dos resultados apresentados na Figura 20, utilizou-se o *Shapiro-Wilk normality test*, o qual obteve os p-valores apresentados na Tabela 4. Com isso, notou-se que os p-valores E3 e E6 para precisão e E6 para especificidade, possui a hipótese de adequação à normalidade rejeitada considerando 95% de confiança. Isso implica no uso de métodos não-paramétricos de comparação entre os conjuntos, sendo indicado para este caso o *Wilcoxon rank sum test*. Os resultados são apresentados na Figura 20, com 95% de confiança.

Tabela 3 – Conjunto de parâmetros escolhidos para serem avaliados.

Experimento	Método	Dataset	Aplicação
E1	ResiDI	1 Semana	Controle de Iluminação
E2	ResiDI	1 Semana	Controle de Equipamento
E3	ResiDI	2 Semanas	Controle de Iluminação
E4	ResiDI	2 Semanas	Controle de Equipamento
E5	CONDE	1 Semana	Controle de Iluminação
E6	CONDE	1 Semana	Controle de Equipamento
E7	CONDE	2 Semanas	Controle de Iluminação
E8	CONDE	2 Semanas	Controle de Equipamento

Tabela 4 – P-valores resultados do *Shapiro-Wilk normality test*.

Experimentos	Shapiro-Wilk normality test		
	Sensibilidade	Precisão	Especificidade
E1	0,472	0,8927	0,5031
E2	0,162	0,8285	0,4266
E3	0,4322	0,2301	0,7154
E4	0,2766	0,2049	0,5609
E5	0,3433	0,01977	0,1622
E6	0,8734	0,04726	0,04116
E7	0,5224	0,754	0,5234
E8	0,4436	0,2305	0,08525

O Gráfico da Figura 20 apresenta a porcentagem dos resultados obtidos dos experimentos de E1 até E8 (Tabela 3) em função das medidas de desempenho para o *dataset* de 1 e 2 semanas. Os resultados obtidos mostram que houve diferença estatística significativa entre o ResiDI e o CONDE, independente do período monitorado e da aplicação utilizada (experimentos {(E1, E5), (E2, E6), (E3, E7), (E4, E8)} da Figura 20). Por meio desses resultados, notou-se que, independente da aplicação utilizada, o ResiDI possui um desempenho superior em relação ao CONDE (aproximadamente 22.4% de aumento, experimentos (E1, E5) e (E2, E6)) quando considerado o *dataset* de 1 semana. Além disso, quando considerado o *dataset* de 2 semanas, tal aumento é mais acentuado (aproximadamente 23.5%, experimentos (E3, E7) e (E4, E8) da Figura 20). Esta situação é derivada do treinamento da rede, a qual possui mais exemplos

para a sua auto-aprendizagem. Isto é, o ResiDI aprende a tomar decisões pela sua própria experiência, a qual pode ser obtida mediante os históricos comportamentais dos moradores (revisite a Seção 4.2.2). Desta forma, o ResiDI não necessita de um especialista na área para gerar bons resultados nas tomadas de decisões, diferentemente do CONDE.

Figura 20 – Análise de desempenho do ResiDI de acordo com a Tabela 3.

Fonte: Elaborada pelo autor.

Outro aspecto importante, notado no resultado, está relacionado com a estabilidade do ResiDI quando comparado com o CONDE. Isto é identificado pela amplitude interquartil (diferença entre o terceiro e primeiro quartil do *boxplot* da Figura 20), a qual indica o grau de dispersão dos dados gerados. Isso é coerente, posto que o ResiDI generaliza as suas decisões com base em exemplos históricos, separando as tomadas de decisões em hiperplanos. Desta forma, é possível tomar decisões corretamente para instâncias nunca vistas na base de dados. Já o CONDE realiza a sua tomada de decisão mediante um espaço fixo para cada aplicação. Por isso, há um alto grau de dispersão nos resultados obtidos. Assim, para instâncias nunca vistas, o CONDE gera resultados incoerentes e muitas vezes toma a mesma decisão para conjuntos de dados distintos, diferentemente do ResiDI.

4.3.3.1 Análise das influências dos parâmetros

Nesta subseção, são apresentadas as análises das influências do conjunto de parâmetro de acordo com a Tabela 3 em função das medidas de desempenho. As análises foram feitas utilizando um modelo de regressão multivariado (JAIN, 1991), no qual inclui uma relação causal com mais de duas variáveis independentes, definindo os valores mais prováveis que essas variáveis podem assumir, e, dessa forma, analisar o efeito que tal manipulação provoca na medida de desempenho. Neste caso, o comportamento de uma medida de desempenho é explicado por mais de um parâmetro. Portanto, é possível analisar quais parâmetros e suas combinações que mais influenciaram nos resultados.

Na Tabela 5, são apresentados os parâmetros métodos, *dataset* e aplicação com as respectivas letras *qA*, *qB* e *qC*. As combinações de duas ou mais letras são os percentuais das interações entre os

conjuntos de parâmetros. Destaca-se que o conjunto de parâmetros com mais influência para todas as medidas de desempenho é justamente o método (qA). Salienta-se, também, que tal informação pode ser constatada nos resultados do conjunto de comparação dos parâmetros $\{(E1,E5), (E2,E6), (E3,E7), (E4, E8)\}$ da Figura 20. Já o segundo parâmetro com mais influência é o *dataset* (qB), como pode ser confirmado entre os conjuntos de comparação dos parâmetros $\{(E1,E5)$ e $(E3,E7)\}$ da Figura 20. Isso é coerente, posto que o *dataset* auxilia a obter melhores resultados no processo de tomada de decisão. Outro ponto a ser observado está relacionado com a aplicação (qC), a qual é o parâmetro com menos influência nos resultados ($\{(E1,E2), (E3,E4), (E5,E6), (E7,E8)\}$, Figura 20). Consequentemente, o ResiDI obtém resultados satisfatórios e estáveis no que diz respeito ao processo de tomada de decisão. Com tais afirmações estatísticas, é possível confirmar a viabilidade e eficácia do ResiDI para a tomada de decisão em um ambiente residencial.

Tabela 5 – Influência dos parâmetros em função das medidas de desempenho. A, método; B, dataset; C, aplicação.

Performance Measurements	A (%)	B (%)	C (%)	AB (%)	BC (%)	AC (%)	ABC (%)
Sensitivity	89.87	9.92	≈ 0.00	0.14	0.04	0.02	≈ 0.00
Precision	87.82	12.13	≈ 0.00	≈ 0.00	0.01	≈ 0.00	0.03
Specificity	87.68	12.26	≈ 0.00	0.02	0.02	≈ 0.00	≈ 0.00

4.3.4 Avaliação de desempenho da infraestrutura

Esta subseção avalia o desempenho da infraestrutura do ResiDI em um ambiente simulado, considerando cenários de testes distintos. O *Network Simulator 3* (NS-3) foi usado para simular o ambiente. A versão utilizada foi a NS-3.21 que fornece suporte para o protocolo IEEE 802.15.4. Para obter um cenário mais próximo de um ambiente real, utilizou-se como entrada para a simulação os conjuntos de dados reais de 2 semanas descritos na Seção 4.3.1.2. Em relação à topologia da rede, adotou-se uma topologia plana com um erro aleatório Gaussiano de média zero para depositar os nós. Com o intuito de evitar buracos na topologia, a densidade dos nós decisores e atuadores são de 0.007 nós/m². Já a densidade dos nós sensores é de 0.015 nós/m², uma vez que é realístico admitir que há mais nós sensoreando um ambiente. O raio de comunicação dos nós é de 15 m, e o seu consumo de energia para transmitir e receber um pacote são de $0.2088 \mu\text{J/bit}$ e $0.2256 \mu\text{J/bit}$, respectivamente, de acordo com a plataforma MicaZ. Além disso, adicionou-se 5% de imprecisão no RSSI. O tempo de simulação foi de uma hora, sendo o primeiro minuto para o *startup* da rede.

Os conjuntos de parâmetros estabelecidos para realizar a avaliação de desempenho são apresentados na Tabela 6. Os experimentos foram avaliados com a alteração da área monitorada (10x10 m, 15x15 m, 20x20 m e 25x25 m), e com a troca dos métodos (ResiDI e CONDE). Como o objetivo da avaliação é determinar a capacidade do ResiDI em obter soluções energeticamente eficientes, utilizou-se como variável de resposta as métricas:

- **Consumo de energia** dos nós, o qual indica a quantidade de energia consumida pela infraestrutura no processo de tomada de decisão;

- **Atraso** no processo de tomada de decisão, o qual representa o tempo gasto desde o sensoriamento até a atuação para que uma decisão seja executada;
- **Mensagem disseminada**, a qual refere-se ao total de mensagens transmitidas durante o processo de tomada de decisão; e
- **Taxa de entrega**, a qual retrata a relação entre as mensagens disseminadas do nó sensor e as mensagens recebidas do nó atuador.

As configurações de cada conjunto de parâmetros foram executadas 33 vezes com 95% de confiança de acordo com o *Wilcoxon rank sum test*, pois ao utilizar o *Shapiro-Wilk normality test* os p-valores obtidos foram inferiores a 0.05.

Tabela 6 – Conjunto de parâmetros escolhidos para serem avaliados.

Experimento	Método	Área monitorada
E1	ResiDI	10x10 m
E2	ResiDI	15x15 m
E3	ResiDI	20x20 m
E4	ResiDI	25x25 m
E5	CONDE	10x10 m
E6	CONDE	15x15 m
E7	CONDE	20x20 m
E8	CONDE	25x25 m

4.3.4.1 Impacto da energia residual dos nós da rede de maneira homogênea

Com base no conjunto de parâmetros propostos, o gráfico da Figura 21 apresenta os resultados relativos à métrica consumo de energia para cenários com diferentes áreas monitoradas. Como os resultados dos p-valores do *Wilcoxon rank sum test* foram inferiores a 0.05, todos os resultados das comparações apresentados na Figura 21 são estatisticamente diferentes. Para o cenário com uma área de 10x10 m e 15x15 m, observa-se que há uma redução de aproximadamente 14,11% e 13,79% do consumo de energia (experimentos {(E1, E5); (E2, E6)} da Figura 21) quando as soluções propostas pelo ResiDI são utilizadas e, conseqüentemente, um aumento no tempo de vida útil da infraestrutura. Isso ocorre devido aos dados transmitidos serem correlacionados ao tempo. Em outras palavras, somente quando há uma diferença da leitura atual com as leituras reportadas, o dado sensorado é encaminhado para o nó desejado (revisite a Subseção 4.2.1.2). Desta forma, uma maior eficiência energética na infraestrutura foi obtida.

Outro ponto importante está relacionado com o aumento da área monitorada que não afeta o desempenho do ResiDI, uma vez que o consumo de energia foi reduzido de forma significativa para 22,24% e 33,31% considerando as áreas de 20x20 m e 25x25 m, respectivamente (experimentos {(E3, E7), (E4, E8)} da Figura 21). Esta diferença significativa em relação ao consumo de energia faz sentido, posto que o trabalho da literatura (isto é, o CONDE) penaliza o nó decisor por consumir mais energia, o qual é considerado um ponto de falha do sistema. Em outras palavras, o consumo de energia do CONDE não é homogêneo entre os nós (Figura 22b), e, dessa forma alguns nós ficam sem energia mais rápido do que outros. Portanto, o ResiDI além de resolver o problema do ponto de falha, ainda uniformiza a sua infraestrutura, deixando-a mais homogênea, como ilustrada na Figura 22a. Este resultado pode ser explicado não apenas pela correlação temporal, mas também pelo uso do RSSI como métrica de distância, e pela distribuição de papéis para cada nó, o qual evita penalizá-los sem gerar sobrecargas.

Figura 21 – Análise de desempenho da métrica consumo de energia de acordo com a Tabela 6.

Fonte: Elaborada pelo autor.

Figura 22 – Mapa de energia residual dos nós na coleta de dados para uma área monitorada de 15x15 m. O eixo Z representa a energia consumida pelos nós.

(a) ResiDI

(b) CONDE

Fonte: Elaborada pelo autor.

4.3.4.2 Impacto do tempo de resposta na tomada de decisão

No gráfico da Figura 23a, são apresentados os resultados referentes ao atraso no processo de tomada de decisão em função da área, ilustrando uma análise comparativa entre o ResiDI e o CONDE. As análises estatísticas demonstram que o ResiDI realiza a tomada de decisão em um tempo menor quando comparado com o CONDE, em todos os experimentos. Nos experimentos E1 e E5 da Figura 23a particularmente, o processamento do ResiDI foi no mínimo 11,8% mais rápido que CONDE. Isso ocorre em virtude da formulação do hiperplano separador gerado pela RNA, a qual não necessita consultar uma base de dados para chegar a um consenso no processo de tomada de decisão, ao contrário do CONDE. Assim, é possível obter respostas mais rápidas, o que influencia diretamente na redução do consumo de energia da rede. Além disso, quando há uma ampliação na área de interesse, notou-se que houve diferenças significativas de 35,04% e 44,35% para os experimentos (E3, E7) e (E4, E8) entre o ResiDI e CONDE. Em outras palavras, no ResiDI, houve uma redução mais acentuada no tempo de entrega das mensagens para a tomada de decisão. Esta situação, além de ocorrer pelo motivo explicado anteriormente, é derivada do uso do RSSI como métrica de distância, a qual auxilia a escolher o nó vizinho mais adequado para

realizar a tomada de decisão (revisite a Seção 4.2.1.1).

A Figura 23b apresenta o atraso no processo de tomada de decisão variando a quantidade de nós (15, 18, 21 e 24) e fixando a área monitorada em 25x25 m, cenário que constatou maior atraso na tomada de decisão. A medida que a quantidade de nós aumenta, observa-se que o atraso no processo de tomada de decisão mantém-se, estatisticamente, constante para ambas as propostas. Isso é coerente, posto que a quantidade de nós vizinhos aumenta e consequentemente a potência dos nós permanece mais previsível, não gerando assim, atrasos para repassar as mensagens. Desta forma, em relação a métrica atraso, o ResiDI possui um desempenho superior em relação ao CONDE independente da área e da sua densidade, apresentando melhor escalabilidade e robustez que a solução da literatura.

