

UNIVERSIDADE ESTADUAL DO MARANHÃO
CENTRO DE CIÊNCIAS TECNOLÓGICAS
COORDENAÇÃO DE PÓS-GRADUAÇÃO

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE
COMPUTAÇÃO E SISTEMAS

APRENDIZAGEM POR REFORÇO EM LOTE PARA MINIMIZAÇÃO DO
CONSUMO ELÉTRICO EM CASAS INTELIGENTES

Elton de Sousa e Silva

Orientador: Prof. Dr. Mauro Sérgio Silva Pinto
Coorientador: Prof. Dr. José Pinheiro de Moura

2022

APRENDIZAGEM POR REFORÇO EM LOTE PARA MINIMIZAÇÃO DO CONSUMO ELÉTRICO EM CASAS INTELIGENTES

Elton de Sousa e Silva

Orientador: Prof. Dr. Mauro Sérgio Silva Pinto

Coorientador: Prof. Dr. José Pinheiro de Moura

Dissertação apresentada Programa de Pós-Graduação
em Engenharia de Computação e Sistemas da
Universidade Estadual do Maranhão:

**São Luís
2022**

Silva, Elton de Sousa e:
Aprendizagem por esforço em lote para minimização do consumo elétrico
em casas inteligentes / Elton de Sousa e Silva – São Luís, 2022.

— f.

Dissertação (Mestrado) – Programa de Pós-Graduação em Engenharia de
Computação e Sistemas, Universidade Estadual do Maranhão, 2022.

Orientador: Prof. Dr. Mauro Sérgio Silva Pinto.

Coorientador: Prof. Dr. José Pinheiro de Moura.

1. Aprendizagem - Esforço em lote. 2. Redes neurais. 3. Casas inteligentes.
4. Consumo elétrico. I. Título.

CDU: 004.09.621.311

ELTON DE SOUSA E SILVA

**APRENDIZAGEM POR REFORÇO EM LOTE PARA MINIMIZAÇÃO DO
CONSUMO ELÉTRICO EM CASAS INTELIGENTES**

Dissertação apresentada Programa de Pós-
Graduação em Engenharia de Computação e
Sistemas da Universidade Estadual do
Maranhão.

Aprovado em: 2 / 2


BANCA EXAMINADORA



Prof.^a Dr. Mauro Sérgio Silva Pinto (Orientador)
Universidade Estadual do Maranhão



Prof. Dr. José Pinheiro de Moura (Co-orientador)
Universidade Estadual do Maranhão



Prof. Dr. Espaldado Edson Clementino Santana
Examinador Interno
Universidade Estadual do Maranhão



Prof. Dr. Daniel Augusto dos Santos
Examinador Externo
Universidade Federal do Espírito Santo

Lista de Figuras

Figura 1 – Publicações sobre eficiência energética	15
Figura 2 – Comparativo do Consumo em lâmpadas antes e depois da utilização IoT SEM16	16
Figura 3 – Fluxograma do DSSM	17
Figura 4 – Representação Simplificada do Neurônio Biológico	19
Figura 5 – O primeiro modelo de neurônio artificial de McCulloch e Pitts	20
Figura 6 – RNA feedforward simples	20
Figura 7 – Tipos de Aprendizado de Máquina	21
Figura 8 – Elementos da Aprendizagem por Reforço	23
Figura 9 – Principais áreas de aplicações de IoT	24
Figura 10 – Arquitetura básica do Protocolo MQTT	27
Figura 11 – ZigBee Alliance	28
Figura 12 – Topologia ZigBee	29
Figura 13 – Topologia do Sistema AutoDomo	31
Figura 14 – DashBoard AutoDomo	32
Figura 15 – Dados AutoDomo bruto em formato JSON	33
Figura 16 – Fases da Mineração de Dados	34
Figura 17 – Dados Minerados no Google Colab	35
Figura 18 – Estrutura do Sistema de Gerenciamento de Energia	38
Figura 19 – Topologia da Rede Neural	40
Figura 20 – Parte 1 do Algoritmo SIGEAD	41
Figura 21 – Parte 2 do Algoritmo SIGEAD	42
Figura 22 – Parte 3 do Algoritmo SIGEAD	42
Figura 23 – Parte 4 do Algoritmo SIGEAD	43
Figura 24 – Consumo Estimado x Consumo Real (outubro)	43
Figura 25 – Consumo de novembro 2021 x novembro 2022	46
Figura 26 – Consumo de dezembro 2021 x dezembro 2022	46

Lista de Quadros

Quadro 1 – Possível Aplicações de Aprendizado Supervisionado	22
Quadro 2 – Aprendizado não Supervisionado exemplo de Aplicações	22
Quadro 3 – Comparativo entre IPv4 e IPv6.	26
Quadro 4 – Comparação entre protocolo MQTT e HTTP	27
Quadro 5 – Questionário Qualitativo	47

Lista de Tabelas

Tabela 1 – Comparativa entre ST e SiE	30
Tabela 2 – Dispositivos Gerenciado pelo SIGEAD	44

Lista de Siglas

ANEL	<i>Agência Nacional de Energia Elétrica</i>
BLE	<i>Bluetooth Low Energy</i>
BRL	<i>Batch Reinforcement Learning</i>
IoT	<i>Internet of Things (Internet das Coisas)</i>
MM	<i>Machine to Machine</i>
MQTT	<i>Message Queue Telemetry Transport</i>
NAT	<i>Network Address Translation</i>
RNA	<i>Redes Neurais Artificiais</i>
SIGEAD	<i>Sistema Integrado de Gerenciamento de Energia</i>

Resumo

Neste trabalho é utilizada a técnica de aprendizagem por reforço em lote, com uma rede neural artificial do tipo *perceptron* multicamadas, para minimização do consumo de energia elétrica em casas inteligentes. A residência do experimento é automatizada, com histórico de consumo de todos os dispositivos elétricos conectados à rede. No trabalho foi usado o sistema de gestão de energia elétrica para comparação do consumo. A partir dos resultados se pode observar que houve uma redução média de 4,52% e 5,19% no mês de novembro e dezembro de 2021 se comparado ao mesmo período do ano anterior.

Palavras-chave: aprendizagem por reforço em lote, redes neurais, casas inteligentes, consumo elétrico.

Abstract

In this work, the batch reinforcement learning technique is used, with an artificial neural network of the multilayer perceptron type, to minimize electrical energy consumption in smart houses. The experiment residence is automated, with consumption history of all electrical devices connected to the network. In the work, the electrical energy management system was used to compare consumption. From the results, it can be observed that there is an average reduction of 4.52% and 5.19% in November and December 2021 compared to the same period of the previous year.

Keywords: Batch reinforcement learning, neural networks, smart homes, electric consumption.

SUMÁRIO

Resumo	8
1. Introdução	12
1.1. Objetivos	13
1.1.1. Objetivo Geral	13
1.1.2. Objetivos Específicos	13
1.2. Problema e Justificativa	13
1.2.1. Problema	13
1.2.2. Justificativa	13
1.3. Organização do projeto	14
2. Revisão Bibliográfica	14
2.1. Estudo de Anterioridade e Estado da Arte	15
2.2. Considerações sobre os trabalhos relacionados	18
3. Metodologia	19
3.1. Arquitetura de Redes Neurais Artificiais (RNA)	20
3.1.1. Aprendizado e Treinamento	21
3.1.1.1. Aprendizado de Máquina Supervisionado	21
3.1.1.2. Aprendizado de Máquina não Supervisionado	22
3.1.1.3. Aprendizado por Reforço	23
3.2. Internet das Coisas	23
3.2.1. IoT e Seus Desafio	24
3.2.1.1. Segurança	25
3.2.1.2. Privacidade	25
3.2.1.3. Infraestrutura	25
3.2.1.4. Energia	26
3.3. Protocolo MQTT	26
3.4. Protocolo Zigbee	28
3.5. Protocolo BLE	30
3.6. Sistema de Automação Residencial AutoDomo	31
3.7. Pré-processamento de dados	32
3.8. Treinamento do Sistema de eficiência energética	35
3.8.1. Aprendizagem por Reforço em Lote	35
3.8.2. Fitted Q Iteration	36

3.8.3	Aplicação do BRL no Sistema AutoDomo	37
3.8.4	Identificado os Estados (Classes) e Ações	38
3.8.5	Treinamento	39
4.	Resultados Experimentais	44
5.	Considerações Finais	48
5.1.	Trabalhos Futuros	48
5.2.	Produção bibliográfica	49
	Referências Bibliográficas	50

1. Introdução

A automação de residência é um fenômeno tecnológico recente, que com o aumento do uso de dispositivos com tecnologia sem fio embarcado do tipo *Wi-Fi*, *Bluetooth*, *ZigBee*, dentre outros, tem ganhado o mercado de residências privadas, prédios públicos, parques industriais e edifícios comerciais. A popularização dos *smartphones* também contribuiu bastante para a rapidez com que a Internet das Coisas (*Internet Of Things – IoT*) tem se desenvolvido. Sem dúvida, o resultado maior está focado nas pessoas, pois traz ao proprietário um sistema de controle de malha fechada, com a possibilidade de aquisição e processamento de sinais dos diversos tipos de sistemas.