Figura 23 – Análise de desempenho da métrica atraso de acordo com a Tabela 6.

Fonte: Elaborada pelo autor.

4.3.4.3 Impacto das mensagens transmitidas na infraestrutura

A métrica mensagem transmitida tem como objetivo avaliar a eficiência do ResiDI no que diz respeito ao tráfego de dados durante a disseminação das informações. A Figura 24a apresenta os resultados referente à quantidade de mensagens transmitidas em função da área monitorada. Ao utilizar o *Wilcoxon rank sum test* como teste de comparação entre os conjuntos $\{(E1, E5), (E2, E6), (E3, E7) \text{ e } (E4, E8)\}$, notou-se que os p-valores foram inferiores a 0.05, com 95% de confiança. Isso indica que houve diferenças estatísticas em todos os resultados. Com base nos resultados, constatou-se que o ResiDI transmite uma menor quantidade de mensagem quando comparado ao CONDE, mantendo-se constante do parâmetro E1 até o E4 da Figura 24a. Isto está relacionado com o mecanismo de correlação temporal que processa os dados localmente antes de transmiti-los, eliminando assim as notificações redundantes e reduzindo a quantidade de comunicação entre os nós. Entretanto, deve-se frisar que o ResiDI possui maior variação na transmissão (notado pela amplitude interquartil do *boxplot*), uma vez que a correlação temporal pode variar a sua transmissão dependendo do tipo de evento monitorado. Convém salientar, contudo, que isso não afetou a acurácia da tomada de decisão do ResiDI, bem como a sua eficiência energética, como pode ser revisto nas Figuras 20 e 22, respectivamente.

Na Figura 24b, é apresentada a quantidade de mensagens transmitidas quando os nós são variados (15, 18, 21, 24), fixando a área monitorada em 25x25 m. Nessa análise em particular, observou-se que apesar do crescimento mais acentuado do ResiDI (em média 18%) a medida que a quantidade de nós aumenta, o mesmo consegue garantir uma menor quantidade de mensagem transmitida que o CONDE. O crescimento inesperado do ResiDI, pode ser explicado pela quantidade de nós sensores em uma área. Isto é, quando a densidade da área aumenta, o número de nós sensores que detectam o mesmo evento aumenta. Apesar disso, é possível constatar que o uso da correlação temporal garante um bom desempenho em termos de transmissão no ResiDI quando comparado com a solução da literatura, como pode ser visto na Figura 24.

Figura 24 – Análise de desempenho da métrica mensagem transmitida de acordo com a Tabela 6.

Fonte: Elaborada pelo autor.

4.3.4.4 Impacto da taxa de entrega das mensagens na infraestrutura

A Figura 25a apresenta a porcentagem da métrica taxa de entrega em função da área. Como esperado, nota-se que ao aplicar o *Wilcoxon rank sum test* com 95% de confiança entre os conjuntos {(E1, E5), (E2, E6), (E3, E7) e (E4, E8)} da Figura 25a, observou-se que não houve diferença estatística entre o ResiDI e o CONDE ao aumentar a área de monitoramento, uma vez que os p-valores foram superiores a 0.05. Já a Figura 25b apresenta a taxa de entrega das mensagens variando a quantidade de nós e fixando a área em 25x25 m (cenário que constatou pior resultado em ambas as soluções). A medida que a quantidade de nós aumenta (isto é, sua densidade), observa-se, estatisticamente, que o ResiDI obteve taxas de entregas mais elevadas quando considerado o cenário com 21 e 24 nós, como apresentado na Figura 25b, não afetando assim no processo de tomada de decisão. Outro importante aspecto observado na Figura 25b, está relacionado com um decréscimo mais lento da taxa de entrega do ResiDI quando comparado com o CONDE. Essas afirmações são derivadas da quantidade de mensagens transmitidas (revisite a Figura 24). Em outras palavras, o *buffer* do ResiDI não fica cheio mais rapidamente e, dessa forma, não ocorre grandes perdas de mensagens. Portanto, pode-se afirmar que em termos de taxa de entrega, o ResiDI apresentou maior eficiência e escalabilidade que o CONDE.

Figura 25 – Análise de desempenho da métrica taxa de entrega de acordo com a Tabela 6.

(a) Taxa de entrega em função da área monitorada (b) Taxa de entrega em função da quantidade de nós

Fonte: Elaborada pelo autor.

4.3.5 Avaliação de Desempenho da Eficácia do ResiDI no Protótipo Desenvolvido

Nesta subseção, é avaliado o desempenho do ResiDI em um ambiente real mediante o protótipo desenvolvido (revisite a Subseção 4.2.3). Para isso, os resultados obtidos da Subseção 4.3.3 foram utilizados como *baseline*. Dessa forma, além de comprovar a eficácia do ResiDI em uma plataforma com recursos escassos, tem-se como objetivo secundário, validar que os resultados obtidos na simulação refletem os mesmos resultados se fossem realizados em um ambiente real.

Os experimentos foram realizados considerando três cenários, sendo eles: (i) cenário 1, o qual representa o ambiente simulado, especificamente experimento E2 da Tabela 6; (ii) cenário 2, o qual representa um ambiente residencial real com baixa interferência; e (iii) cenário 3, o qual representa um ambiente residencial real com alta interferência e, por isso, foram adicionadas outras redes no mesmo canal de comunicação para promover uma maior interferência na rede. Destaca-se que as redes que foram adicionadas, disseminam dados aleatoriamente entre 0 a 5s durante 1h.

Para analisar a eficácia do ResiDI, bem como validar os resultados da simulação, utilizou-se as seguintes medidas de desempenho: (i) consumo de energia; (ii) atraso no processo de tomada de decisão; (iii) total de mensagem disseminada; e (iv) taxa de entrega. Tais medidas são as mesmas utilizadas na Subseção 4.3.3. As configurações de cada conjunto de parâmetros foram executadas 33 vezes com 95% de confiança. Em seguida, o *Shapiro-Wilk normality test* foi utilizado para verificar a adequação a normalidade dos dados. Como mais da metade dos p-valores foram inferiores a 0.05 (Tabela 7), notou-se que os conjuntos de dados possuem a hipótese de adequação à normalidade rejeitada. Por isso, o *Wilcoxon rank sum test* foi utilizado para a comparação entre os conjuntos de dados, como ilustrado na Tabela 8. Os resultados de tais comparações são apresentados na Figura 26 com 95% de confiança.

A Figura 26a apresenta os resultados pertencentes à variável consumo de energia para os cenários 1, 2 e 3. Destaca-se que tais cenários são estatisticamente equivalentes no que diz respeito ao

Tabela 7 – P-valores resultantes do *Shapiro-Wilk normality test*.

Medidas	<i>Shapiro-Wilk normality test</i>		
	Cenário 1	Cenário 2	Cenário 3
Energia	0.012	0.367	0.419
Atraso	0.005	$\approx$ 0.000	0.065
Overhead	0.858	0.018	0.105
Entrega	0.002	0.006	$\approx$ 0.000

Tabela 8 – P-valores resultantes do *Wilcoxon rank sum test*.

Medidas	Conjunto de comparação do <i>Wilcoxon rank sum test</i>		
	Cenário 1/Cenário 2	Cenário 1/Cenário 3	Cenário 2/Cenário 3
Energia	0.985	0.497	0.612
Atraso	0.559	0.001	0.424
Overhead	0.488	$\approx$ 0.000	0.001
Entrega	0.066	0.284	0.630

consumo de energia. Isto é, todos os cenários possuem desempenho similar, não havendo diferenças estatísticas significativas entre eles, revise a Tabela 8. Entretanto, os cenários 2 e 3 apresentam médias ligeiramente maiores em relação ao cenário 1. Isso ocorre devido ao processamento de outros recursos, como os componentes do circuito implantado no protótipo que não foram levados em consideração na simulação, causando assim uma pequena variação na dispersão dos dados gerados (amplitude interquartil do *boxplot* da Figura 26a) quando comparado com o cenário 1. Em relação à variável atraso (Figura 26b), observou-se que o cenário 1 e 2 não apresentam diferenças estatísticas significativas (Tabela 8). Porém, como era esperado, o cenário 3 apresenta um tempo de resposta ligeiramente maior quando comparado com o cenário 1, e, estatisticamente equivalente quando comparado com o cenário 2. Isso ocorre devido a adição de interferência na rede no mesmo canal de comunicação que o ResiDI, podendo gerar uma pequena perda de dados, como já observado nas figuras 24 e 25.

A Figura 26c apresenta os resultados referentes à quantidade de mensagens transmitidas, confrontando-as com os cenários 1, 2 e 3. Como evidenciado na simulação e validado na Tabela 8, constatou-se que os cenários 1 e 2 são estatisticamente equivalentes em relação a quantidade de mensagens transmitidas. Essa afirmação já era esperada, haja vista que o cenário com baixa interferência não influencia na disseminação dos eventos. Particularmente, a maior diferença na quantidade de mensagens transmitidas está relacionada com o cenário 3 quando comparado com o cenário 1. Salienta-se, entretanto, que tal diferença de desempenho é praticamente insignificante devido ao mecanismo de correlação temporal que reduz a quantidade de transmissão de dados (veja a Figura 24). É importante frisar, como apresentado na Figura 26d, que as taxas de entrega das mensagens são uniformes. Em outras palavras, os cenários (Figura 26d) possuem comportamentos similares, não havendo diferenças estatísticas entre eles, não afetando assim no processo de tomada de decisão para a eficiência energética dos moradores e da infraestrutura do ResiDI. Essas afirmações estatísticas, além de comprovar que os resultados simulados refletem a realidade se fossem realizados em um ambiente real, evidenciam a eficácia do ResiDI em uma plataforma com recursos escassos.

Figura 26 – Análise de desempenho do ResiDI em um ambiente real comparado com resultados simulados.

Fonte: Elaborada pelo autor.

4.4 Considerações finais

Este capítulo apresentou o ResiDI, um sistema de decisão inteligente para uma infraestrutura residencial distribuída baseado em sensores e atuadores sem fio. O ResiDI além de manter uma precisão no processo de tomada de decisão, tem como objetivo minimizar o consumo de energia da sua infraestrutura de comunicação. O núcleo da inteligência do ResiDI é baseado em uma rede neural que visa melhorar a precisão da tomada de decisão, juntamente com um mecanismo de correlação temporal que é projetado para reduzir o consumo de energia da infraestrutura. Com o propósito de validar a viabilidade do ResiDI em um ambiente real, foi desenvolvido um protótipo como prova de conceito.

Para avaliar o ResiDI, utilizou-se métodos estatísticos paramétricos e não-paramétricos sobre

os resultados obtidos. Os resultados obtidos permitiram validar a eficiência do ResiDI frente a um dos trabalhos da literatura. Por meio do planejamento de experimentos, tais resultados mostraram ser promissores, sendo três deles relevantes: (i) aumento nas tomadas de decisões; (ii) redução no consumo de energia dos nós de maneira homogênea; e (iii) eficiência na disseminação das informações. Ainda, os resultados apresentados mostraram um ganho no tempo de resposta da ação. Convém salientar que os resultados reais obtidos mediante o protótipo ratificam tais contribuições.

Por meio de uma visão holística na área conquistada durante o desenvolvimento do ResiDI, notou-se que é possível melhorar os resultados alcançados neste capítulo. Para isso, foi desenvolvida uma nova solução derivada do ResiDI. Tal solução, nomeada como ImPeRIum, propõe uma generalização das operações e abstração das informações por meio dos dispositivos inteligentes, provendo um mecanismo de decisão e atuação mais eficiente. Para alcançar esse objetivo, uma arquitetura baseada no paradigma de *fog computing* e *publish-subscribe* foi desenvolvida. Destaca-se que apesar do ResiDI aproveitar o processamento dos nós da rede, melhorando a precisão na tomada de decisão e reduzindo o gasto de energia dos nós, não é capaz de utilizar os dispositivos inteligentes da própria residência para gerenciar as aplicações, como é proposto no ImPeRIum. Com isso, é possível utilizar a intercomunicação de tais dispositivos para melhorar a qualidade da informação no processo de tomada de decisão. Vale frisar, ainda, que o ResiDI não possui interoperabilidade e integração com dispositivos inteligentes da própria casa. Por causa das limitações citadas, no próximo capítulo é apresentado o ImPeRIum.

UM SISTEMA DE CONTROLE NEURO-FOG PARA INFRAESTRUTURAS RESIDENCIAIS VIA OBJETOS INTELIGENTES

Este capítulo apresenta o ImPeRIum (*an Intelligent aPproach for decision-making in a ResIdential environment*) que é uma nova solução derivada do ResiDI. Inicialmente, é descrita uma visão geral do funcionamento do ImPeRIum e a estratégia utilizada para o seu desenvolvimento. Em seguida, são apresentados os resultados da avaliação de desempenho e a metodologia utilizada para realizar a validação do ImPeRIum. Por fim, as considerações finais deste capítulo são apresentadas.

5.1 ImPeRIum - Um sistema de controle neuro-fog para infraestruturas residenciais

Esta seção apresenta o ImPeRIum, um sistema de decisão inteligente com recursos computacionais distribuídos que forma um ambiente computacional de *fog* para gerenciar as aplicações da residência. O ImPeRIum foi desenvolvido com base em técnicas de inteligência computacional para realizar o processo de tomada de decisão, bem como com um conjunto de dispositivos inteligentes da residência (por exemplo, *set-top box*, tvs inteligentes, medidores e roteadores inteligentes) para formar um ambiente computacional de *fog* (Figura 27a). Para lidar com a heterogeneidade dos dados e eliminar o problema de interoperabilidade dos dispositivos que formam o *fog computing*, o ImPeRIum implementa um módulo de comunicação *Publish/Subscribe*¹ (Pub/Sub). O ImPeRIum tem como objetivos principais prover maior robustez no processamento e aumentar a precisão da tomada de decisão, tendo como objetivos específicos eficiência na entrega dos dados² e alta disponibilidade para o usuário.

¹ Com o *Publish/Subscribe* pode-se criar grupos de interesse e a entrega das mensagens é direcionada a tais grupos, o que faz com que somente os interessados sejam envolvidos no processo de transmissão e, portanto acarretando em menor consumo energético.