As instituições públicas e privadas, assim como as famílias, têm aumentado os investimentos em tecnologias que promovam o consumo racional e eficiente de energia elétrica. Vale ressaltar que um dos principais conceitos de eficiência energética é fazer igual ou melhor com menos consumo de energia, sem abrir mão do conforto e qualidade (MARCICANO, 2011).

Vários trabalhos utilizam inteligência artificial na busca por economia de energia, em Marbherro-Cano (2010) é apresentada o HEMS-IoT (*Home Energy Management System*) com um sistema de gerenciamento de energia residencial inteligente baseado em *Big Data* e aprendizado de máquina, com um objetivo de economia de energia sem a perda do conforto e da segurança.

Amaral (2019) utiliza-se de redes neurais artificiais e decomposição de séries temporais com a finalidade de previsão do consumo de energia elétrica de curto prazo em prédios residenciais, como forma de conscientização baseado no fornecimento de informações úteis e de fácil interpretação para os moradores.

No trabalho Reddy, Rabbani e Oo (2019) foi desenvolvida uma plataforma de IoT com a finalidade de melhorar a eficiência energética e o gerenciamento do lado da demanda em tempo real, utilizando para isso o micro-computador *Raspberry Pi* e vários sensores instalados ao longo da casa.

Logenthiran, Phat e Woo (2018) desenvolveram o *Home Energy Management System*, que é um sistema de gerenciamento de energia doméstica baseado em aprendizagem de máquina, capaz de coletar dados da residência (horário, potência dos equipamentos, demandas) para ditar ao usuário uma forma de como reduzir ou otimizar o uso da energia, com implementações de mudanças para melhor uso de energia durante o horário de pico e fora de pico.

1.1 Objetivos

1.1.1 Objetivo Geral

O objetivo deste trabalho é desenvolver uma rede neural artificial com a técnica de aprendizagem por reforço em lote Lacerda (2013) com a finalidade de redução do consumo de energia elétrica de uma residência automatizada sem abrir mão do conforto traido pelas novas tecnologias.

1.1.2 Objetivos Específicos

Para obtenção do objetivo geral são delineados os seguintes objetivos específicos:

- Redução do consumo de energia elétrica em casas automatizadas;
- Diminuição do impacto no conforto do usuário com a redução do consumo elétrico;
- Utilização do Sistema Integrado de Gerenciamento de Energia (SIGEAD) em qualquer sistema de automação residencial.

1.2 Problema e justificativa

1.2.1. Problema

A produção e o consumo de energia são ambientalmente impactantes para o mundo em muitos casos. Ao mesmo tempo, os padrões vigentes de consumo podem ser melhorados, estimulando o uso mais eficiente de energia, conforme frisam Goldemberg e Lucan (2007). O custo da energia elétrica no Brasil vem aumentando ao longo dos anos, com crescimento do custo da energia para o consumidor residencial em média de 59% entre 2012 e 2021. A tarifa média em 2021 para o consumidor residencial, sem impostos, foi de R\$ 630,13/MWh (ENERGÉTICA, 2021).

1.2.2. Justificativa

Segundo a Associação Brasileira de Automação Residencial (AURESIDE, 2006), existe um potencial atual para o fornecimento de equipamentos para 1,5 milhão de residências, estimando que cerca de 300 mil possuam equipamentos de automação. A automação residencial, é uma

ferramenta que também pode ser usada para otimizar a eficiência energética de uma residência, tendo em vista que pode integrar diversas informações, tais como iluminação, segurança, climatização e afins, em uma base de dados, permitindo assim a incorporação de mecanismos para a implementação de um programa de gerenciamento de energia (PEDRO, 2021).

Uma possibilidade de otimização é o uso de redes neurais artificiais, que é uma técnica de inteligência artificial que busca trabalhar no processamento de dados de maneira semelhante ao cérebro humano e pode ser interpretada como um esquema de processamento capaz de armazenar conhecimento baseado em aprendizagem (HAYKIN, 2007).

Dessa forma, com o objetivo de aproveitar os sistemas de automação residencial já instalados e o grande potencial de crescimento deste tipo de sistema no Brasil, justifica-se a importância deste trabalho, visando desenvolver um sistema que melhore a eficiência do consumo dos dispositivos elétricos, minimizando o impacto no uso e no conforto diário dos moradores.

1.3. Organização do projeto

Esta Dissertação está dividida em mais quatro capítulos além desta Introdução. No capítulo 2 é abordada a Revisão Bibliográfica com um estudo de anterioridade e estado da arte, assumindo uma cronologia de estudos relacionados à eficiência energética.

No capítulo 3 é indicada a metodologia aplicada no desenvolvimento da Dissertação. No capítulo 4 são tratados os resultados obtidos após a utilização da rede neural treinada com os dados reais dessa residência, enquanto no capítulo 5 são apresentadas as considerações finais e a sugestão de novas aplicações para o desenvolvimento de futuros trabalhos.


1. Revisão Bibliográfica

Neste capítulo são abordados os trabalhos relacionados à busca por eficiência energética.

2.1. Estudo de Anterioridade e Estado da Arte

A eficiência energética é um tema que tem abrangido diversos trabalhos, com intensificação por busca na otimização dos recursos, o que pode ser verificado pelo número de publicações relacionadas ao tema, como observado na Figura 1.

Figura 1 – Publicações sobre eficiência energética



Fonte: Autor (2022)

Diversos trabalhos têm abordado o tema com o uso da IoT, com diversas soluções. Em Machorro-Cano (2020) é apresentada o HEMS-IoT com um sistema de gerenciamento de energia residencial inteligente baseado em *Big Data* e aprendizado de máquina, com um objetivo de economizar energia sem a perda do conforto e da segurança. No processo de aprendizagem de máquina, foi utilizado o pacote de programa Weka desenvolvido em Java, trazendo como resultado uma economia de energia de 90kW em dois meses.

Anaral (2019) utilizou-se de redes neurais artificiais e decomposição de séries temporais com a finalidade de previsão do consumo de energia elétrica de curto prazo em prédio residencial, como forma de conscientização baseado no fornecimento de informações úteis e fácil interpretação para os moradores.


Assim como em Machorro-Cano (2020), Anaral (2019) verificou a inexistência de uma atuação ativa ou reativa aos dispositivos instalados na residência, contando apenas com a colaboração e conscientização direta dos moradores quanto à utilização dos dados obtidos para redução do consumo elétrico.

Por sua vez, Reddy, Rabbani e Oo (2019) propuseram o desenvolvimento de um sistema de gerenciamento de energia baseado em IoT com o objetivo de melhorar a eficiência energética

e gerenciamento do lado da demanda em tempo real. O sistema foi desenvolvido utilizando o microcomputador *Raspberry Pi*, com sensores instalados ao longo da casa com a finalidade de medição dos parâmetros ambientais como temperatura, umidade, além de sensores de presença. O objetivo principal do trabalho não foi necessariamente a diminuição do consumo de energia, mas o deslocamento da demanda para um período em que o custo da energia tivesse um valor tarifário inferior para o consumidor.

O resultado do trabalho pode ser visualizado na Figura 2, onde observa-se que houve economia de energia. A proposta principal do trabalho foi o deslocamento da demanda da residência, de tal forma a não poder ser aplicado em todos os tipos de residência brasileira, pois no Brasil, apenas poderia ser aplicado em locais que aderizam ou utilizam algum tipo de medição diferenciada por horário e demanda, o que corresponde apenas 0,1% dos consumidores.

Figura 2 - Comparativo do Consumo em lâmpadas antes e depois da implantação IoT SEM




Fonte: Reddy, Rabbani e Os (2019)

Em Logenthiran, Phan e Woo (2018) foi desenvolvido um sistema de gerenciamento de energia doméstica baseado em aprendizado de máquina denominado *Home Energy Management System*. O sistema é composto por um subsistema ou função que é denominado *Demand Side Management (DSM)* que tem a função de gerenciamento da demanda das cargas, ou seja, coleta os dados da residência (horário, potência dos equipamentos, demandas) para ditar ao usuário uma forma de como reduzir ou otimizar o uso da energia, através da implementações de mudanças para melhor uso de eletricidade durante o horário de pico e fora de pico. O sistema disponibiliza um aplicativo móvel que permite ao usuário ditar regras para aperfeiçoar a inteligência do sistema sem a perda do conforto.

O Sistema DSM implementado por Loganthiran, Phan e Woo (2015) se baseia na interação do usuário com a automação da residência com a finalidade de determinar a prioridade do sistema que deve ser desligado, conforme fluxograma da Figura 3.

Figura 3 - Fluxograma do DSM



Fonte: Loganthiran, Phan e Woo (2015)

Já Berlink, Kagan e Costa (2015) propuseram um sistema inteligente de suporte à decisão baseado em técnicas de aprendizado por reforço em lote como uma solução para o problema de decisão sequencial referente ao gerenciamento de energia de uma casa inteligente (*Smart Home*). Segundo os autores, os resultados obtidos mostram um ganho significativo na recompensa financeira pela utilização do algoritmo *Q-Learning* e do *Fitted Q-iteration*, que utilizam dados armazenados em um banco como forma de treinamento por reforço visando extrair a melhor

política de decisão. O sistema fornece política energética viável que decide sobre o armazenamento no sistema de baterias ou venda da energia produzida por microgeração para a concessionária, dessa forma maximizando o lucro quando a geração é maior que o consumo ou minimizando a conta do usuário quando o consumo é menor que a geração.

2.2. Considerações sobre os trabalhos relacionados

Como pode ser verificado nos trabalhos citados, um dos principais focos é o gerenciamento da demanda como forma de melhor aproveitamento do uso da energia conforme o preço do mercado e as regras locais. Nesse aspecto, este trabalho não se restringe apenas a um mero gerenciamento pelo lado da demanda, vai muito além disso, tem o potencial de promover a diminuição consumo de energia por meio do gerenciamento do uso dos aparelhos.

Este ponto é importante ser mencionado porque, apesar de o Brasil possuir um sistema de tarifação variável para consumidores residenciais conforme o dia e o horário denominado comercialmente de "Tarifa Branca"¹, houve baixíssima adesão por parte dos consumidores residenciais, o que torna soluções focadas em deslocamento de demanda de horário pouco atrativas e sistemas baseado na diminuição total do consumo, mas aceitos: (PEDRO, 2011). Esta característica local, traz a este trabalho a vantagem a de poder ser aplicado por consumidores residenciais que não optaram pela adesão à tarifa branca.

Em Berlinck, Kagan e Costa (2012) é proposto utilizar o mesmo de algoritmo de aprendizagem por reforço em lote como forma de busca uma política ótima sobre eficiência energética, o trabalho se distancia da presente pesquisa quanto ao objetivo final, pois não busca maximizar o lucro com a venda de energia ou minimização da conta de energia, mas indica a redução do consumo de energia, a partir do uso de um sistema inteligente de automação com controle total dos dispositivos elétricos instalados na residência. Dessa forma, o sistema elaborado para essa pesquisa pode desligar os dispositivos elétricos sem a necessidade de uma intervenção direta do proprietário da residência, diferentemente dos trabalhos apresentados anteriormente, os quais recomendam ações ao usuário, que podem ou não ser aceitas pelo mesmo, para diminuir o consumo de energia.


¹ A Tarifa Branca é uma norma regulamentada pela Agência Nacional de Energia Elétrica (ANEEL), que entrou em vigor a partir de janeiro de 2013. O objetivo da nova regulamentação é oferecer aos consumidores um novo regime de preço, como uma tarifa alternativa baseada na variação do valor da energia conforme o dia e o horário de consumo (CPFL, 2010).

3. Metodologia

As Redes Neurais Artificiais (RNA), ou simplesmente redes neurais, foram desenvolvidas para simular uma das características mais importantes dos seres humanos, que é a capacidade cognitiva. A evolução da aprendizagem sobre rede neural é formada por conhecimentos advindos de muitos ramos da ciência tais como a Matemática, Ciência da Computação, Engenharia, Estatística, Física, Biologia entre outros (HAYKIN, 2007).

A primeira noção de um neurônio artificial é de um artigo de 1943, elaborado por Warren McCulloch e Walter Pitts, conforme observado na Figura 4. Frank Rosenblatt, em 1958, apresentou o modelo *perceptron*, demonstrando que se as redes neurais artificiais fossem acrescidas de ligações ajustáveis poderiam ser treinadas de tal forma que poderiam ser utilizadas para classificação de tipos de padrões, propondo um algoritmo para treinar a rede (HAYKIN, 2007).


Figura 4 - Representação Simplificada de Neurônio Biológico



Fonte: Haykin (2007)

A partir dos anos de 1980 houve um aumento nas pesquisas em RNAs, quando Rumelhart, Williams e Hinton publicaram a descrição de um algoritmo de treinamento de retro propagação (*Backpropagation*) para solução dos problemas encontrados no *perceptron* (HAYKIN, 2007), cujo modelo de RNA pode ser observado na Figura 5.

Figura 3 – O primeiro modelo de neurônio artificial de McCulloch e Pitts.




Fonte: Haykin (2007).

3.1. Arquitetura de Redes Neurais Artificiais (RNA)

Uma RNA pode ser dividida em camadas com unidades que podem estar conectadas às unidades da camada posterior. Uma das formas mais simples de organização de uma rede neural pode ser observada na Figura 6, na qual não é utilizada uma camada interna, podendo resolver problemas lineares. Outros modelos utilizam camadas internas, também chamadas de ocultas, podendo ter dezenas de camadas internas utilizadas em aprendizados profundos (*Deep learning*).

Figura 6 – RNA *feedforward* simples



Fonte: Radly, Rabhi e Co (2019)

3.1.1 Aprendizado e Treinamento

O objetivo principal do aprendizado em uma rede neural é encontrar os pesos ótimos que possam definir a melhor função que tenha as saídas necessárias. O processo de aprendizagem em rede neural é algo que pode ser relativamente demorado e depende de alguns fatores como capacidade computacional, arquitetura dos RNAs, número de neurônios, número de camadas internas, função de ativação, número de interações, erros aceitáveis e outros (BRUMATTI, 2005). Vale ressaltar que o aprendizado em uma rede neural artificial não é um processo único e, mesmo nos dias de hoje, ainda é algo intensamente estudado.

A relação da rede neural com o ambiente é um fator importante para a determinação de paradigmas de aprendizagem (HONDA, 2017). Na Figura 7 podem ser visualizados alguns paradigmas dessa aprendizagem.

Figura 7 - Tipos de Aprendizado de Máquinas



Fonte: Honda (2017)

3.1.1.1. Aprendizado de Máquina Supervisionado

Diversos métodos de análise de dados utilizam algoritmos que aprendem iterativamente a partir dos dados, dentre os quais estão o aprendizado supervisionado e o não supervisionado, tentam prever uma variável dependente a partir de uma lista de variáveis independentes (DATA

SCIENCE ACADEMY, 2021). No Quadro 1 são indicados alguns parâmetros para aplicações de aprendizado supervisionado.

Quadro 1 – Possíveis Aplicações de Aprendizado Supervisionado	
Var. Independentes	Var. Dependentes
Anos de carreira, formação, idade	Salário
Idade do carro, idade do motorista	Risco de acidente autônomo
Texto de um livro	Escola literária
Temperatura	Receta de venda de sorvete
Imagem de rodovia	Ângulo de direção de um carro autônomo
Histórico escolar	Nota no ENEM

Fonte: Data Science Academy (2021).

3.1.1.2. Aprendizado de Máquina não Supervisionado

O aprendizado não supervisionado é um ramo que aprende com dados de teste que não foram rotulados, classificados ou categorizados previamente. Em vez de responder à programação de um operador, o aprendizado não supervisionado identifica semelhanças nos dados e reage com base na presença ou ausência de tais semelhanças em cada novo dado (ALIGER, 2019), uma das possíveis aplicação é listado no Quadro 2.