² O sistema deve ser capaz de disseminar os dados com baixo atraso e com um número menor de transmissões, maximizando a energia residual dos dispositivos.

Figura 27 – ImPeRIum - Funcionamento do sistema de decisão inteligente para infraestruturas residenciais.

Fonte: Elaborada pelo autor.

Na solução, assume-se que os nós são munidos com uma interface de comunicação sem fio, armazenamento, processamento e bateria como fonte de *backup*. A Figura 27b ilustra a arquitetura de componentes do ImPeRIum, no qual os nós publicam (*publish*) seus dados e, em seguida, os nós assinantes (*subscribe*) recebem os dados correspondentes para processar e retornar uma resposta. A arquitetura do sistema além de ser dividida em papéis³, também é distribuída em níveis: (i) Nível 0, sensores utilizados para coletar os dados do ambiente e disseminar tais dados para o Nível 1; (ii) Nível 1, dispositivos embarcados que além de processar os dados, também podem monitorar e controlar o ambiente; e (iii) Nível 2, servidor remoto com maior poder de processamento e armazenamento.

O ImPeRIum além de prover uma infraestrutura com alta disponibilidade caso um dispositivo falhe, ele aumenta a cobertura no gerenciamento do ambiente. Além disso, a arquitetura proposta maximiza a eficiência na entrega dos dados com uma baixa latência, uma vez que os dispositivos estão localizados mais próximos da região de interesse e o processo de tomada de decisão, bem como a sua atuação é realizada no próprio dispositivo (isto é, no ambiente de *fog computing*). De outro ponto de vista, uma abordagem tradicional que utiliza um *sink* para realizar o gerenciamento do ambiente, caso o *sink* falhe, toda a rede fica inoperante. Ainda nesse cenário, caso o *sink* fosse considerado como um atuador, haveria um consumo desigual dos recursos devido ao fluxo de dados próximos ao *sink* ser mais intenso. Destaca-se, também, que caso ocorra uma falha no componente de atuação do *sink* a tarefa não é finalizada com êxito, isto é, mesmo o *sink* funcionando, a rede ficaria inoperante para realizar as atuações no ambiente. Para um melhor entendimento da solução, o ImPeRIum é detalhado em três etapas, sendo elas: (i) divisão dos papéis com a descrição do seu funcionamento; (ii) comunicação do sistema; e (iii) inteligência computacional para o processo de tomada de decisão. Cada uma dessas etapas são descritas nas subseções seguintes.

³ Entende-se como papéis as funcionalidades específicas que são atribuídas para cada nó

5.1.1 Funcionamento dos papéis e níveis do ImPeRIum

Para monitorar e gerenciar o ambiente, os papéis são distribuídos entre os nós (revisite a Figura 27) da rede, sendo eles: (i) nó sensor; e (ii) nó *fog*. Os nós sensores (Nível 0) são distribuídos no ambiente para coletar e disseminar dados, transmitindo-os para o ambiente computacional de *fog* (Nível 1). O ambiente computacional de *fog* é composto por dispositivos que estão próximo da borda da rede com poder de processamento, armazenamento e de comunicação entre os usuários finais e os servidores de nuvem tradicionais (Nível 2) (MAHMUD; KOTAGIRI; BUYYA, 2017). No ImPeRIum, tais dispositivos são chamados de nós *fogs*, sendo responsáveis por receber os dados dos sensores e realizar o processamento para detectar a tomada de decisão e atuar no ambiente. Nesse caso, as informações para realizar a decisão são processadas no próprio nó *fog*. A implementação do modelo de tomada de decisão (descrita na Subseção 5.1.3) para o ambiente de *fog* foi realizada no Nível 2. O ambiente computacional de *fog* é responsável por toda região de detecção e atuação. Para isso, o ImPeRIum possui um Mapa Virtual dos *Fogs* (MVF). Com isso, cada nó *fog* possui seu conhecimento local e de todo o ambiente. Para adquirir o conhecimento de todo o ambiente, os nós *fogs* compartilham dados entre si por meio de um modelo *request-reply* via *Pub/Sub*. Em relação a atuação, o nó *fog* controla as aplicações (iluminação e equipamentos eletrodomésticos) do ambiente por meio de diferentes componentes de atuação, tais como chaves elétricas, relés, transistores e LEDs. Isso é uma realidade razoável de supor, uma vez que os dispositivos inteligentes podem possuir diferentes tipos de atuadores. O processo para realizar a comunicação do ImPeRIum é descrito na próxima Subseção.

5.1.2 Comunicação Publish/Subscribe do ImPeRIum

No ImPeRIum, o paradigma *Pub/Sub* (EUGSTER *et al.*, 2003) permite a disseminação confiável do conteúdo de maneira assíncrona entre os fornecedores (*Publish*) e os consumidores (*Subscribe*) de informações. Para a comunicação entre os nós, baseada no paradigma *Pub/Sub*, foi utilizado o protocolo de comunicação *Message Queue Telemetry Transport* (MQTT) (STANFORD-CLARK; NIPPER, 2014) (isto é, barramento *Publish/Subscribe* - MQTT, Figura 28a) que está implementado em todos os nós do ImPeRIum. O barramento gerencia os fornecedores de conteúdo e seus assinantes, de maneira que, tal barramento filtra os eventos recebidos e os repassa para os assinantes de acordo com o conteúdo da assinatura, como ilustrado na Figura 28a. Em outras palavras, um determinado nó publica seus dados e, em seguida, os nós assinantes recebem os dados correspondentes para processar e retornar uma resposta. Assim, é possível garantir a entrega confiável dos dados publicados pelos nós para os componentes do ambiente de execução do ImPeRIum.

O processo de publicação ocorre quando o nó sensor (S_n) gera um evento (Rótulo A, Figura 28b). Neste caso, o S_n cria uma mensagem de publicação contendo o seu ID e o conteúdo do evento. Antes de enviar a mensagem (Rótulo B, Figura 28b), o ImPeRIum utiliza o protocolo de correlação temporal (ROCHA FILHO *et al.*, 2015b). Tal protocolo correlaciona os eventos gerados ao tempo, comparando o conteúdo do evento atual com os conteúdos dos eventos anteriores para publicar, ou não, o evento gerado. Com isso, o ImPeRIum consegue eliminar as notificações redundantes, aumentando o tempo de vida da rede e reduzindo a quantidade de comunicação entre os nós. Após o S_n publicar o conteúdo, o nó *fog* (F_n) que está inscrito naquele conteúdo recebe o evento publicado (Rótulo C, Figura 28b). Para o F_n receber o

Figura 28 – ImPeRIum - Comunicação Pub/Sub por meio do MQTT.

(a) Barramento de eventos.

(b) Fluxograma de comunicação do ImPeRIum.

Fonte: Elaborada pelo autor.

conteúdo, é necessário inscrever-se no barramento de evento com uma mensagem contendo o seu ID, o conteúdo a ser recebido e os tipos de aplicações que irá gerenciar. Ainda, o F_n também se registra em outros nós *fogs* para receber dados de outros sensores, os quais não estão em seu alcance. Tais dados são armazenados no MVF e, dessa forma, o ImPeRIum adquire o conhecimento local e de todo ambiente para realizar o processo de tomada de decisão (Rótulo D, Figura 28b). Tal processo é iniciado quando o F_n recebe os dados dos sensores. Assim, por meio de uma rede neural, o F_n verifica se é necessário atuar no ambiente (Rótulo E, Figura 28b). Com isso, a informação da aplicação e sua respectiva atuação são adquiridas com o intuito de atuar no ambiente (Rótulo F, Figura 28b). Tal informação é armazenada no MVF para evitar conflitos de atuação ou interesse ou caso outro F_{n+1} deseje atuar no ambiente. O processo para a tomada de decisão é descrito a seguir.

5.1.3 Inteligência computacional para o processo de tomada de decisão

Para realizar o processo de tomada de decisão, foram explorados seis algoritmos de classificação clássicos da literatura, sendo eles: (i) Lógica *fuzzy*; (ii) Árvore de Decisão (iii) *K-Nearest Neighbors*, KNN; (iv) *Naive Bayes*; (v) Rede Neural Artificial do tipo *Multi-Layer Perceptron*, RNA; e (vi) Comitê de classificadores. Os algoritmos utilizam os dados que estão no MVF e, em seguida, detectam as características do ambiente de acordo com a preferência do morador para realizar o processo de tomada de decisão.

Para saber qual algoritmo utilizar na modelagem do ImPeRIum, realizou-se uma análise exploratória, como ilustrado na Figura 29. Para obter os modelos de classificação, utilizou-se os dados obtidos em (BACHE; LICHMAN, 2013; ROCHA FILHO *et al.*, 2014) que foram transformados em uma base de dados aplicados em (ROCHA FILHO *et al.*, 2015b). A base de dados é apresentada na Subseção 4.3.1.2 do Capítulo 4. Os experimentos foram executados 12 vezes com 95% de confiança. A Figura 29a apresenta a porcentagem dos resultados relativos à métrica precisão em função dos algoritmos de classificação. Já a Figura 29b fornece um *ranking* que permite determinar o desempenho geral de cada um dos algoritmos avaliados e suas diferenças estatísticas.

Figura 29 – Análise exploratória dos algoritmos de classificação.

Fonte: Elaborada pelo autor.

Com base nesses resultados, nota-se que o Comitê e a RNA obtiveram os melhores resultados. Apesar do Comitê possuir uma melhor colocação no *ranking*, o mesmo utiliza vários algoritmos que aumentam significativamente o seu custo computacional. Em razão disso, ao utilizar o Comitê, o processo de tomada de decisão fica mais lento no que diz respeito ao tempo de resposta e processamento. Por outro lado, a RNA possui um menor custo computacional, além de apresentar uma alta taxa de acertos com uma melhor estabilidade nos resultados (identificado pela amplitude interquartil do boxplot). Pelos motivos supracitados, a RNA foi utilizada para realizar o processo de tomada de decisão.

Deve-se destacar que a topologia da rede neural adotada na nossa proposta é composta por três camadas (Figura 30), sendo a camada de entrada com sete neurônios responsável por inserir os dados na rede, a camada escondida com quinze neurônios responsável por determinar padrões de regiões de aprendizado, e a camada de saída com três neurônios responsável por fornecer o resultado dos dados inseridos. A topologia da rede neural utilizada no ImPeRIum, é a mesma apresentada na Subseção 4.2.2 do Capítulo 4, haja vista que foi a topologia que apresentou os melhores resultados (reviste a Figura 15b). Vale salientar, ainda, que a função de ativação adotada na camada escondida foi a sigmóide logística, e o algoritmo utilizado para treinar a rede foi o *backpropagation*. A rede foi treinada no nível 2 do ImPeRIum e, em seguida disseminada para os nós *fogs*. Com isso, foi possível reduzir a sobrecarga de processamento no nosso sistema.

5.2 Avaliação de Desempenho e Metodologia

Nesta seção, são apresentados os resultados da avaliação de desempenho e a metodologia utilizada para gerar os resultados. Para isso, a validação do ImPeRIum foi dividida em dois estágios. No primeiro estágio foi realizada uma validação do ImPeRIum, comparando-o com duas abordagens da literatura, CONDE e ResiDI. Tais abordagens foram escolhidas por serem os trabalhos que mais se assemelham com o ImPeRIum. Já no estágio 2, foi avaliada a gerência de recurso do ImPeRIum em um ambiente de *fog*, comparando-o com uma abordagem tradicional que utiliza um ambiente de servidor em nuvem. Portanto, foi possível entender o funcionamento do ImPeRIum em diversos cenários. Os cenários modelados, as métricas utilizadas e os resultados alcançados são apresentados a seguir.

Figura 30 – Funcionamento da RNA modelada para o processo de tomada de decisão.

Fonte: Elaborada pelo autor.

5.2.1 Avaliação de desempenho do ImPeRIum com outras soluções da literatura

Esta subseção valida o desempenho do ImPeRIum por meio de simulações utilizando o *Network Simulator 3*⁴. Em relação a topologia da rede, adotou-se uma área monitorada de 40x40 m. Para cobrir toda área de coleta e disseminação de dados da topologia, a densidade dos sensores é de 0.015 nós/m². Já a densidade dos nós *fogs* é de 0.007 nós/m², uma vez que é realístico admitir que há menos nós processando dados que sensoreando o ambiente. O raio de comunicação dos nós é de 15 m, e o seu consumo de energia para transmitir e receber um pacote são de 0,2088 μ J/bit e 0,2256 μ J/bit, respectivamente, de acordo com a plataforma MicaZ. O tempo de simulação foi de uma hora, sendo o primeiro minuto para o *startup* da rede.

No ImPeRIum, foram implementadas duas aplicações residenciais: (i) controle do sistema de iluminação residencial; e (ii) controle energético dos eletrodomésticos, especificamente televisão, computador e geladeira. No caso do sistema de iluminação, três tipos de intensidade luminosa (baixa, média e alta) foram considerados para atuação. Já no sistema de eletrodoméstico, considerou-se o estado ligar/standby/desligar para atuação. Para obter um cenário mais próximo de um ambiente real, utilizou-se como entrada para a simulação os conjuntos de dados reais obtidos em (BACHE; LICHMAN, 2013; ROCHA FILHO *et al.*, 2014) com os seguintes atributos: (i) temperatura do ambiente em grau Celsius; (ii) presença de pessoas no ambiente; (iii) data e horário de utilização da aplicação; (iv) potência em Watt da aplicação; (v) estado da aplicação; (vi) tipo de aplicação; e (vii) tomada de decisão. Tais atributos foram transformados em blocos de dados (Figura 31) para simular a disseminação de vários eventos na residência. Destaca-se, também, que as aplicações implementadas possuem diferentes intensidades de uso durante o dia, como apresentada na Figura 32.

⁴ Network Simulator 3 - NS3, <http://www.nsnam.org/>

Figura 31 – Bloco de dados utilizados.

Fonte: Elaborada pelo autor.

Figura 32 – Intensidade de uso das aplicações.

Fonte: Elaborada pelo autor.