Quadro 2 – Aprendizado não Supervisionado exemplo de Aplicações	
Dados	Formas Representativas
Transações bancárias	Normalidade de transação
Registros de Compras	Associação entre produtos
Dados Multidimensionais	Dados com dimensão reduzida
Registros de Compras	Perfil das comunidades
Palavras em um texto	Representação sintática das palavras

Fonte: Aliger (2019).

3.1.1.3. Aprendizado por Reforço

Na aprendizagem por reforço o agente aprende a atingir uma meta em um ambiente incerto e potencialmente complexo. Na sequência de tomada de decisões, o computador se utiliza da tentativa e erro para encontrar uma solução para o problema. Nesse modelo, a aprendizagem da máquina deve receber recompensas ou penalidades pelas ações que executa, com o objetivo de maximizar a recompensa total. As partes componentes da aprendizagem por reforço são o agente, ambiente, política, sinal de reforço, e função valor (DATA SCIENCE ACADEMY, 2021), como ilustrado na Figura 8.

Figura 8 - Elementos da Aprendizagem por Reforço




3.2. Internet das Coisas

O termo 'Internet das Coisas' (*Internet of Things – IoT*) foi introduzido por Kevin Ashton em 1999, o qual procurou descrever um sistema em que objetos do mundo físico pudessem ser conectados à internet através de sensores (ASHTON, 2015). A IoT pode ser entendida como uma rede de dispositivos capazes de realizar controle e comunicar dados através da internet. Estes dispositivos possuem capacidade de processamento local de forma a interagir com seus estados internos ou variáveis do ambiente externo.

A IoT aliada a tecnologia do *Big Data* é usada no setor industrial nos processos decisórios, tendo grande importância para indústria 4.0 como um novo paradigma de processos de produção

e gerenciamento em diversas áreas de aplicação, como na indústria de manufatura, redes de energia elétrica, cidades inteligentes, monitoramento da saúde de pacientes, segurança patrimonial, sistemas de transporte e automação residencial (COLOMBO, LUCCA FILHO, 2018). Na Figura 9 podem ser observadas algumas das áreas de aplicações da tecnologia IoT.

Figura 9 - Principais áreas de aplicações de IoT



Fonte: Colombo e Lucca Filho (2018)

3.2.1 IoT e Seus Desafios

Segundo a Juniper Research (2020), o tamanho do mercado de dispositivos IoT está previsto para alcançar um valor estimado de 1,4 trilhões de dólares até 2027, sendo que até 2024 está previsto um total de 83 bilhões de dispositivos conectados à rede, com a quantidade de dados estimados em 73,1 bilhões de terabytes até 2025. Além das grandes possibilidades comerciais que estão surgindo, a IoT também traz grandes desafios nas áreas de segurança, privacidade, infraestrutura e energia.

3.2.1.1 Segurança

Grande parte dos dispositivos de IoT não incluem recursos de segurança e como esses dispositivos têm acesso à mesma infraestrutura de rede dos outros equipamentos da residência ou empresa, como computadores, celulares e servidores, são alvos de ataques de vírus, worms ou outros programas maliciosos. O ataque do próprio dispositivo IoT com o objetivo de controlar ou sequestrar os equipamentos, conhecido como *Ransomware das coisas*, com a finalidade de pedir "resgate" do dispositivo, é hoje também uma realidade (SALAT, 2017).

3.2.1.2 Privacidade

A confidencialidade dos dados consiste na manutenção de acesso apenas aos usuários autorizados, humanos e/ou máquinas. Uma solução é o uso de criptografia, que é uma tecnologia chave para alcançar a confidencialidade. Por outro lado, devido ao baixo custo dos dispositivos IoT, estes apresentam baixa capacidade de processamento ocasionada pelo uso de um microcontrolador, um microprocessador ou mesmo um microcomputador, atuando no controle de dispositivos domésticos, como máquina de lavar, geladeira, dentre outros. Isso implica no uso de protocolos com sistemas de segurança mais simples, que podem ser alvo de ataques diretos ou indiretos, não garantindo a privacidade dos dados armazenados nos dispositivos (SALAT, 2017).

3.2.1.3 Infraestrutura

Conforme a Juniper Research (2010), o protocolo IPV4 utilizado atualmente, tem uma capacidade de uso de dispositivos simultâneos chegando a valores de 4,2 bilhões disponíveis, porém a demanda é maior podendo chegar a 82 bilhões de dispositivos em 2024. Assim, uma alternativa foi a adoção da conversão de endereço de rede (NAT) que tem a função de converter endereço de IP público (endereço válido) em endereço privado (inválido). No entanto, dada a quantidade de dispositivos conectados à internet no mundo foi necessário a adoção de uma solução mais definitiva, que é o uso do protocolo IPV6 com capacidade de 340 undecilhões de endereços ou, $3,4 \times 10^{11}$ dispositivos.

O novo protocolo IPV6 não resolve apenas o problema da falta de endereços IPs, traz vários outros recursos novos em relação a sua versão anterior o IPv4 (MUNIZ et al., 2017), sendo um comparativo entre esses protocolos apresentados no Quando 3.

Quadro 3 – Comparativo entre IPv4 e IPv6

IPv4	IPv6
Endereço de 32 bits	Endereço de 128 bits
Suporte opcional de IPSec	Suporte obrigatório de IPSec
Nenhuma referência à capacidade de QoS (<i>Quality of Service</i>)	Introduz capacidades de QoS utilizando para isso o campo <i>Flow Label</i>
Processo de fragmentação realizada pelos roteadores	A fragmentação deixa de ser realizada pelos roteadores e passa ser processada pelos hosts emissores
O cabeçalho inclui os campos de opção	Todos os campos de opção foram movidos para dentro do campo <i>extension header</i>

Fonte: Menezes et al. (2017)

3.2.1.4 Energia

Os pontos importantes no projeto de dispositivos IoT é o uso dos protocolos de comunicação, os tipos de dados que serão modelados, a aplicação, a configuração do circuito e o tipo de alimentação (FELICIANO, 2021). A energização do dispositivo IoT pode ser um fator crítico quanto à geração de diversos problemas, dependendo da aplicação e do local de instalação. Em sistemas remotos, como lavouras ou grandes campos de plantações do agronegócio, a solução pode utilizar baterias recarregáveis e ou fontes de energia renováveis, como a energia solar.

Os dispositivos sem fio geralmente têm um consumo de energia maior devido à necessidade de transmissão de dados por onda de rádio, o que pode em muitos casos inviabilizar a bateria. Sendo assim, para esse propósito estão surgindo novas técnicas de "colheita" de energia de diversas fontes renováveis chamado de *Harvesting Energy*, que é o processo de captura e conversão de energia de uma ou mais fontes renováveis (GARG, GARG, 2017).

3.3. Protocolo MQTT

O protocolo MQTT (*Message Queue Telemetry Transport*) é um protocolo de comunicação entre máquinas (*Machine to Machine - M2M*) que projetado pelos engenheiros da IBM Andy Stanford-Clark e Arlen Nipper em 1999, sua aplicação original era vincular sensores em pipelines em indústria de petróleo a satélites (IBM, 2021).

A grande vantagem do protocolo MQTT em relação ao HTTP para uso em IoT, como abordado no Quadro 4, é que o MQTT é um protocolo leve, o que permite a implementação em *hardware* com baixa capacidade de processamento como microcontroladores.


Quadro 4 – Comparação entre protocolo MQTT e HTTP

	MQTT	HTTP
Orientação de Design	Centrado em dados	Centrado em Documentos
Request-Response	<i>Publish-Subscribe</i>	<i>Request-Response</i>
Complexidade	Simples	Completa
Tamanho Mensagem	Pequena Cabeçalho com apenas dois bytes	Maior, os detalhes do status são baseados em texto
Nível Serviço	Três nível de qualidade (Serviço)	Toda mensagem tem o mesmo nível de serviço
Biblioteca	30kb em C, 100kb em Java	Depende de aplicação mas geralmente não é pequena
Distribuição dados	1/0, 1/1, 1/Q	1/1

Fonte: IBM (2021)

O protocolo MQTT é definido basicamente em dois tipos de entidades na rede: o Servidor MQTT ou *Message Broker* e os dispositivos MQTT ou Clientes. O Broker é um servidor (computador) que recebe todas as mensagens dos clientes, depois reenvia para os clientes de destino, que são quaisquer dispositivos que tenham interesse em enviar ou receber informação pelo servidor MQTT, conforme a Figura 10.