Para avaliar o ImPeRIum, utilizou-se as métricas: (i) **taxa de acerto**, que representa a porcentagem de acertos classificados corretamente no processo de tomada de decisão; (ii) **tempo de resposta**, que representa o tempo gasto desde o sensoriamento até a atuação para finalizar a execução de uma decisão; (iii) **transmissão de dados**, que representa o total de mensagens transmitidas na infraestrutura durante o processo de tomada de decisão; (iv) **taxa de entrega**, que representa a relação entre as mensagens disseminadas do nó sensor e as mensagens recebidas do nó *fog*; e (v) **consumo de energia**, que representa o total de energia consumida pela infraestrutura no processo de tomada de decisão. Os experimentos foram executados 33 vezes com um intervalo de confiança de 95% de acordo com a distribuição *t-student*. Os resultados são apresentados na próxima subseção.

5.2.1.1 Análise dos resultados obtidos

Na Figura 33a, é apresentada a taxa de acerto no processo de tomada de decisão variando a quantidade de blocos de dados (8, 16, 32, 64 e 128). O intuito é apresentar o comportamento do ImPeRIum em classificar corretamente as tomadas de decisões. Por meio dos resultados, notou-se que o ImPeRIum possui em média 1.17 vezes mais acertos que o CONDE. Isso ocorre pois o CONDE modelou a tomada de decisão por meio de tecnologias semânticas (isto é, parâmetros e regras), diferentemente do ImPeRIum que generaliza as tomadas de decisões baseado em exemplos históricos. Com isso, o ImPeRIum realiza o acerto das tomadas de decisões para exemplos nunca vistos. Quando comparado com o ResiDI, o ImPeRIum foi estatisticamente equivalente independente da quantidade de bloco de dados publicado na rede. Isso é coerente, posto que ambas soluções utilizam o mesmo conceito de aprendizagem para o processo de tomada de decisão. Além disso, a similaridade entre o ImPeRIum e o ResiDI ratifica a eficiência da inteligência computacional no processo de tomada de decisão.

Após validar a taxa de acertos, foi analisado o tempo gasto para que uma decisão seja executada, como apresentado na Figura 33b. Como pode ser observado, o ImPeRIum possui um tempo de resposta menor quando comparado com o ResiDI e o CONDE, em todos os cenários. Em média o ImPeRIum foi 13% e 60% mais rápido que o ResiDI e CONDE, respectivamente. No pior caso, 128 blocos de dados, o ImPeRIum foi 9% mais rápido que o ResiDI e 48% mais rápido que o CONDE. Isto está relacionado com o ambiente computacional de *fog* que não necessita transmitir a informação da atuação para um

Figura 33 – Impacto de desempenho do ImPeRIum quando comparado com outras abordagens da literatura.

Fonte: Elaborada pelo autor.

dispositivo específico, diferentemente das soluções comparadas.

Em relação à métrica total de mensagem disseminada, Figura 33c, tem-se o objetivo de avaliar a eficiência do ImPeRIum no que diz respeito ao tráfego da rede durante a disseminação dos dados. Independente da quantidade de bloco de dados utilizados, observou-se que o ImPeRIum dissemina em média 1.74 e 2.45 vezes menos dados quando comparado com o ResiDI e o CONDE, respectivamente. Isso

reduz o número de colisões na rede e preserva a energia residual do dispositivo. Isso ocorre pois, a atuação é realizada no próprio ambiente computacional de *fog*. Isto é, não é necessário repassar as informações da atuação para outro dispositivo na rede e, conseqüentemente, há menos mensagens disseminadas. Já na métrica taxa de entrega (Figura 33d), constatou-se que o ImPeRIum e o ResiDI são estatisticamente equivalentes, independente do cenário avaliado. Em outras palavras, em ambas soluções as taxas de entrega das mensagens possuem comportamentos semelhantes. Entretanto, o ImPeRIum e o CONDE não são estatisticamente equivalentes. Isto é, o ImPeRIum possui uma maior taxa de entrega. Além disso, outro ponto importante, está relacionado com a estabilidade na taxa de entrega que o ImPeRIum possui quando comparado com as outras soluções. Portanto, o ImPeRIum possui menos sobrecarga na disseminação de dados que as demais soluções.

Por fim, a Figura 33e apresenta a métrica consumo de energia dos dispositivos em função da quantidade de bloco de dados. Em todos os cenários avaliados, observa-se que o ImPeRIum consome menos energia residual dos dispositivos à medida que a quantidade de bloco de dados aumenta. Isso é uma consequência não apenas da redução da quantidade de mensagem transmitida, mas também é devido a robustez no processamento para a tomada de decisão por meio do ambiente computacional de *fog*, como pode ser revisto nas figuras 33c e 33b. O pior caso ocorre com 128 bloco de dados, sendo que o ImPeRIum possui uma redução de 9% no consumo de energia em relação ao ResiDI e 47% no consumo de energia em relação ao CONDE. Portanto, o ImPeRIum é capaz de preservar a energia residual dos dispositivos, mantendo uma precisão na tomada de decisão, além de garantir robustez no processamento (isto é, tempo de resposta menor) com uma redução na transmissão de dados e com uma taxa de entrega elevada.

5.2.2 Avaliação de desempenho do ImPeRIum no ambiente de fog

Nesta subseção, é avaliada a gerência de recurso do ImPeRIum, apresentado a sua eficiência em um ambiente computacional de *fog*, comparando-o com uma abordagem tradicional que utiliza um ambiente de servidor em nuvem. Os experimentos foram executados em diferentes ambientes reais, chamados de níveis: (i) nível 1, ambiente computacional de *fog*; e (ii) nível 2, servidor remoto. Para cada nível foram utilizados os blocos de dados e as aplicações apresentadas na Subseção 5.2.1. A descrição do conjunto de parâmetros estabelecidos para realizar a avaliação e os dispositivos físicos utilizados para os experimentos são apresentados na Tabela 9. Como o objetivo da avaliação é determinar a eficiência da gerência de recurso do ImPeRIum em um ambiente de *fog*, utilizou-se como variável de resposta as métricas consumo de memória, consumo de processador e tempo de processamento das aplicações. Destaca-se que o tempo de processamento das aplicações, considera o tempo gasto entre o envio dos dados e a resposta da ação. Os experimentos foram replicados 33 vezes com uma confiança de 95% de acordo com a distribuição *t-student*. Os resultados de tais experimentos são apresentados a seguir.

5.2.2.1 Análise dos resultados obtidos

Inicialmente, foi avaliada a gerência de recursos do ImPeRIuM por meio das métricas consumo de memória e processador em função da quantidade de dados no momento da tomada de decisão. Nota-se que há uma linearidade de ambas as métricas (Figuras 34a e 34b), independente dos níveis e dos blocos de dados de entrada. A estabilidade no consumo de memória (Figura 34a) e processador (Figura 34b) é

Tabela 9 – Conjunto de parâmetros para serem avaliados e os dispositivos físicos utilizados nos experimentos.

Descrição dos parâmetros						
Experimento usando o nó fog e servidor remoto	Nó fog ¹	Servidor remoto				
	E1 ¹	E2	E3	E4	E5	E6
Quantidade de blocos de dados	128 ¹	8	16	32	64	128
Descrição dos dispositivos físicos						
Nó fog - Raspberry Pi 2		ARMV7-A, BCM2836 @900 MHz, 1GB				
Servidor remoto - Computador		Intel Core I7-7700K, @4.2 GHz, 16GB				

¹ Representa o cenário que constatou ser o menos favorável para o ImPeRIum nos experimentos realizados da Subseção 5.2.1.

outro ponto que merece destaque. Isso pode ser observado pela uniformidade da amplitude interquartil do boxplot, a qual apresenta comportamentos semelhantes para as métricas utilizadas no momento da tomada de decisão. Outro aspecto importante, notado nas Figuras 34a e 34b, está relacionado com os níveis. Em particular, o nível 1 possui maior consumo de memória e processador quando comparado com as variações do nível 2. Entretanto, tal consumo não é grave, não ultrapassando 3% de memória e 45% de processador. Consequentemente, o nível 1 possui ciclos ociosos de processador e suporta a execução de aplicações sem sobrecarregar os dispositivos. Com isso em mente, é possível aproveitar os recursos computacionais dos dispositivos que estão na borda da rede para coletar e atuar no ambiente mediante o *fog computing*.

Figura 34 – Impacto de desempenho do consumo de memória, processador e tempo de processamento.

Fonte: Elaborada pelo autor.

Após notar os ciclos ociosos de processamento do nível 1 sem sobrecarregá-lo, foi avaliado o tempo de processamento da aplicação, como pode ser observado na Figura 34c. Nota-se que o tempo de processamento do ambiente computacional de *fog* com 128 blocos de dados é 2.1 vezes no melhor caso (Experimento E6, Figura 34c) e 1.4 vezes no pior caso (Experimento E2, Figura 34c) mais rápido que o ambiente em nuvem para realizar o processo da tomada de decisão. Isso ocorre devido ao ambiente computacional de *fog* que, além de possuir recursos disponíveis para realizar o processamento, não necessita repassar os dados para um ambiente externo (isto é, nível 2). Com isso, o tempo gasto para repassar os dados para o ambiente externo, é utilizado para realizar o processamento das tomadas de decisões. Em outras palavras, o tempo para processar é muito mais rápido que o tempo para enviar os dados. Portanto, tais afirmações evidenciam a eficiência do ImPeRIum em um ambiente computacional de

fog, apresentado robustez no processamento das tomadas de decisões, sem sobrecarregar os recursos do sistema.

5.3 Considerações finais

Este capítulo apresentou o ImPeRIum, um sistema de decisão inteligente que forma um ambiente computacional de *fog* para gerenciar as aplicações da residência. Para realizar o processo de tomada de decisão, este capítulo explorou técnicas de inteligência computacional com o propósito de escolher a melhor técnica para ser utilizada no ImPeRIum. Para gerenciar as aplicações da residência, utilizou-se do paradigma de *fog computing* que foi composto por um conjunto de dispositivos inteligentes da residência. Diante disso, foi possível processar o conteúdo localmente na própria infraestrutura criada, e ganhar tempo na decisão. Tal infraestrutura é responsável por coletar e disseminar os dados no ambiente e, em seguida, detectar e atuar nas aplicações desejadas. Para disseminar os dados no ImPeRIum, implementou-se um módulo de comunicação baseado no paradigma *Publish/Subscribe* (Pub/Sub) que também permite conectar novos dispositivos e lidar com o problema de interoperabilidade entre eles.

O ImPeRIum foi avaliado tanto em um ambiente simulado quanto em um ambiente real. Quando comparado com outros trabalhos da literatura, o ImPeRIum mostrou avançar no estado da arte por obter três resultados promissores: (i) alta taxa de acertos com baixo atraso no processo de tomada de decisão; (ii) eficiência na disseminação da informação com baixo *overhead* na infraestrutura; e (iii) robustez no processamento com baixo consumo de energia. No próximo capítulo, são apresentadas as conclusões desta tese.

CONCLUSÃO

Os sistemas residenciais inteligentes permitem o gerenciamento dos recursos habitacionais da casa para monitorar e atuar de maneira inteligente em benefício do morador. Tais sistemas são dependentes da sua infraestrutura de comunicação interna para disseminar dados e atuar no ambiente. Ainda, o sistema residencial inteligente deve otimizar o seu funcionamento para realizar a escolha da melhor ação no processo de tomada de decisão. Nesse contexto, a pesquisa desenvolvida nesta tese contribui para a área de sistema residencial inteligente por meio das soluções propostas. Para isso, foi elaborada uma revisão sistemática que investigou o estado da arte em sistemas residenciais inteligentes que (i) identificou as lacunas para esta tese e, (ii) norteou novos projetos de pesquisa na área em questão. Com o objetivo de atender os problemas encontrados na literatura e superá-los, esta tese apresentou duas soluções nomeadas como ResiDI e ImPeRIum, sendo o ImPeRIum derivado do ResiDI. As soluções apresentadas foram cientes dos problemas decorrentes da energia residual dos nós da infraestrutura de comunicação e da precisão para as tomadas de decisões.

As soluções apresentadas foram avaliadas extensivamente e comparadas com um trabalho da literatura. As avaliações utilizaram métodos estatísticos paramétricos e não-paramétricos para analisar os resultados obtidos. Os resultados reais e simulados mostraram alcançar o objetivo desta tese, sendo quatro deles notáveis: (i) aumento da precisão nas tomadas de decisões; (ii) redução no consumo de energia dos nós da rede; (iii) redução no tempo de resposta da atuação com baixa sobrecarga; e (iv) eficiência na disseminação das informações. Portanto, por meio dos resultados, pode-se comprovar que é possível garantir uma redução no consumo de energia nos nós da rede com eficiência na disseminação dos dados, ao mesmo tempo em que provê uma alta precisão na tomada de decisão com um ganho no tempo de resposta para realizar a sua atuação.

6.1 Principais contribuições

As principais contribuições desta tese foram apresentadas em forma de documentos científicos que foram publicados e submetidos em conferências e periódicos nacionais e internacionais. A seguir são apresentadas as publicações provenientes desta tese, seguida das publicações derivadas desta pesquisa e,

finalizada com as publicações correlacionadas deste trabalho com o grupo de pesquisa.

Publicações provenientes desta tese, sendo este discente o primeiro autor:

- **Rocha Filho, G. P.**; Ueyama, J.; Façal, B.; Guidoni, D. L.; Villas L. A.. “ResiDI: Um Sistema de Decisão Inteligente para Infraestruturas Residenciais via Sensores e Atuadores Sem Fio”. Publicado no XXXIII Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos, SBRC, 2015, Vitória, ES. (**Qualis B2**).
- **Rocha Filho, G. P.**; Ueyama, J.; Façal, B.; Guidoni, D. L.; Pazzi, R. W.; Villas, L. A.;. “An Energy-Aware System for Decision-Making in a Residential Infrastructure Using WSN”. Publicado no 14th IEEE International Symposium on Network Computing and Applications, NCA’15, Cambridge. (**Qualis B1**).
- **Rocha Filho, G. P.**; Torres Neto, J. R.; Ueyama, J.. “Uma Solução para Tomadas de Decisões em um Ambiente Residencial baseado em fog computing e inteligência computacional”. Publicado no Workshop de Computação Urbana (CoUrb) do Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos, SBRC, 2017, Belém, Pará.
- **Rocha Filho, G. P.**; Mano, L. Y.; Valejo, A. D.; Villas, L. A.; Ueyama, J.. “A Low-Cost Smart Home Automation to Enhance Decision-Making based on Fog Computing and Computational Intelligence”. Publicado na Revista IEEE América Latina, 2018. (**Qualis B4, Fator de Impacto 0.631**).
- **Rocha Filho, G. P.**; Villas, L. A.; Heitor, F.; Valejo, A. D.; Guidoni, D. L.; Ueyama, J. “ResiDI: Towards a Smarter Smart Home System for Decision-Making Using Wireless Sensors and Actuators”. Publicado na Elsevier Computer Networks, 2018. (**Qualis A1, Fator de Impacto 2.516**).
- **Rocha Filho, G. P.**; Villas, L. A.; Gonçalves, V. P.; Façal, B.; Gomes, P. H.; Pessin, G.; Ueyama, J.. “A Systematic review in smart home systems that covers energy efficiency: Infrastructure and decision-making process”. Aceito para publicação na ACM Computing Surveys, 2018. (**Qualis A1, Fator de Impacto 6.748**).
- **Rocha Filho, G. P.**; Torres Neto, J. R.; Valejo, A. D.; Meneguette, R. I.; Villas L. A.; Ueyama, J.. “Um Sistema de Controle Neuro-Fog para Infraestruturas Residenciais via Objetos Inteligentes”. Publicado no XXXVI Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos, SBRC, 2018, Campos do Jordão, SP. (**Qualis B2**).

Publicações derivadas desta tese, sendo este discente o segundo autor:

- Meneguette, R. I.; **Rocha Filho, G. P.**; Bittencourt, L.; Ueyama, J.; Krishnamachari, B.; Villas L. A. “Enhancing Intelligence in Intervehicle Communications to Detect and Reduce Congestion in Urban Centers”. Publicado na IEEE Symposium on Computers and Communications, ISCC 2015, Larnaca, Cyprus. (**Qualis A2**).
- Meneguette, R. I.; **Rocha Filho, G. P.**; Bittencourt, L.; Ueyama, J.; Villas L. A. “A Solution for Detection and Control For Congested Roads Using Vehicular Networks”. Publicado na Revista IEEE América Latina, 2016. (**Qualis B4, Fator de Impacto 0.631**).

- Meneguette, R. I.; **Rocha Filho, G. P.**; Guidoni, D. L.; Pessin, G.; Villas, L. A.; Ueyama, J.. "Increasing Intelligence in Inter-Vehicle Communications to Reduce Traffic Congestions: Experiments in Urban and Highway Environments". Publicado na Plos One, 2016. (**Qualis B2, Fator de Impacto 2.806**).
 - Salienta-se que este trabalho gerou reportagem para a revista Pesquisa FAPESP (Ed. 248/Outubro de 2016) e destaque no site do CEMAI-CEPID¹. Tal publicação foi derivado do projeto de doutorado deste discente financiado pela FAPESP (processo, 2014/06330-5).
- Torres Neto, J. R.; **Rocha Filho, G. P.**; Mano, L. Y.; Ueyama, J.. "INCA: Um sistema healthcare flexível baseado no paradigma fog computing e publish/subscribe". Publicado no Workshop de Computação Urbana (CoUrb) do Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos, SBRC, 2017, Belém, Pará.

Publicações correlacionadas desta tese com o grupo de pesquisa:

- Correa, C.; Ueyama, J.; Meneguette, R. I.; Villas, L. A.; **Rocha Filho, G. P.** "Ad hoc vehicular: Exploratory evaluation of a vehicular ad hoc network in Urban and highway settings". Publicado no 7th International Conference on New Technologies, Mobility and Security, NTMS, 2015, Paris, France. (**Qualis B1**).
- Gonçalves, V. P.; Giancristofaro, G. T.; **Rocha Filho, G. P.**; Johnson, T.; Carvalho, V.; Pessin, G.; Neris, V. P. A.; Ueyama, J.. "Assessing users' emotion at interaction time: a multimodal approach with multiple sensors". Publicado no Soft Computing, 2016. (**Qualis A2, Fator de Impacto 2.472**).
- Gonçalves, V. P.; Costa, E. P.; Valejo, A. D.; **Rocha Filho, G. P.**; Johnson, T. M.; Pessin, G.; Ueyama, J.. "Enhancing intelligence in multimodal emotion assessments". Publicado em Applied Intelligence, 2016. (**Qualis B1, Fator de Impacto 1.904**).
- Façal, B. S.; Pessin, G.; **Rocha Filho, G. P.**; Carvalho, A. C. P. L. F.; Gomes, P. H.; Ueyama, J.. "Fine-Tuning of UAV Control Rules for Spraying Pesticides on Crop Fields: An Approach for Dynamic Environments". Publicado no International Journal on Artificial Intelligence Tools, 2016. (**Qualis B1, Fator de Impacto 0.778**).
- Mano, L. Y.; Façal, B. S.; Nakamura, L. H. V.; Gomes, P. H.; Libralon, G. L.; Meneguette, R. I.; **Rocha Filho, G. P.**; Giancristofaro, G. T.; Pessin, G.; Krishnamachari, B.; Ueyama, J.. "Exploiting IoT technologies for enhancing Health Smart Homes through patient identification and emotion recognition". Publicado no Elsevier Computer Communications, 2016. (**Qualis A2, Fator de Impacto 3.338**).
- Carvalho, E.; Façal, B. S.; **Rocha Filho, G. P.**; Vargas, P. A.; Ueyama, Jo; Pessin, G.. "Exploiting the use of machine learning in two different sensor network architectures for indoor localization". Publicado na IEEE International Conference on Industrial Technology, ICIT, 2016, Taipei, Taiwan. (**Qualis B3**).

¹ <http://www.cemeai.icmc.usp.br/educacao-e-difusao/item/405-estudo-sobre-transito-em-rede-edestaque-na-revista-pesquisa-fapesp>

6.2 Trabalhos futuros

Durante o desenvolvimento desta pesquisa, novas ideias surgiram para avançar no estado da arte em sistemas de automação residencial. Tais ideias, elencadas a seguir como trabalhos futuros, além de complementar esta tese, podem nortear novos projetos de pesquisa.

- Propor soluções de decisões baseadas em redes definidas por *software* (SDN). A SDN gerenciaria regiões ou sub-regiões de interesse por meio de controladores da SDN. Neste caso, a SDN poderia controlar: (i) as aplicações da residência; (ii) os recursos computacionais dos dispositivos da rede; ou (iii) os serviços na comunicação de dados. O uso da SDN nos dispositivos sem fio vem ganhando destaque nos últimos anos e, consequentemente, os desafios de pesquisas da SDN com redes sem fio conquistou interesse na comunidade científica acadêmica.
- Aplicar as soluções validadas nesta tese em outros tipos de sistemas, tais como predial, segurança e *Health Smart Homes*.
- Integrar as soluções desenvolvidas nas *smart grids*. Por *smart grid*, entende-se como o uso de tecnologias da informação no sistema elétrico de potência. O intuito é gerenciar a rede elétrica entre os consumidores e os fornecedores, e vice-versa. Com isso, é possível propor soluções baseadas nas tarifações dos fornecedores de energia. Com base nas tarifações, seria possível realizar o agendamento das operações dos aparelhos eletrônicos quando houvesse menos demanda de energia na rede elétrica. Em outras palavras, usar os aparelhos fora do horário de pico.
- Propor soluções sensíveis ao contexto de maneira individualizada para os sistemas residências. A solução poderia utilizar sensores de imagem para identificar o morador e, em seguida, detectar qual morador terá prioridade no processo de tomada de decisão.
- Outra vertente que poderia ser explorada diz respeito à privacidade das informações dos usuários. As soluções desenvolvidas não cobriram a parte de segurança das informações. Os componentes arquiteturais das soluções poderiam ser protegidos por mecanismos de segurança. Nas soluções apresentadas, as informações podem ser capturadas por equipamentos maliciosos que podem utilizá-los para benefícios de outras pessoas. Por isso, deve-se haver uma preocupação em proteger os dados pessoais dos usuários.

REFERÊNCIAS

- ABDMOULEH, Z.; GASTLI, A.; BEN-BRAHIM, L. Survey about public perception regarding smart grid, energy efficiency renewable energies applications in qatar. **Renewable and Sustainable Energy Reviews**, v. 82, p. 168 – 175, 2018. ISSN 1364-0321. Disponível em: <http://www.sciencedirect.com/science/article/pii/S1364032117312558>. Citado na página 21.
- AKYILDIZ, I. F.; KASIMOGLU, I. H. Wireless sensor and actor networks: research challenges. **Ad Hoc Networks**, Elsevier, v. 2, n. 4, p. 351 – 367, 2004. Citado nas páginas 22, 28 e 30.
- AKYILDIZ, I. F.; SU, W.; SANKARASUBRAMANIAM, Y.; CAYIRCI, E. A survey on sensor networks. **Communications magazine**, IEEE, v. 40, n. 8, p. 102–114, August 2002. Citado nas páginas 22, 25 e 26.
- AKYILDIZ, I. F.; VURAN, M. C. **Wireless sensor networks**. [S.l.]: John Wiley & Sons, 2010. v. 4. Citado nas páginas 25, 26, 27, 28, 29, 30 e 31.
- ARAÚJO, G. B.; DUARTE-FIGUEIREDO, F. d. L.; TOSTES, A. I.; LOUREIRO, A. A. A protocol for identification and minimization of traffic congestion in vehicular networks. In: **Computer Networks and Distributed Systems (SBRC), 2014 Brazilian Symposium on**. [S.l.]: IEEE, 2014. p. 103–112. Citado na página 26.
- BACHE, K.; LICHMAN, M. **UCI Machine Learning Repository**. 2013. Irvine, CA: University of California, School of Information and Computer Science. Disponível em: <http://archive.ics.uci.edu/ml>. Citado nas páginas 59, 76 e 78.
- BAI, X.; CAO, M.; LIU, L.; PANNEERSELVAM, J.; SUN, Q. Efficient estimation and control of wsans for the greenhouse environment. In: **Proceedings of the 9th International Conference on Utility and Cloud Computing**. New York, NY, USA: ACM, 2016. (UCC'16), p. 369–374. ISBN 978-1-4503-4616-0. Disponível em: <http://doi.acm.org/10.1145/2996890.3007853>. Citado na página 29.
- BARAKA, K.; GHOBRI, M.; MALEK, S.; KANJ, R.; KAYSSI, A. Low cost arduino/android-based energy-efficient home automation system with smart task scheduling. In: IEEE. **Computational Intelligence, Communication Systems and Networks (CICSyN), 2013 Fifth International Conference on**. Madrid, 2013. p. 296–301. Citado nas páginas 22, 39, 41, 42 e 49.
- BEGG, R.; HASSAN, R. Artificial neural networks in smart homes. In: AUGUSTO, J.; NUGENT, C. (Ed.). **Designing Smart Homes**. [S.l.]: Springer Berlin Heidelberg, 2006. v. 4008, p. 146–164. Citado nas páginas 32 e 33.
- BHARDWAJ, M.; CHANDRAKASAN, A. P. Bounding the lifetime of sensor networks via optimal role assignments. In: INSTITUTE OF ELECTRICAL ENGINEERS INC (IEEE). **IEEE INFOCOM**. [S.l.], 2002. v. 3, p. 1587–1596. Citado na página 52.
- BIOLCHINI, J.; MIAN, P. G.; NATALI, A. C. C.; TRAVASSOS, G. H. Systematic review in software engineering. **System Engineering and Computer Science Department COPPE/UFRJ, Technical Report ES**, v. 679, n. 05, 2005. Citado na página 37.
- BOTMA, J.; HANCKE, G. P.; RAMOTSOELA, T. D. Solar home energy management system. In: **2017 IEEE AFRICON**. [S.l.: s.n.], 2017. p. 1575–1580. Citado na página 21.

- BOUBICHE, S.; BOUBICHE, D. E.; AZZEDINE, B. Integrating big data paradigm in wsns. In: **Proceedings of the International Conference on Big Data and Advanced Wireless Technologies**. New York, NY, USA: ACM, 2016. (BDAW '16), p. 56:1–56:4. ISBN 978-1-4503-4779-2. Disponível em: <<http://doi.acm.org/10.1145/3010089.3017606>>. Citado na página 25.
- BOUDRIOUA, A.; YAHIAOUI, S.; OMAR, M.; BOUABDALLAH, A. Ereat: Efficient route estimation based-on actuator tracking for wsans. In: **Proceedings of the International Conference on Big Data and Advanced Wireless Technologies**. New York, NY, USA: ACM, 2016. (BDAW'16), p. 27:1–27:5. ISBN 978-1-4503-4779-2. Disponível em: <<http://doi.acm.org/10.1145/3010089.3010112>>. Citado na página 29.
- BOUKERCHE, A.; ARAUJO, R.; VILLAS, L. A novel qos based routing protocol for wireless actor and sensor networks. In: **Global Telecommunications Conference, 2007. GLOBECOM '07. IEEE**. [S.l.: s.n.], 2007. p. 4931–4935. Citado na página 28.
- BRAGA, A. P.; CARVALHO, A. P. de Leon F. de; LUDERMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações**. [S.l.]: Livros Tecnicos Cientificos, 2000. Citado nas páginas 33 e 34.
- CARDOSO, C. B.; GUIDONI, D. L.; MAIA, G.; UEYAMA, J.; LOUREIRO, A. A.; VILLAS, L. A. Uma solucao ciente do consumo de energia para os problemas de localizaçao 3d e sincronizacao em rssfs. In: (SBC) sociedade Brasileira de C. (Ed.). **Simposio Brasileiro de Redes de Computadores e Sistemas Distribuidos (SBRC)**. [S.l.: s.n.], 2014. v. 32, p. 765–778. Citado na página 25.
- CARVALHO, E.; FAIÇAL, B. S.; FILHO, G. P. R.; VARGAS, P. A.; UEYAMA, J.; PESSIN, G. Exploiting the use of machine learning in two different sensor network architectures for indoor localization. In: **2016 IEEE International Conference on Industrial Technology (ICIT)**. [S.l.: s.n.], 2016. p. 652–657. Citado nas páginas 32 e 33.
- CASIMIR, R.; BOUTLEUX, E.; CLERC, G.; YAHOU, A. The use of features selection and nearest neighbors rule for faults diagnostic in induction motors. **Eng. Appl. Artif. Intell.**, Pergamon Press, Inc., Tarrytown, NY, USA, v. 19, n. 2, p. 169–177, mar 2006. ISSN 0952-1976. Citado na página 33.
- CHENG, J.; KUNZ, T. A survey on smart home networking. **Carleton University, Systems and Computer Engineering**, Citeseer, 2009. Citado na página 21.
- CORREA, U.; PINTO, A.; CODAS, A.; FERREIRA, D.; MONTEZ, C. Redes locais sem fio: Conceitos e aplicacoes. **IV Escola Regional de Redes de Computadores. Passo Fundo, Brasil**, 2006. Citado na página 26.
- DAWADI, P. N.; COOK, D. J.; SCHMITTER-EDGEcombe, M. Automated cognitive health assessment from smart home-based behavior data. **IEEE Journal of Biomedical and Health Informatics**, v. 20, n. 4, p. 1188–1194, July 2016. ISSN 2168-2194. Citado na página 32.
- DITTAWIT, K.; AAGESEN, F. Architecture and functional framework for home energy management systems. In: BAUSCHERT, T. (Ed.). **Advances in Communication Networking**. [S.l.]: Springer Berlin Heidelberg, 2013, (Lecture Notes in Computer Science, v. 8115). p. 173–184. Citado nas páginas 22, 39, 45 e 49.
- ESCOBAR, J. A. D. Avaliação do consumo de energia na detecção de intrusões em redes de sensores sem fio utilizando um modelo realístico de energia. 2011. Citado na página 28.
- EUGSTER, P. T.; FELBER, P. A.; GUERRAOUI, R.; KERMARREC, A.-M. The many faces of publish/-subscribe. **ACM Comput. Surv.**, ACM, New York, NY, USA, v. 35, n. 2, p. 114–131, jun. 2003. ISSN 0360-0300. Disponível em: <<http://doi.acm.org/10.1145/857076.857078>>. Citado na página 75.