Figura 10 – Arquitetura básica de Protocolo MQTT



Fonte: IBM (2021)

As mensagens MQTT são organizadas em tópicos, podendo definir quem pode escrever ou ler determinada mensagem garantido um nível a mais de segurança e organização, diferente de outros protocolos, como o HTTP.

3.4. Protocolo Zigbee

No ano de 2002 foi criada a *ZigBee Alliance*, que é uma associação de empresas, universidades e agências governamentais que têm o intuito de desenvolver o protocolo ZigBee (UFRJ, 2017). O logotipo do protocolo ZigBee (Figura 11 – ZigBee Alliance geralmente vem impresso em todos os dispositivos ou equipamentos que têm suporte ao protocolo).

A tecnologia Zigbee é principalmente utilizada em sensores e dispositivos com necessidade de baixo consumo de energia, os quais geralmente são alimentados por bateria. O protocolo utiliza o padrão IEEE 802.15.4 para WPAN e pode operar nas frequências de 868 MHz, 902-928 MHz e 2,4 GHz, dependendo do tipo de aplicação. Mas se tratando da automação residencial, é muito comum que os dispositivos utilizem a frequência de 2,4 GHz (OLIVEIRA, 2015). Os dispositivos que utilizam a tecnologia Zigbee podem ser classificados em três tipos, de acordo com suas funções na rede, como demonstrado na Figura 11.

Figura 11 – ZigBee Alliance



Fonte: UFRJ (2017)

- Coordenador

O Coordenador faz o papel de nó principal da rede, sendo através dele que toda a rede recebe um canal e um endereço para a comunicação, permitindo que os roteadores e os dispositivos finais interajam. Contudo, pode existir apenas um dispositivo coordenador na rede por vez, para diminuir o risco de falhas. Além disso, é aconselhável que o dispositivo coordenador seja alimentado diretamente pela rede elétrica.


- Roteador

Os dispositivos roteadores são usados na topologia em *mesh* e *cluster* para dar maior robustez à rede. Possuem tabelas de roteamento e permitem encontrar o menor caminho para chegar ao destino. Assim como os dispositivos coordenadores, também é aconselhável que esses sejam alimentados diretamente na rede elétrica.

- Dispositivo final

Os dispositivos finais podem ser desenvolvidos com os microcontroladores com capacidade de processamento e memória inferior, se comparados ao coordenador ou roteadores da rede. Não fazem função de roteamento, nem coordenam a rede, mas se comunicam diretamente com o roteador mais próximo. Geralmente passam quase todo o tempo em estado inativo, por isso são excelentes para serem usados diretamente com baterias. Na maioria das vezes dispositivos finais são utilizados em sensores, atuadores e sistemas de controle. A Figura 12 ilustra a versatilidade de topologias que podem ser aplicadas com o ZigBee.

Figura 12 - Topologia ZigBee



Fonte: UFRRJ (2017)

3.5 Protocolo BLE

Bluetooth Low Energy (BLE) surgiu a partir da versão 4.0 do *Bluetooth*, em 2010, com a finalidade de ser utilizado em IoT. Uma de suas principais vantagens em relação ao *Bluetooth* clássico é que permite diminuir os níveis de consumo de energia, podendo apresentar um gasto energético de apenas 10% em relação ao *Bluetooth* clássico, tornando possível alimentá-los com baterias (UFRJ, 2017). Há ainda outras diferenças que otimizam sua aplicação em relação ao seu modelo antecessor, como demonstrado na Tabela 1.

Tabela 1 – Comparativo entre BT e BLE

Especificações Técnicas	Bluetooth Clássico	Bluetooth Low Energy
Frequência	2400 a 2483,5MHz	2400 a 2483,5MHz
Esquema de modulação	GFSK	GFSK
Número de Canais	79	40
Comprimento de Banda do Canal	1MHz	2MHz
Taxa de transferência de dados	0,7 - 2,1Mbps	< 0,3Mbps
Velocidade	7	Ilimitado
Segurança	SD e L2CAP	128bit AES
Método de Transmissão	FSK	FSK
Velocidade	Positivo	Não indicada

Fonte: UFRJ (2017)

Se comparados com outros protocolos de comunicação focados em IoT, como Zigbee, a principal vantagem está no fato de que o BLE já vem embutido em praticamente todos os telefones inteligentes, o que facilita a utilização por parte dos usuários finais, não havendo necessidade de *gateway* para comunicação direta com um tablet, celular ou até mesmo computador (UFRJ, 2017).

3.6. Sistema de Automação Residencial AutoDomo

O Sistema AutoDomo foi desenvolvido pelo Engenheiro Elton de Sousa e Silva e Igor Aguiar, em 2019, com a finalidade de popularizar e facilitar a integração dos diversos protocolos e dispositivos IoT, além da possibilidade de múltiplas topologias, como ilustrado na Figura 13.

Figura 13 – Topologia do Sistema AutoDomo



Fonte: Autor (2022)

Os protocolos suportado pelo sistema AutoDomo:

- Suporte ao protocolo Bluetooth Low Energy (BLE);
- Suporte ao protocolo ZigBee;
- Suporte ao protocolo Wifi;
- Suporte ao protocolo MQTT;
- Armazenamento de dados de sistemas em nuvem.

O sistema é composto por uma *Dashboard* de fácil utilização que exige um mínimo de treinamento, conforme mostrado na Figura 14, e que pode ser rodado localmente em um dispositivo sem a necessidade de grandes requisitos computacionais ou mesmo em nuvem.

Figura 14 – DashBoard AutoDomo.



Fonte: Anzer (2022)


3.7. Pré-processamento de dados

Diariamente os usuários que se utilizam de algum sistema de automação residencial como AutoDomo podem gerar uma quantidade considerável de dados que são então armazenados em algum tipo de banco de dados, um exemplo disso está na Figura 15. Esses dados são essenciais para o processo de treinamento da inteligência artificial. Entretanto, para que isso possa acontecer de forma eficiente, se faz necessário um pré-processamento dos dados para, então, ser realizado o treinamento, pois frequentemente os dados apresentam diversos problemas, tais como:

- Grande quantidade de valores desconhecidos;
- Ruídos (atributos com valores incorretos);
- Atributo de baixo valor preditivo;
- Desproporção entre número de exemplo de cada classe.

Também faz parte do pré-processamento, a transformação da forma como os dados estão representados, com a finalidade de superar as limitações que possam existir no algoritmo de aprendizagem de máquina.

Figura 16 – Fases da Mineração de Dados



Fonte: Autor (2022)

Para o pré-processamento dos dados foi empregada a linguagem Python, rodada em um serviço em nuvem e gratuito, conhecido como *Google Colaboratory*, ou simplesmente *Google Colab*. Para auxiliar nesse processo de manipulação dos dados foi utilizada a biblioteca "Pandas" e como é possível ver na Figura 17, os dados já foram trabalhados organizados, sobretudo se comparados a Figura 16 – Fases da Mineração de Dados onde tínhamos os dados brutos e praticamente ilegíveis. O pré-processamento dos dados geralmente não pode ser totalmente automatizado ou, por vezes, é simplesmente semiautomático, pois depende da capacidade de analisar os dados para identificar os problemas presentes.