FAIÇAL, B. S.; COSTA, F. G.; PESSIN, G.; UEYAMA, J.; FREITAS, H.; COLOMBO, A.; FINI, P. H.; VILLAS, L.; OSORIO, F. S.; VARGAS, P. A.; BRAUN, T. The use of unmanned aerial vehicles and wireless sensor networks for spraying pesticides. **Journal of Systems Architecture**, Elsevier, p. 1–12, 2014. ISSN 1383-7621. Citado na página 27.

FAIÇAL, B. S.; FREITAS, H.; GOMES, P. H.; MANO, L. Y.; PESSIN, G.; CARVALHO, A. C. de; KRISHNAMACHARI, B.; UEYAMA, J. An adaptive approach for uav-based pesticide spraying in dynamic environments. **Computers and Electronics in Agriculture**, v. 138, n. Supplement C, p. 210 – 223, 2017. ISSN 0168-1699. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0168169916304173>>. Citado na página 50.

FAIÇAL, B. S.; PESSIN, G.; FILHO, G. P.; FURQUIM, G.; CARVALHO, A. C. de; UEYAMA, J. Exploiting evolution on uav control rules for spraying pesticides on crop fields. In: **Engineering Applications of Neural Networks**. [S.l.]: Springer International Publishing, 2014, (Communications in Computer and Information Science). Citado na página 29.

FAIÇAL, B. S.; PESSIN, G.; FILHO, G. P. R.; CARVALHO, A.; FURQUIM, G.; UEYAMA, J. Fine-tuning of uav control rules for spraying pesticides on crop fields. In: **Tools with Artificial Intelligence (ICTAI), 2014 IEEE 26th International Conference on**. [S.l.: s.n.], 2014. p. 527–533. ISSN 1082-3409. Citado nas páginas 26 e 27.

FAIÇAL, B. S.; PESSIN, G.; FILHO, G. P. R.; CARVALHO, A. C. P. L. F.; GOMES, P. H.; UEYAMA, J. Fine-tuning of uav control rules for spraying pesticides on crop fields: An approach for dynamic environments. **International Journal on Artificial Intelligence Tools**, v. 25, n. 01, p. 1660003, 2016. Disponível em: <<http://www.worldscientific.com/doi/abs/10.1142/S0218213016600034>>. Citado nas páginas 26, 29 e 50.

FARIAS, C.; PIRMEZ, L.; DELICATO, F.; SOARES, H.; SANTOS, I. D.; CARMO, L. A control and decision system for smart buildings. In: **Ubiquitous Intelligence and Computing, 2013 IEEE 10th International Conference on and 10th International Conference on Autonomic and Trusted Computing (UIC/ATC)**. [S.l.]: IEEE, 2013. p. 254–261. Citado nas páginas 22 e 46.

FARIAS, C.; PIRMEZ, L.; DELICATO, F. C.; PIRES, P. F.; LI, W.; ZOMAYA, A. Y.; JORGE, E. N. de L. F.; JUAREZ-RAMIREZ, R. Grown: A control and decision system for smart greenhouses using wireless sensor networks. In: **Proceedings of the Australasian Computer Science Week Multiconference**. New York, NY, USA: ACM, 2017. (ACSW '17), p. 48:1–48:8. ISBN 978-1-4503-4768-6. Disponível em: <<http://doi.acm.org/10.1145/3014812.3014862>>. Citado na página 44.

FARIAS, C.; SOARES, H.; PIRMEZ, L.; DELICATO, F.; SANTOS, I.; CARMO, L. F.; SOUZA, J.; ZOMAYA, A.; DOHLER, M. A control and decision system for smart buildings using wireless sensor and actuator networks. **Transactions on Emerging Telecommunications Technologies**, Wiley Online Library, v. 25, n. 1, p. 120–135, 2014. Citado nas páginas 22, 32, 39, 46, 48, 49, 52 e 58.

FENG, M.-W.; WEN, S.-L.; TSAI, K.-C.; LIU, Y.-C.; LAI, H.-R. Wireless sensor network and sensor fusion technology for ubiquitous smart living space applications (invited paper). In: **Universal Communication, 2008. ISUC '08. Second International Symposium on**. [S.l.]: IEEE, 2008. p. 295–302. Citado na página 59.

FENSEL, A.; TOMIC, S.; KUMAR, V.; STEFANOVIC, M.; ALESHIN, S. V.; NOVIKOV, D. O. Sesame-s: Semantic smart home system for energy efficiency. **Informatik-Spektrum**, v. 36, n. 1, p. 46–57, 2013. Citado nas páginas 22, 39, 40, 41 e 49.

FILHO, G. P. R.; MANO, L. Y.; VALEJO, A. D. B.; VILLAS, L. A.; UEYAMA, J. A low-cost smart home automation to enhance decision-making based on fog computing and computational intelligence. **IEEE Latin America Transactions**, IEEE, v. 16, n. 1, p. 186–191, 2018. Citado na página 26.

FILHO, P. G.; NETO, J. R. T.; VALEJO, A.; MENEGUETTE, R. I.; VILLAS, L. A.; UHEYAMA, J. Um sistema de controle neuro-fog para infraestruturas residenciais via objetos inteligentes. In: **Simpósio Brasileiro de Redes de Computadores (SBRC)**. [S.l.: s.n.], 2018. v. 36. Citado na página 27.

FILHO, P. G.; VILLAS, L. A.; FREITAS, H.; VALEJO, A.; GUIDONI, D. L.; UHEYAMA, J. Residi: Towards a smarter smart home system for decision-making using wireless sensors and actuators. **Computer Networks**, Elsevier, v. 135, p. 54–69, 2018. Citado na página 27.

FORTINO, G.; GUERRIERI, A.; O'HARE, G.; RUZZELLI, A. A flexible building management framework based on wireless sensor and actuator networks. **Journal of Network and Computer Applications**, v. 35, n. 6, p. 1934 – 1952, 2012. ISSN 1084-8045. Citado na página 59.

FURQUIM, G.; JALALI, R.; PESSIN, G.; PAZZI, R. W.; UHEYAMA, J. *et al.* How to improve fault tolerance in disaster predictions: a case study about flash floods using iot, ml and real data. **Sensors**, Multidisciplinary Digital Publishing Institute, v. 18, n. 3, p. 907, 2018. Citado na página 26.

FURQUIM, G.; PESSIN, G.; FAIÇAL, B. S.; MENDIONDO, E. M.; UHEYAMA, J. Improving the accuracy of a flood forecasting model by means of machine learning and chaos theory. **Neural Computing and Applications**, v. 27, n. 5, p. 1129–1141, Jul 2016. Citado nas páginas 26 e 50.

GIUNTINI, F. T.; BEDER, D. M.; UHEYAMA, J. Exploiting self-organization and fault tolerance in wireless sensor networks: A case study on wildfire detection application. **International Journal of Distributed Sensor Networks**, v. 13, n. 4, p. 1550147717704120, 2017. Disponível em: <<https://doi.org/10.1177/1550147717704120>>. Citado nas páginas 26 e 50.

GOVINDAN, R.; ESTRIN, D. Sensor network tomography: Monitoring wireless sensor networks. **SIGCOMM Comput. Commun. Rev.**, ACM, New York, NY, USA, v. 32, n. 1, p. 64–64, jan. 2002. ISSN 0146-4833. Disponível em: <<http://doi.acm.org/10.1145/510726.510738>>. Citado na página 26.

GOVINDAN, R.; SHENKER, S.; ESTRIN, D.; GANESAN, D. Highly-resilient, energy-efficient multipath routing in wireless sensor networks. **SIGMOBILE Mob. Comput. Commun. Rev.**, ACM, New York, NY, USA, v. 5, n. 4, p. 11–25, out. 2001. ISSN 1559-1662. Disponível em: <<http://doi.acm.org/10.1145/509506.509514>>. Citado na página 25.

GUIDONI, D.; SOUZA, F.; UHEYAMA, J.; VILLAS, L. Topological routing for heterogeneous wireless sensor networks. In: **Computers and Communication (ISCC), 2014 IEEE Symposium on**. [S.l.: s.n.], 2014. p. 1–6. Citado na página 29.

GUNGOR, V. C.; LU, B.; HANCKE, G. P. Opportunities and challenges of wireless sensor networks in smart grid. **Industrial Electronics, IEEE Transactions on**, IEEE, v. 57, n. 10, p. 3557–3564, October 2010. Citado na página 26.

GÖKCELI, S.; KURT, G. K.; ÖRS, B. Backhaul infrastructures in building automation systems: Wired or wireless? In: **2016 3rd International Symposium on Wireless Systems within the Conferences on Intelligent Data Acquisition and Advanced Computing Systems (IDAACS-SWS)**. [S.l.: s.n.], 2016. p. 70–74. Citado na página 40.

HAYKIN, S. **Neural Networks: A Comprehensive Foundation**. 2nd. ed. Upper Saddle River, NJ, USA: Prentice Hall PTR, 1998. ISBN 0132733501. Citado na página 32.

HAYKIN, S. S. **Neural networks and learning machines**. [S.l.]: Pearson Upper Saddle River, NJ, USA:, 2009. v. 3. Citado nas páginas 32 e 33.

IRVAN, M.; TERANO, T. Distributed classifier system for smart home's machine learning. In: _____. **Agent-Based Approaches in Economics and Social Complex Systems IX: Post-Proceedings of The**

AESCS International Workshop 2015. Singapore: Springer Singapore, 2017. p. 191–197. ISBN 978-981-10-3662-0. Disponível em: <https://doi.org/10.1007/978-981-10-3662-0_15>. Citado nas páginas 22, 39, 47 e 49.

JAIN, R. The art of computer systems performance analysis: Techniques for experimental design, measurement, simulation, and modeling. **SIGMETRICS Perform.**, New York: John, New York, NY, USA, 1991. ISSN 0163-5999. Citado nas páginas 58 e 63.

JAVED, A.; LARIJANI, H.; AHMADINIA, A.; GIBSON, D. Smart random neural network controller for hvac using cloud computing technology. **IEEE Transactions on Industrial Informatics**, v. 13, n. 1, p. 351–360, Feb 2017. ISSN 1551-3203. Citado na página 32.

JIANG, L.; LIU, D.-Y.; YANG, B. Smart home research. In: IEEE. **Machine Learning and Cybernetics, 2004. Proceedings of 2004 International Conference on**. Shanghai, 2004. v. 2, p. 659–663. Citado nas páginas 21 e 40.

JÚNIOR, J. F.; CARVALHO, E.; FERREIRA, B. V.; SOUZA, C. de; SUHARA, Y.; PENTLAND, A.; PESSIN, G. Driver behavior profiling: An investigation with different smartphone sensors and machine learning. **PLoS one**, Public Library of Science, v. 12, n. 4, p. e0174959, 2017. Citado na página 32.

KAFI, M. A.; OTHMAN, J. B.; BADACHE, N. A survey on reliability protocols in wireless sensor networks. **ACM Comput. Surv.**, ACM, New York, NY, USA, v. 50, n. 2, p. 31:1–31:47, maio 2017. ISSN 0360-0300. Disponível em: <<http://doi.acm.org/10.1145/3064004>>. Citado na página 25.

KANG, B.; KIM, S.; CHOI, M. I.; CHO, K.; JANG, S.; PARK, S. Analysis of types and importance of sensors in smart home services. In: **2016 IEEE 18th International Conference on High Performance Computing and Communications; IEEE 14th International Conference on Smart City; IEEE 2nd International Conference on Data Science and Systems (HPCC/SmartCity/DSS)**. [S.l.: s.n.], 2016. p. 1388–1389. Citado na página 39.

KAZARIAN, A.; TESLYUK, V.; TSMOTS, I.; MASHEVSKA, M. Units and structure of automated “smart” house control system using machine learning algorithms. In: **2017 14th International Conference The Experience of Designing and Application of CAD Systems in Microelectronics (CADSM)**. [S.l.: s.n.], 2017. p. 364–366. Citado nas páginas 22, 39, 47 e 49.

KHAN, M.; SILVA, B. N.; HAN, K. Internet of things based energy aware smart home control system. **IEEE Access**, v. 4, p. 7556–7566, October 2016. ISSN 2169-3536. Citado nas páginas 22, 39, 42, 43 e 49.