Figura 17 – Dados Alameda no Google Colab

EMPLOYEE													DEPT		
EMPID	EMPNAME	JOBID	JOBNAME	SALARY	COMM	COMM PCT	EMPID	EMPNAME	JOBID	JOBNAME	SALARY	COMM	COMM PCT		
1	SCOTT	ANALYST	ANALYST	3000	14	14	2	ADAMS	CLERK	CLERK	1100	0	0		
3	SMITH	CLERK	CLERK	1300	0	0	4	WARD	SALES	SALES	1200	5	5		
5	ALLEN	SALES	SALES	1600	25	25	6	MARTIN	SALES	SALES	1250	14	14		
7	WARD	SALES	SALES	1100	0	0	8	SCOTT	ANALYST	ANALYST	3000	14	14		
9	JONES	MANAGER	MANAGER	2800	0	0	10	ADAMS	CLERK	CLERK	1100	0	0		
11	SMITH	CLERK	CLERK	1300	0	0	12	WARD	SALES	SALES	1200	5	5		
13	WARD	SALES	SALES	1200	5	5	14	SCOTT	ANALYST	ANALYST	3000	14	14		
15	ADAMS	CLERK	CLERK	1100	0	0	16	JONES	MANAGER	MANAGER	2800	0	0		
17	SMITH	CLERK	CLERK	1300	0	0	18	WARD	SALES	SALES	1200	5	5		
19	WARD	SALES	SALES	1200	5	5	20	SCOTT	ANALYST	ANALYST	3000	14	14		
21	ADAMS	CLERK	CLERK	1100	0	0	22	JONES	MANAGER	MANAGER	2800	0	0		
23	SMITH	CLERK	CLERK	1300	0	0	24	WARD	SALES	SALES	1200	5	5		
25	WARD	SALES	SALES	1200	5	5	26	SCOTT	ANALYST	ANALYST	3000	14	14		
27	ADAMS	CLERK	CLERK	1100	0	0	28	JONES	MANAGER	MANAGER	2800	0	0		
29	SMITH	CLERK	CLERK	1300	0	0	30	WARD	SALES	SALES	1200	5	5		
31	WARD	SALES	SALES	1200	5	5	32	SCOTT	ANALYST	ANALYST	3000	14	14		
33	ADAMS	CLERK	CLERK	1100	0	0	34	JONES	MANAGER	MANAGER	2800	0	0		
35	SMITH	CLERK	CLERK	1300	0	0	36	WARD	SALES	SALES	1200	5	5		
37	WARD	SALES	SALES	1200	5	5	38	SCOTT	ANALYST	ANALYST	3000	14	14		
39	ADAMS	CLERK	CLERK	1100	0	0	40	JONES	MANAGER	MANAGER	2800	0	0		
41	SMITH	CLERK	CLERK	1300	0	0	42	WARD	SALES	SALES	1200	5	5		
43	WARD	SALES	SALES	1200	5	5	44	SCOTT	ANALYST	ANALYST	3000	14	14		
45	ADAMS	CLERK	CLERK	1100	0	0	46	JONES	MANAGER	MANAGER	2800	0	0		
47	SMITH	CLERK	CLERK	1300	0	0	48	WARD	SALES	SALES	1200	5	5		
49	WARD	SALES	SALES	1200	5	5	50	SCOTT	ANALYST	ANALYST	3000	14	14		
51	ADAMS	CLERK	CLERK	1100	0	0	52	JONES	MANAGER	MANAGER	2800	0	0		
53	SMITH	CLERK	CLERK	1300	0	0	54	WARD	SALES	SALES	1200	5	5		
55	WARD	SALES	SALES	1200	5	5	56	SCOTT	ANALYST	ANALYST	3000	14	14		
57	ADAMS	CLERK	CLERK	1100	0	0	58	JONES	MANAGER	MANAGER	2800	0	0		
59	SMITH	CLERK	CLERK	1300	0	0	60	WARD	SALES	SALES	1200	5	5		
61	WARD	SALES	SALES	1200	5	5	62	SCOTT	ANALYST	ANALYST	3000	14	14		
63	ADAMS	CLERK	CLERK	1100	0	0	64	JONES	MANAGER	MANAGER	2800	0	0		
65	SMITH	CLERK	CLERK	1300	0	0	66	WARD	SALES	SALES	1200	5	5		
67	WARD	SALES	SALES	1200	5	5	68	SCOTT	ANALYST	ANALYST	3000	14	14		
69	ADAMS	CLERK	CLERK	1100	0	0	70	JONES	MANAGER	MANAGER	2800	0	0		
71	SMITH	CLERK	CLERK	1300	0	0	72	WARD	SALES	SALES	1200	5	5		
73	WARD	SALES	SALES	1200	5	5	74	SCOTT	ANALYST	ANALYST	3000	14	14		
75	ADAMS	CLERK	CLERK	1100	0	0	76	JONES	MANAGER	MANAGER	2800	0	0		
77	SMITH	CLERK	CLERK	1300	0	0	78	WARD	SALES	SALES	1200	5	5		
79	WARD	SALES	SALES	1200	5	5	80	SCOTT	ANALYST	ANALYST	3000	14	14		
81	ADAMS	CLERK	CLERK	1100	0	0	82	JONES	MANAGER	MANAGER	2800	0	0		
83	SMITH	CLERK	CLERK	1300	0	0	84	WARD	SALES	SALES	1200	5	5		
85	WARD	SALES	SALES	1200	5	5	86	SCOTT	ANALYST	ANALYST	3000	14	14		
87	ADAMS	CLERK	CLERK	1100	0	0	88	JONES	MANAGER	MANAGER	2800	0	0		
89	SMITH	CLERK	CLERK	1300	0	0	90	WARD	SALES	SALES	1200	5	5		
91	WARD	SALES	SALES	1200	5	5	92	SCOTT	ANALYST	ANALYST	3000	14	14		
93	ADAMS	CLERK	CLERK	1100	0	0	94	JONES	MANAGER	MANAGER	2800	0	0		
95	SMITH	CLERK	CLERK	1300	0	0	96	WARD	SALES	SALES	1200	5	5		
97	WARD	SALES	SALES	1200	5	5	98	SCOTT	ANALYST	ANALYST	3000	14	14		
99	ADAMS	CLERK	CLERK	1100	0	0	100	JONES	MANAGER	MANAGER	2800	0	0		

Figure 1. Summary of the study.

3.8 Treinamento do Sistema de eficiência energética

Como dito anteriormente, o sistema descrito neste trabalho tem o objetivo de diminuir o consumo de energia na residência com a menor perda possível no conforto, para isso como forma de treinamento, foi utilizada a técnica de Aprendizagem por Reforço lote (*Batch Reinforcement Learning - BRL*).

3.8.1 Aprendizagem por Reforço em Lote

Como dito no item 0, o aprendizado por reforço se baseia na experiência ou interação com o ambiente. Logo, a aplicação desse método em problemas reais pode, algumas vezes, ser inviável, como é o caso de uma residência, pois o agente não pode interagir com o ambiente para não afetar de forma significativa a qualidade de vida dos moradores. Sendo assim, são utilizadas algumas adaptações do aprendizado por reforço conhecido como aprendizado por reforço em lote (EPRLST; GEURT; WEHENKEL, 2005).

Para que se possa utilizar a técnica BRL (Algoritmo 1) no processo de aprendizagem, é fundamental a existência de um histórico ou banco de dados com valores de estados e ações tomadas ao longo de um período. Como o agente se utiliza desse histórico para realizar a aprendizagem, embora não interaja com o ambiente, e o conjunto de transições (Estados e Ações) é finito, não se pode esperar que se consiga encontrar uma política ótima. Dessa forma, o objetivo

não é mais aprender a política ótima, mas sim a melhor política possível com os dados fornecidos (LACERDA, 2013).

Algoritmo 1 – Aprendizagem por Reforço em Lote

```

Saída:  $Q$ 
 $Q \leftarrow Q_0$ 
while  $Q$  não converge do
     $D \leftarrow \{\}$ 
     $i \leftarrow 0$ 
    while  $experiencia < m$  do
         $i \leftarrow i + 1$ 
         $s_t \leftarrow estadoDoAmbiente()$ 
         $experiencia \leftarrow experiencia + 1$ 
         $a_t \leftarrow politicaAtual(Q, s_t)$ 
         $executaAcao(a_t)$ 
         $r_t \leftarrow recompensaDoAmbiente()$ 
         $s_{t+1} \leftarrow estadoDoAmbiente()$ 
         $d_t \leftarrow (s_t, a_t, r_t, s_{t+1})$ 
         $D \leftarrow D \cup \{d_t\}$ 
    end
     $D \leftarrow treinaLote(D)$ 
end

```

Fonte: Ernst, Geurts e Weisbankel (2005)

3.8.2 Fitted Q Iteration

O algoritmo *Fitted Q Iteration*, desenvolvido por Ernst (2005), é provavelmente o mais conhecido quando se fala em aprendizagem por reforço em lote e tem sua implementação feita conforme o Algoritmo 2.