KIM, Y.; SCHMID, T.; CHARBIWALA, Z. M.; FRIEDMAN, J.; SRIVASTAVA, M. B. Nawms: Noninvasive autonomous water monitoring system. In: ACM. **Proceedings of the 6th ACM conference on Embedded network sensor systems**. [S.l.], 2008. p. 309–322. Citado na página 26.

KLUES, K.; HANDZISKI, V.; LU, C.; WOLISZ, A.; CULLER, D.; GAY, D.; LEVIS, P. Integrating concurrency control and energy management in device drivers. In: ACM. **Proceedings of Twenty-first ACM SIGOPS Symposium on Operating Systems Principles**. New York, NY, USA, 2007. (SOSP’07, 6), p. 251–264. ISBN 978-1-59593-591-5. Citado na página 60.

KRISHNAMACHARI, B.; GOVINDAN, R. The impact of spatial correlation on routing with compression in wireless sensor networks. **ACM Trans. Sen. Netw.**, ACM, New York, NY, USA, v. 4, n. 4, p. 24:1–24:33, set. 2008. ISSN 1550-4859. Disponível em: <<http://doi.acm.org/10.1145/1387663.1387670>>. Citado na página 25.

KUPPER, A. Front matter, location-based services. In: _____. [S.l.]: John Wiley Sons, Ltd, 2005. Citado na página 53.

- LEE, J. H.; LEE, H.; KIM, M. J.; WANG, X.; LOVE, P. E. Context-aware inference in ubiquitous residential environments. **Computers in Industry**, Elsevier, v. 65, n. 1, p. 148 – 157, 2014. Citado nas páginas 21, 22, 39, 45 e 49.
- LEE, W. S.; HONG, S. H. Implementation of a knx-zigbee gateway for home automation. In: IEEE. **Consumer Electronics, 2009. ISCE'09. IEEE 13th International Symposium on**. Kyoto, 2009. p. 545–549. Citado na página 21.
- LI, J.; MOHAPATRA, P. Analytical modeling and mitigation techniques for the energy hole problem in sensor networks. **Pervasive and Mobile Computing**, v. 3, n. 3, p. 233 – 254, 2007. ISSN 1574-1192. Citado na página 47.
- LIN, Y.-J.; LATCHMAN, H. A.; LEE, M.; KATAR, S. A power line communication network infrastructure for the smart home. **Wireless Communications**, IEEE, v. 9, n. 6, p. 104–111, 2002. Citado nas páginas 21, 22, 39, 40, 41 e 49.
- LOUREIRO, A. A.; NOGUEIRA, J. M. S.; RUIZ, L. B.; MINI, R. A. d. F.; NAKAMURA, E. F.; FIGUEIREDO, C. M. S. Redes de sensores sem fio. In: (SBC) sociedade Brasileira de C. (Ed.). **Simposio Brasileiro de Redes de Computadores e Sistemas Distribuidos (SBRC)**. [S.l.: s.n.], 2003. v. 21, p. 179–226. Citado nas páginas 25 e 26.
- MAHMOOD, A.; KHAN, I.; RAZZAQ, S.; NAJAM, Z.; KHAN, N.; REHMAN, M.; JAVAID, N. Home appliances coordination scheme for energy management (hacs4em) using wireless sensor networks in smart grids. In: **Procedia Computer Science**. [S.l.]: Elsevier, 2014. v. 32, p. 469 – 476. Citado nas páginas 22, 39, 42 e 49.
- MAHMUD, R.; KOTAGIRI, R.; BUYYA, R. Fog computing: A taxonomy, survey and future directions. In: _____. **Internet of Everything: Algorithms, Methodologies, Technologies and Perspectives**. Singapore: Springer Singapore, 2017. p. 103–130. ISBN 978-981-10-5861-5. Disponível em: <https://doi.org/10.1007/978-981-10-5861-5_5>. Citado na página 75.
- MANTORO, T.; AYU, M. A.; ELNOUR, E. E. Web-enabled smart home using wireless node infrastructure. In: **Proceedings of the 9th International Conference on Advances in Mobile Computing and Multimedia**. New York, NY, USA: ACM, 2011. (MoMM'11), p. 72–79. Citado nas páginas 22, 39, 41, 42 e 49.
- MARKOV, A. A. Extension of the limit theorems of probability theory to a sum of variables connected in a chain. John Wiley & Sons, Inc., p. 552–577, 1971. Citado na página 32.
- MCCULLOCH, W.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, Kluwer Academic Publishers, v. 5, n. 4, p. 115–133, 1943. ISSN 0007-4985. Citado nas páginas 13, 33 e 34.
- MEKIKIS, P.-V.; ATHANASIOU, G.; FISCHIONE, C. A wireless sensor network testbed for event detection in smart homes. In: IEEE. **Distributed Computing in Sensor Systems (DCOSS), 2013 IEEE International Conference on**. Cambridge, 2013. p. 321–322. Citado na página 21.
- MENEGUETTE, R. I.; FILHO, G. P. R.; GUIDONI, D. L.; PESSIN, G.; VILLAS, L. A.; UHEYAMA, J. Increasing intelligence in inter-vehicle communications to reduce traffic congestions: Experiments in urban and highway environments. **PLOS ONE**, Public Library of Science, v. 11, n. 8, p. 1–25, 08 2016. Disponível em: <<https://doi.org/10.1371/journal.pone.0159110>>. Citado nas páginas 26, 33 e 50.
- MINENO, H.; KATO, Y.; OBATA, K.; KURIYAMA, H.; ABE, K.; ISHIKAWA, N.; MIZUNO, T. Adaptive home/building energy management system using heterogeneous sensor/actuator networks. In: **Consumer Communications and Networking Conference (CCNC), 2010 7th IEEE**. [S.l.: s.n.], 2010. p. 1–5. Citado nas páginas 21, 22, 39, 41 e 49.

MING, A.; LUO, H.; REN, Y.; PANG, Z.; TSANG, K. F. A energy efficient multi-dimension model for system control in smart environment systems. In: **2016 IEEE 14th International Conference on Industrial Informatics (INDIN)**. [S.l.: s.n.], 2016. p. 946–949. Citado nas páginas 22, 39, 47 e 49.

MINSKY, M. L.; PAPERT, S. A. **Perceptrons: An Introduction to Computational Geometry**. [S.l.]: The MIT Press, 1987. Citado na página 34.

MITCHELL, T. M. **Machine Learning**. New York, NY, USA: McGraw-Hill Science, 1997. Citado nas páginas 32, 33 e 56.

MONARD, M. C.; BARANAUSKAS, J. A. Conceitos sobre aprendizado de máquina. **Sistemas Inteligentes-Fundamentos e Aplicações**, v. 1, n. 1, 2003. Citado na página 32.

NIKOLOPOULOS, C. **Expert Systems: Introduction to First and Second Generation and Hybrid Knowledge Based Systems**. 1st. ed. New York, NY, USA: Marcel Dekker, Inc., 1997. ISBN 0824799275. Citado na página 32.

OJUROYE, O.; TORAH, R.; BEEBY, S.; WILDE, A. Smart textiles for smart home control and enriching future wireless sensor network data. In: **Sensors for Everyday Life**. [S.l.]: Springer, 2017. p. 159–183. Citado na página 26.

ORESTIS, A.; DIMITRIOS, A.; DIMITRIOS, D.; IOANNIS, C. Smart energy monitoring and management in large multi-office building environments. In: **Proceedings of the 17th Panhellenic Conference on Informatics**. New York, NY, USA: ACM, 2013. p. 219–226. Citado na página 21.

PAZZI, R.; ZHANG, D.; BOUKERCHE, A.; MOKDAD, L. E-trail: Energy-efficient trail-based data dissemination protocol for wireless sensor networks with mobile sinks. In: **Communications (ICC), 2011 IEEE International Conference on**. [S.l.]: IEEE, 2011. p. 1–5. ISSN 1550-3607. Citado na página 27.

PESSIN, G. **Estratégias inteligentes aplicadas em robôs móveis autônomos e em coordenação de grupos de robôs**. Tese (Doutorado) — Instituto de Ciências Matemáticas e de Computação, University of São Paulo, São Carlos, Disponível em: <<http://www.teses.usp.br/teses/disponiveis/55/55134/tde-25062013-160156/>>, 2013. Citado nas páginas 32 e 35.

PESSIN, G.; OSORIO, F. S.; SOUZA, J. R.; COSTA, F. G.; UEYAMA, J.; WOLF, D. F.; BRAUN, T.; VARGAS, P. A. Evolving an indoor robotic localization system based on wireless networks. In: JAYNE, C.; YUE, S.; ILIADIS, L. (Ed.). **Engineering Applications of Neural Networks**. [S.l.]: Springer Berlin Heidelberg, 2012, (Communications in Computer and Information Science, v. 311). p. 61–70. ISBN 978-3-642-32908-1. Citado na página 27.

PESSIN, G.; OSORIO, F. S.; UEYAMA, J.; WOLF, D. F.; MOIOLI, R. C.; VARGAS, P. A. Self-localisation in indoor environments combining learning and evolution with wireless networks. In: **Proceedings of the 29th Annual ACM Symposium on Applied Computing**. New York, NY, USA: ACM, 2014. (SAC '14), p. 661–666. Citado nas páginas 29, 32 e 33.

PESSIN, G.; SOUZA, J. R.; OSÓRIO, F. S.; FAICAL, B. S.; FILHO, G. P. R.; UEYAMA, J.; VARGAS, P. A.; WOLF, D. F. Investigation on the evolution of a robotic controller for autonomous vehicle navigation. **J. Intell. Fuzzy Syst.**, IOS Press, Amsterdam, The Netherlands, The Netherlands, v. 27, n. 6, p. 3047–3058, nov. 2014. ISSN 1064-1246. Citado na página 33.

PRATAP, K.; SHELJA. Artificial neural network (ann) inspired from biological nervous system. **International Journal of Application or Innovation in Engineering & Management (IJAIEEM)**, p. 227–231, 2013. Citado na página 32.

PRATHAP, U.; SHENOY, P. D.; VENUGOPAL, K.; PATNAIK, L. Wireless sensor networks applications and routing protocols: Survey and research challenges. In: IEEE. **Cloud and Services Computing (ISCOS), 2012 International Symposium on**. Mangalore, 2012. p. 49–56. Citado na página 25.

- RAMLEE, R.; OTHMAN, M.; LEONG, M.; ISMAIL, M.; RANJIT, S. Smart home system using android application. In: IEEE. **Information and Communication Technology (ICoICT), 2013 International Conference of**. Bandung, 2013. p. 277–280. Citado nas páginas 22, 39, 41, 44 e 49.
- REED, R. Pruning algorithms-a survey. **IEEE transactions on Neural Networks**, IEEE, v. 4, n. 5, p. 740–747, 1993. Citado na página 35.
- RIVERA-ILLINGWORTH, F.; CALLAGHAN, V.; HAGRAS, H. A neural network agent based approach to activity detection in ami environments. In: **IEEE international workshop on intelligent environments**. [S.l.: s.n.], 2005. p. 92–99. Citado na página 32.
- ROCHA FILHO, G. P.; TORRES NETO, J. R. N.; UHEYAMA, J. Uma solução para tomadas de decisões em um ambiente residencial baseado em fog computing e inteligência computacional. In: **2017 XXXV Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos, Workshop: Computação Urbana**. [S.l.: s.n.], 2017. Citado na página 26.
- ROCHA FILHO, G. P.; UHEYAMA, B. S. F. J.; PESSIN, G.; FARIAS, C. M. de; PAZZI, R. W.; GUIDONI, D. L.; VILLAS, L. A. An energy-aware system for decision-making in a residential infrastructure using wireless sensors and actuators. In: **International Symposium on Network Computing and Applications (NCA)**. [S.l.: IEEE - To Appear, 2015. Citado nas páginas 29, 47 e 50.
- ROCHA FILHO, G. P.; UHEYAMA, J.; FAIÇAL, B. S.; GUIDONI, D. L.; VILLAS, L. A. Residi: An intelligent decision platform for residential infrastructure using wireless sensors and actuators. In: **2015 XXXIII Brazilian Symposium on Computer Networks and Distributed Systems**. [S.l.: s.n.], 2015. p. 237–245. Citado nas páginas 26, 35, 75 e 76.
- ROCHA FILHO, G. P.; UHEYAMA, J.; VILLAS, L. A.; PINTO, A.; GONÇALVES, V. P.; SERAPHINI, S. An intelligent approach for improving energy efficiently in smart grids. In: THE STEERING COMMITTEE OF THE WORLD CONGRESS IN COMPUTER SCIENCE, COMPUTER ENGINEERING AND APPLIED COMPUTING (WORLDCOMP). **Proceedings of the International Conference on Wireless Networks (ICWN)**. [S.l.], 2013. p. 1. Citado na página 27.
- ROCHA FILHO, G. P.; UHEYAMA, J.; VILLAS, L. A.; PINTO, A. R.; GONÇALVES, V. P.; PESSIN, G.; PAZZI, R. W.; BRAUN, T. Nodepm: A remote monitoring alert system for energy consumption using probabilistic techniques. **Sensors**, v. 14, n. 1, p. 848–867, 2014. ISSN 1424-8220. Citado nas páginas 14, 21, 22, 26, 32, 39, 42, 45, 49, 50, 59, 60, 76 e 78.
- RODRIGUES, T.; DELICATO, F. C.; BATISTA, T.; PIRES, P. F.; PIRMEZ, L. An approach based on the domain perspective to develop wspan applications. **Software & Systems Modeling**, v. 16, n. 4, p. 949–977, Oct 2017. ISSN 1619-1374. Disponível em: <<https://doi.org/10.1007/s10270-015-0498-5>>. Citado na página 29.
- ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological review**, American Psychological Association, v. 65, n. 6, p. 386, 1958. Citado na página 34.
- RUMELHART, D. E.; MCCLELLAND, J. L.; GROUP, C. P. R. (Ed.). **Parallel Distributed Processing: Explorations in the Microstructure of Cognition, Vol. 1: Foundations**. Cambridge, MA, USA: MIT Press, 1986. ISBN 0-262-68053-X. Citado nas páginas 34 e 59.
- SENDRA, S.; LABORDA, A.; DÍAZ, J.; LLORET, J. A smart bluetooth-based ad hoc management system for appliances in home environments. In: GUO, S.; LLORET, J.; MANZONI, P.; RUEHRUP, S. (Ed.). **Ad-hoc, Mobile, and Wireless Networks**. [S.l.: Springer International Publishing, 2014, (Lecture Notes in Computer Science, v. 8487). p. 128–141. Citado nas páginas 22, 39, 44 e 49.

SIANO, P.; GRADITI, G.; ATRIGNA, M.; PICCOLO, A. Designing and testing decision support and energy management systems for smart homes. **Journal of Ambient Intelligence and Humanized Computing**, v. 4, n. 6, p. 651–661, 2013. Citado na página 43.

SINGH, D.; MERDIVAN, E.; PSYCHOULA, I.; KROPF, J.; HANKE, S.; GEIST, M.; HOLZINGER, A. Human activity recognition using recurrent neural networks. In: _____. **Machine Learning and Knowledge Extraction: First IFIP TC 5, WG 8.4, 8.9, 12.9 International Cross-Domain Conference, CD-MAKE 2017, Reggio, Italy, August 29 – September 1, 2017, Proceedings**. Cham: Springer International Publishing, 2017. p. 267–274. ISBN 978-3-319-66808-6. Disponível em: <https://doi.org/10.1007/978-3-319-66808-6_18>. Citado na página 32.

SOARES, H. R. d. S.; PIRMEZ, L.; DELICATO, F. C.; FARIAS, C. M. de. Conde: Um sistema de controle e decisao para edificios inteligentes usando redes de sensores e atuadores sem fio. In: **XXX SBRC**. [S.l.: s.n.], 2012. Citado na página 46.

SOUZA, A. M. de; BRENNAND, C. A.; YOKOYAMA, R. S.; DONATO, E. A.; MADEIRA, E. R.; VILLAS, L. A. Traffic management systems: A classification, review, challenges, and future perspectives. **International Journal of Distributed Sensor Networks**, v. 13, n. 4, p. 1550147716683612, 2017. Disponível em: <<https://doi.org/10.1177/1550147716683612>>. Citado na página 26.

SOUZA, J. R.; PESSIN, G.; EBOLI, G. B.; MENDES, C. C. T.; OSÓRIO, F. S.; WOLF, D. F. Vision and gps-based autonomous vehicle navigation using templates and artificial neural networks. In: **Proceedings of the 27th Annual ACM Symposium on Applied Computing**. New York, NY, USA: ACM, 2012. (SAC'12), p. 280–285. ISBN 978-1-4503-0857-1. Citado na página 32.

SPINOSA, E. J. **Deteção de novidade com aplicação a fluxos contínuos de dados**. Tese (Doutorado) — Universidade de São Paulo - USP, Disponível em: <<http://www.teses.usp.br/teses/disponiveis/55/55134/tde-02042008-112027/>>, 2008. Citado na página 32.

STANFORD-CLARK, A.; NIPPER, A. Mq telemetry transport. 2014. Disponível em: <<http://mqtt.org>>. Citado na página 75.

SUMINO, H.; ISHIKAWA, N.; MURAKAMI, S.; KATO, T.; HJELM, J. Pucc architecture, protocols and applications. In: IEEE. **Consumer Communications and Networking Conference, 2007. CCNC 2007. 4th IEEE**. [S.l.], 2007. p. 788–792. Citado na página 42.

TANG, Y.; CIUCIU, I. Semantic decision support models for energy efficiency in smart-metered homes. In: **Trust, Security and Privacy in Computing and Communications (TrustCom), 2012 IEEE 11th International Conference on**. [S.l.]: IEEE, 2012. p. 1777–1784. Citado nas páginas 22, 39, 46 e 49.

TEICH, T.; ROESSLER, F.; KRETZ, D.; FRANKE, S. Design of a prototype neural network for smart homes and energy efficiency. **Procedia Engineering**, v. 69, p. 603 – 608, 2014. Citado nas páginas 22, 44 e 45.

TOMIC, S.; FENSEL, A.; PELLEGRINI, T. Sesame demonstrator: Ontologies, services and policies for energy efficiency. In: **Proceedings of the 6th International Conference on Semantic Systems**. New York, NY, USA: ACM, 2010. p. 24–28. Citado nas páginas 22, 39, 45, 46 e 49.

UEYAMA, J.; FAIÇAL, B. S.; MANO, L. Y.; BAYER, G.; PESSIN, G.; GOMES, P. H. Enhancing reliability in wireless sensor networks for adaptive river monitoring systems: Reflections on their long-term deployment in brazil. **Computers, Environment and Urban Systems**, v. 65, n. Supplement C, p. 41 – 52, 2017. ISSN 0198-9715. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0198971516301351>>. Citado nas páginas 27 e 50.

UEYAMA, J.; FREITAS, H.; FAIÇAL, B.; FILHO, G.; FINI, P.; PESSIN, G.; GOMES, P.; VILLAS, L. Exploiting the use of unmanned aerial vehicles to provide resilience in wireless sensor networks. **Communications Magazine, IEEE**, v. 52, n. 12, p. 81–87, December 2014. Citado na página 27.

UEYAMA, J.; HUGHES, D.; MAN, K. L.; GUAN, S.; MATTHYS, N.; HORRE?, W.; MICHIELS, S.; HUYGENS, C.; JOOSEN, W. Applying a multi-paradigm approach to implementing wireless sensor network based river monitoring. In: IEEE. **Cryptography and Network Security, Data Mining and Knowledge Discovery, E-Commerce Its Applications and Embedded Systems (CDEE), First ACIS International Symposium on**. Qinhuangdao, 2010. p. 187–191. Citado na página 27.

UEYAMA, J.; PINTO, V. P. V.; MADEIRA, E. R. M.; GRACE, P.; JONHSON, T. M. M.; CAMARGO, R. Y. Exploiting a generic approach for constructing mobile device applications. In: **Proceedings of the Fourth International ICST Conference on COMMunication System softWARE and middlewaRE**. New York, NY, USA: ACM, 2009. (COMSWARE '09), p. 12:1–12:12. ISBN 978-1-60558-353-2. Disponível em: <<http://doi.acm.org/10.1145/1621890.1621906>>. Citado na página 52.

USMAN, A.; SHAMI, S. H. Evolution of communication technologies for smart grid applications. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 19, p. 191–199, 2013. Citado na página 41.

VERDONE DAVIDE DARDARI, G. M. R.; CONTI, A. **Wireless Sensor and Actuator Networks. Technologies, Analysis and Design**. 1. ed. Academic Press, 2008. ISBN 978-0-12-372539-4. Disponível em: <<http://gen.lib.rus.ec/book/index.php?md5=6e74c86c3388c23057e44929f17bd5f1>>. Citado na página 28.

VILLAS, L.; BOUKERCHE, A.; RAMOS, H.; OLIVEIRA, H. de; ARAUJO, R. de; LOUREIRO, A. Drina: A lightweight and reliable routing approach for in-network aggregation in wireless sensor networks. **Computers, IEEE Transactions on**, v. 62, n. 4, p. 676–689, April 2013. ISSN 0018-9340. Citado na página 27.

VILLAS, L. A. **Protocolos de Roteamento Cientes de QoS para Redes de Sensores e Atuadores Sem Fio**. Dissertação (Mestrado), Maio 2007. Citado nas páginas 28 e 30.

VILLAS, L. A. **Soluções cientes de agregação de dados da correlação espaço-temporal e consumo de energia para realizar coleta de dados em redes de sensores sem fio**. Tese (Doutorado) — Instituto de Ciências Exatas da Universidade Federal de Minas Gerais, Disponível em: <<http://hdl.handle.net/1843/ESBF-8SVGUA>>, 2012. Citado na página 28.

VILLAS, L. A.; BOUKERCHE, A.; GUIDONI, D. L.; OLIVEIRA, H. A. B. F. D.; ARAUJO, R. B. D.; LOUREIRO, A. A. F. An energy-aware spatio-temporal correlation mechanism to perform efficient data collection in wireless sensor networks. **Computer Communications**, Elsevier Science Publishers B. V., Amsterdam, The Netherlands, The Netherlands, v. 36, n. 9, p. 1054–1066, May 2013. Citado nas páginas 25, 27 e 29.

VILLAS, L. A.; GUIDONI, D. L.; ARAUJO, R. B.; BOUKERCHE, A.; LOUREIRO, A. A. Um algoritmo ciente da correlacao espaco-temporal e consumo de energia para coleta de dados em redes de sensores sem fio. In: (SBC) sociedade Brasileira de C. (Ed.). **Simposio Brasileiro de Redes de Computadores e Sistemas Distribuidos**. [S.l.: s.n.], 2012. v. 30, p. 131–144. Citado na página 28.

WU, Y. C.; CHEN, L. B.; CHANG, W. J.; YANG, C. C.; YU, C. T. Implementation of a zigbee-based wireless router for home automation systems. In: **2017 IEEE International Conference on Consumer Electronics - Taiwan (ICCE-TW)**. [S.l.: s.n.], 2017. p. 61–62. Citado nas páginas 22, 39, 42, 43 e 49.

ZHILENKOV, A. A.; GILYAZOV, D. D.; MATVEEV, I. I.; KRISHTAL, Y. V. Power line communication technologies in automated control systems. In: IEEE. **Young Researchers in Electrical and Electronic Engineering (EIconRus), 2017 IEEE Conference of Russian**. [S.l.], 2017. p. 246–249. Citado na página 41.

PLANEJAMENTO DO PROTOCOLO PARA REVISÃO SISTEMÁTICA

Este apêndice apresenta a elaboração do protocolo utilizado para conduzir a revisão sistemática. A explicação do protocolo está dividida em quatro partes para nortear as análises dos trabalhos selecionados, a saber: (i) definir os objetivos da pesquisa; (ii) formular as questões de pesquisa; (iii) especificar as estratégias de busca; e (iv) determinar os critérios de inclusão e exclusão para a seleção dos estudos primários.

A.1 Objetivos da pesquisa

Esta revisão sistemática tem como objetivo investigar o estado da arte em sistemas residenciais inteligentes, tendo como foco principal a infraestrutura e o processo de tomada de decisão. Com vistas em alcançar o objetivo geral, delimitou-se metas específicas, as quais incluem:

1. Identificar e analisar os tipos de infraestruturas adotadas que têm sido utilizadas para sensorar e disseminar os dados do ambiente.
2. Identificar e analisar as abordagens que têm sido aplicadas para o processo de tomada de decisão.
3. Identificar como as aplicações têm sido integradas nos sistemas residenciais inteligentes.
4. Identificar as vantagens e limitações encontradas nos itens 1, 2 e 3.

De acordo com a pesquisa realizada até o momento, não foi observada na literatura uma revisão sistemática que endereçam os itens citados anteriormente. Além disso, é válido argumentar que tais itens não devem ser tratados separadamente, pois são as bases para a implantação e gerenciamento de uma casa inteligente.

A.2 Questões de pesquisa

Com o intuito de atender os objetivos propostos, duas questões de pesquisa foram formuladas para nortear esta revisão sistemática, a saber:

- Questão 1: Quais são os tipos de infraestruturas adotadas para a comunicação de dados, considerando a implantação de uma rede interna nos sistemas residenciais?
- Questão 2: Quais são as soluções que têm sido propostas para realizar o processo de tomada de decisão nas aplicações nos sistemas residenciais?

As questões de pesquisa foram essenciais para definir o processo de condução deste trabalho, bem como os critérios de seleção dos estudos primários e a estratégia de busca adotada para identificar tais estudos.

A.3 Estratégias de busca para a seleção dos trabalhos

Para a análise e seleção dos trabalhos em um estudo primário, foram utilizadas uma série de palavras chaves e seus sinônimos para elaborar uma *string* de busca, a saber: (i) *home automation system*; (ii) *domotic*; (iii) *smart home*; (iv) *decision-making*; (v) *infrastructure*; (vi) *sensor*; (vii) *actuator*; (viii) *energy consumption*; (ix) *energy efficiency*; e (x) *energy management*. Tais palavras chaves estão relacionadas com as questões de pesquisa, bem como com os objetivos propostos neste trabalho. A partir das palavras chaves, operadores booleanos foram utilizados para formular expressões de busca, com as seguintes base de dados: (i) Scopus¹; (ii) ACM Digital Library²; (iii) ScienceDirect³; (iv) Springer⁴; e (v) IEEE Xplore Digital Library⁵.

A.4 Critérios e procedimentos para a seleção dos trabalhos

As questões de pesquisa foram definidas para fornecer as entradas apropriadas ao protocolo. Com tais questões de pesquisa, foram definidos para elaborar o protocolo os seguintes Critérios de Inclusão (CI):

CI 1 – Trabalhos que apresentem o modelo da infraestrutura adotada para a coleta de dados;

CI 2 – Trabalhos que apresentem as aplicações e os tipos de sensores;

CI 3 – Trabalhos que apresentem propostas ou soluções para o processo de tomada de decisão; e

¹ <http://www.scopus.com/>

² <http://dl.acm.org/>

³ <http://www.sciencedirect.com/>

⁴ <http://link.springer.com/>

⁵ <http://ieeexplore.ieee.org/>

CI 4 – Trabalhos que apresentem a integração do processo de tomada de decisão com a infraestrutura.

Ainda na fase de elaboração do protocolo, foram definidos os seguintes Critérios de Exclusão (CE):

CE 1 – Publicações que não possuam informações suficientes para responder as questões de pesquisa;

CE 2 – Publicações hospedadas em serviços inacessíveis ou com acesso restrito a grupos específicos de pesquisadores;

CE 3 – Publicações não disponíveis na íntegra, ou seja, com apenas títulos e resumos;

CE 4 – Publicações com a mesma contribuição. Nesse caso, a publicação mais completa é selecionada, e as demais publicações são citadas;

CE 5 – Publicações escritas em idiomas diferentes do Inglês ou do Português; e

CE 6 – Publicações com registros de erratas e retratações.

Deve-se ressaltar que tais critérios delimitam quais artigos serão selecionados para serem lidos na íntegra, como apresentado no Capítulo 3.