Algoritmo 2 – Fitted Q Iteration

```

Saída:  $Q$ 
 $i \leftarrow 0$ 
while  $i < k$  do
    foreach  $t \in [1, \dots, |D|]$  do
         $T_t \leftarrow r_t + \gamma \max_a Q_{i-1}(s_{t-1}, a)$ 
    end
     $Q_i \leftarrow Q_{i-1}$ 
    foreach  $iteracao = 1:nk$  do
        foreach  $t \in [1, \dots, |D|]$  do
             $Q_i(s_t, a_t) \leftarrow Q_i(s_t, a_t) + \alpha_{\text{aprendizado}}(T_t - Q_i(s_t, a_t))$ 
        end
    end
end
end

```

Fonte: Ernst (2005)

3.8.3 Aplicação do BRL no Sistema AutoDomo

A estrutura de treinamento foi baseada em três etapas (Figura 18), conforme a lista abaixo:

- Aquisição de Dados

Todos os dados do sistema AutoDomo já são por padrão armazenados em nuvem utilizando um banco de dados NoSQL *Real-Time Database* da Google.


- Treinamento

O treinamento foi todo realizado em linguagem Python; utilizando a plataforma *Google Colab*, e que facilita a comunicação com os dados armazenados no *Real-Time Database* da Google.

- Operação

A operação pode ser realizada em qualquer sistema que utilize o MQTT como protocolo de comunicação entre os dispositivos, todavia, neste trabalho os testes foram feitos utilizando o Sistema AutoDomo.

Figura 18 – Estrutura do Sistema de Gerenciamento de Energia



Fonte: Autor (2022)

3.8.4 Identificado os Estados (Classes) e Ações

Para resolver um problema com esse nível de dificuldade, é importante identificar as variáveis de estados que, de fato, podem interferir no processo. Caso contrário, nunca será possível convergir a uma solução (política) aceitável. Dentro do banco de dados do sistema AutoDomo (*Real-Time database*) existe uma quantidade de aproximadamente 25 variáveis; porém, foram separadas as variáveis que de fato podem influenciar no processo. Entre elas:

- Id do Ambiente

Essa variável armazena um valor que corresponde a cada ambiente da residência. Essa variável tem a sua importância no treinamento, pois, a utilização de determinado dispositivo na

residência depende também de onde está localizado:

- **Pduração**

A variável **Pduração** armazena por quanto tempo a lâmpada ficou ligada durante o dia. É importante informar que esse valor foi normalizado entre 0 e 1 a partir da duração do dia em segundos:

- **Hora**

Armazena a hora em que o dispositivo foi acionado.


- **Dia da Semana**

Armazena o dia da semana em que o dispositivo foi acionado, onde 0 é domingo e 6 é segunda-feira.

3.8.5 Treinamento

A arquitetura da RNA do Sistema Integrado de Gerenciamento de Energia (SIGEAD) é apresentada na Figura 19, no qual se pode observar que é constituída da seguinte forma: a camada de entrada com 10 neurônios, 4 camadas internas e 1 camada de saída com 2 neurônios.

Figura 19 – Topologia da Rede Neural.



Fonte: Autor (2022)

O algoritmo do SIGEAD, foi dividido em quatro partes para melhor entendimento de seu funcionamento na plataforma *Google Colaboratory*. Na Figura 20 apresenta-se a parte 1 do Algoritmo SIGEAD. Nesta, define-se os parâmetros iniciais da classe construtora da RNA associados com equação de Bellman (Equação 1).

$$V(x) = \max_a (R(x, a) + \gamma V(x')) \quad (1)$$

- Na Linha 1, a variável *max_size* representa a quantidade de estados vindo do ambiente (residência a ser controlada);
- Na linha 2, a variável *action_space* é a quantidade de ações (ação da RNA) Ligar/Desligar dispositivos;

- Na Linha 4, a variável *gamma* equivale a o parâmetro γ da equação de Bellman;
- Nas linhas 6, 7 e 8 temos os valores de *epsilon* que são os parâmetros para definir a probabilidade de uma ação ser aleatória ou executada pela RNA.

No início do treinamento, tem-se o valor de *epsilon* = 1 (100%) pois, a ação executada pelo agente é aleatória, tendo em vista, que os pesos ainda não foram treinados o suficiente para tomar as devidas ações. Porém, com o avanço do treinamento o *epsilon* pode decair até 0,01 (1%). Dessa forma, existe uma probabilidade de 99% da ação ser executada com a saída da RNA e pode-se observar que, mesmo após uma RNA treinada, existe uma possibilidade mínima de executar uma ação aleatória não prevista. Isto tem a importância de evitar que o agente fique preso em um mínimo local.

Figura 20 - Parte 1 do Algoritmo SIGEAD

```

1  self.state_size = state_size
2  self.action_space = action_space
3  self.model_name = model_name
4  self.gamma = 0.96
5  self.epsilon = 1.0
6  self.epsilon_final = 0.01
7  self.epsilon_decay = 0.995
8  self.model = self.model_builder()
```

Fonte: Autor (2022)

Na Figura 21, apresenta-se a parte 2 do Algoritmo SIGEAD em que é definida a função *model_builder*, a qual é responsável por construir a rede neural da Figura 19. Para isso foi utilizado a biblioteca *TensorFlow*.

Figura 21 – Parte 2 do Algoritmo SGEAD

```

1 def model_builder(self):
2     model = tf.keras.models.Sequential()
3     model.add(tf.keras.layers.Input(shape=(self.state_size,)))
4     model.add(tf.keras.layers.Dense(units = 12, activation = 'relu'))
5     model.add(tf.keras.layers.Dense(units = 64, activation = 'relu'))
6     model.add(tf.keras.layers.Dense(units = 128, activation = 'relu'))
7     model.add(tf.keras.layers.Dense(units = self.action_space, activation = 'linear'))
8     model.compile(loss = 'mse', optimizer = tf.keras.optimizers.Adam(lr = 1e-3))
9     return model

```

Fonte: Astor (2022)

Na parte 3 do algoritmo, conforme Figura 22, é definida a função `action` na linha 1. Essa função recebe o parâmetro `state` (estados) vindo do ambiente e executa as ações a serem tomadas. Tais ações podem ser aleatórias ou definidas pela saída da rede neural, dependendo do valor de `epsilon` na linha 2, pois quanto menor o valor de `epsilon` maior a probabilidade de uma ação ser executada pela rede neural.

Figura 22 – Parte 3 do Algoritmo SGEAD

```

1 def action(self, state):
2     if random.random() <= self.epsilon:
3         return random.randrange(self.action_space)
4
5     actions = self.model.predict(state)
6     return np.argmax(actions[0])

```

Fonte: Astor (2022)

Por fim, na Figura 23, mostra-se a execução da função `treinamentoLote()`, que recebe um lote de dados vindo do banco de dados Firebase para realizar o treinamento da RNA. Essa função percorre todo o banco de dados buscando todos os estados para o treinamento.

Figura 23 - Parte 4 do Algoritmo STOEAD

```

1 def reinicializa lote(self, tamanhoLote):
2     lote = []
3     for i in range(len(self.memory) - tamanhoLote + 1, len(self.memory)):
4         lote.append(self.memory[i])
5
6     for state, action, reward, next_state, done in lote:
7         if not done:
8             reward = reward + self.gamma * np.max(self.model.predict(next_state)[0])
9
10        target = self.model.predict(state)
11        target[0][action] = reward
12
13        self.model.fit(state, target, epochs=1, verbose=0)
14
15    if self.epsilon > self.epsilon_final:
16        self.epsilon *= self.epsilon_decay

```

Fonte: Autor (2022).

4. Resultados Experimentais

No problema de busca por eficiência energética utiliza-se aprendizagem por reforço em lote, cujo objetivo final é a busca por uma política ótima π , que mapeia as melhores ações de desligamento dos dispositivos sem comprometer o conforto dos moradores da residência, gerando oportunidade de economia de energia por meio da redução do consumo de *grid*. Nesse estudo de caso, foi considerada uma residência localizada em São Luís no Estado do Maranhão, Brasil. A residência é completamente automatizada pelo sistema AutoDomo, porém para efeito de comparação foram utilizados os dispositivos gerenciados pelo SIGEAD, com os dispositivos indicados na Tabela 2.


Tabela 2 – Dispositivos Gerenciado pelo SIGEAD

Item	Descrição	Quantidade
1	Lustre	4
2	Lâmpadas	32
3	Chuveiro Elétricos	5
4	Tupa	10
5	Bomba Piscina	1
6	Bomba de Água	1
7	Aquecedor	1

Fonte: Autor (2022)

Após o treinamento do agente utilizando o dados histórico da residência, conforme descrito no item 3.8.5, o SIGEAD foi finalmente acoplado a automação residencial da casa em outubro de 2021, porém com a habilidade apenas de monitoramento, pois o mesmo não tinha a capacidade de desligamento dos dispositivos. Após um mês de atuação foi verificado, conforme mostrado na Figura 14, que a residência teria uma redução estimada de 3,19% em comparação com os dados reais no mês de outubro de 2021.

Figura 24 – Consumo Estimado e Consumo Real (outubro)




Fonte: Autor (2021).

A partir dos resultados do SIGEAD do mês de outubro o sistema foi avaliado e iniciado o processo para controle da residência em novembro de 2021, com a possibilidade de controle total dos dispositivos. Assim, o sistema de automação SIGEAD passou a ser um agente ativo, responsável em desligar os equipamentos elétricos mencionado na Tabela 2, com a finalidade de redução do consumo de energia.

Como forma de validação do desempenho do sistema foi realizada uma comparação do consumo de energia elétrica da residência nos meses de novembro e dezembro de 2020 em relação aos meses de novembro e dezembro de 2021. Os dados históricos de consumo dos meses de 2020 foram todos retirados do banco de dados do sistema Autodomo e autorizado pelo proprietário da residência para a utilização na comparação apresentada na Figura 25. Conforme observado em novembro de 2020, o consumo de energia elétrica foi de 3761 kWh e em novembro de 2021, o consumo foi de 3592 kWh, obtendo-se uma redução de 4,52%, conforme Figura 25.


Figura 25 – Consumo de novembro 2021 x novembro 2022



Fonte: Autor (2022)

Na Figura 26 é observado o consumo de energia elétrica em dezembro de 2021, que foi de 3694 kWh e em dezembro de 2022, o consumo foi de 3502 kWh, reduzindo-se assim o consumo em 5,19% com o SIGEAD.

Figura 26 – Consumo de dezembro 2021 x dezembro 2022



Fonte: Autor (2022)

Como é possível verificar nos resultados mostrados nas Figuras 25 e 26, houve uma redução importante no consumo de energia elétrica durante todos os meses que o sistema permaneceu ativo, e como parte da análise verificou-se de forma qualitativa (Quadro 5) que não houve reclamação por parte dos usuários durante as intervenções automáticas do sistema na

residência, ou seja, os moradores da residência em estudo foram pouco afetados por desligamentos indevidos do SIGEAD, ou seja, por erros de operação do sistema.

Quadro 3 – Questionário Qualitativo

Questionário	Moradores=Funcionários					
	1	2	3	4	5	6
Algum Dispositivo desliga sem comando direto?	Sim	Não	Não	Não	Sim	Sim
Você teve que religar algum dispositivo?	Sim	Não	Não	Não	Não	Sim
Você percebeu diferença na automação residencial?	Não	Não	Não	Não	Não	Não
Você se sente desconfortável com o sistema?	Não	Não	Não	Não	Não	Não

Fonte: Autor (2022)

5. Considerações Finais

Nesta Dissertação desenvolveu-se uma rede neural utilizando a técnica de aprendizagem por reforço em lote, baseado em Lacerda (2013) com a finalidade de redução do consumo de energia elétrica de uma residência com automação pré-existente. O SIGEAD se demonstrou eficiente na redução do consumo elétrico diminuindo em média 4,86% com um impacto mínimo no conforto dos moradores.

A redução de energia foi obtida sem a necessidade de nenhuma instalação de componentes (sensores, atuadores) extras, trabalhando apenas com a automação previamente instalada na residência. Todavia, se faz necessário que o sistema existente tenha um histórico com todos os dados de utilização e rotina da casa, por exemplo:

- Tipo de Dispositivo (exemplo: lâmpada, ar-condicionado, ventilador, televisão etc.);
- Hora de atuação do dispositivo;
- Usuário que atou o dispositivo;
- Ambiente em que o dispositivo está instalado (Exemplo, Sala, Cozinha, quarto etc.);
- Potência dos equipamentos.

Desta forma, o sistema proposto pode ser treinado em qualquer residência automatizada e pode ser desligado facilmente em caso de atuação indevida que venha a causar algum desconforto aos moradores.

5.1. Trabalhos Futuros

O uso de redes neurais IoT em residências inteligentes possui diversas oportunidades, como trabalhos futuros se pode indicar as seguintes aplicações:

- Aperfeiçoamento da rede neural com a finalidade de controles de cargas que não seja simplesmente liga e desliga, como dimensinadores de luz e controle de temperaturas;
- Monitoramento dos valores de tensão elétrica e corrente elétrica, com a finalidade de gerenciamento dos risco de acidentes causado por sobrecargas nos circuitos residenciais;
- Acompanhamento da vida útil dos equipamentos elétricos para avaliação e prevenção de desgastes e possível antecipação de falhas (manutenção do preditiva) com base nas assinaturas elétricas dos equipamentos; e

- A indicação de possível desvio na rotina dos moradores da residência, como forma de indicação de possíveis eventos de segurança.

5.2. Produção bibliográfica

1. SILVA, E. S.; PINTO, M. S. S.; Moura, José Pinheiro; SILVA JUNIOR, P. F. Sistema Inteligente para o Controle de Dispositivos Elétricos Eletrônico e Consumo de Energia Elétrica em Residência de Alto Padrão In: Simpósio Brasileiro de Sistemas Elétricos (SBSSE 2022), 2022, Santa Maria. Simpósio Brasileiro de Sistemas Elétricos (SBSSE 2022).
2. Certificado de Registro de Programa de Computador, Junto ao Instituto nacional de propriedade Industrial. Processo N°. BR512022002987-1. Título: Sistema de Inteligente de Energia AutoDomo SIGEAD. Campo de aplicação: EN-01; EN-04; EN-05; IN-01.

Referências Bibliográficas

- ALIGER. Entenda o aprendizado não supervisionado no Machine Learning. *Aliger [online]*, 30 jul. 2019. Disponível em: <https://aliger.com.br/blog/entenda-o-aprendizado-nao-supervisionado-no-machine-learning/>. Acesso em: 25 nov. 2021.
- AMARAL, H. L. M. D. Desenvolvimento de uma nova metodologia para previsão do consumo de energia elétrica de curto prazo utilizando redes neurais artificiais e decomposição de séries temporais. 2019. 113f. Tese (Doutorado em Sistemas de Potência) - Escola Politécnica, Universidade de São Paulo, São Paulo, 2019. Disponível em: <https://teses.usp.br/teses-disponiveis/3/3143-tde-07022020-115308-publico/HaroldoLmzMosetidoAmaralCorr20.pdf>. Acesso em: 13 nov. 2021.
- AMORIM, T. Conceitos, técnicas, ferramentas e aplicações de Mineração de Dados para gerar conhecimento a partir de bases de dados. 2006. 30f. Monografia (Graduação - Ciência da Computação). Universidade Federal de Pernambuco, Recife, 2006. Disponível em: <http://www.cin.ufpe.br/~tg/2006-2/tmas.pdf>. Acesso em: 20 jul. 2021.
- ASHTON, K. Entrevista exclusiva com o criador do termo "Internet das Coisas". *Finap [online]*, 13 Jan. 2015. Disponível em: <http://finap.gov.br/noticias/todas-noticias/4446-kevin-ashton-entrevista-exclusiva-com-o-criador-do-termo-internet-das-coisas>. Acesso em: 12 out. 2021.
- AURESIDE. Automação Residencial: demanda na Construção Civil. *Aureside [online]*, 2020. Disponível em: <http://www.aureside.org.br/noticias/automacao-residencial-demanda-na-construcao-civil>. Acesso em: out. 2021.
- BERLING, H.; KAGAN, N.; COSTA, A. H. R. Intelligent Decision-Making for Smart Home Energy Management. *Journal of Intelligent & Robotic Systems*, v. 1, p. 331-354, 2015.
- BRUMATTI, M. Redes Neurais Artificiais. Departamento de Engenharia Elétrica - Universidade Federal do Espírito Santo, Vitória, UFES, 2005.
- COLOMBO, J. F.; LUCCA FILHO, J. de. Internet das Coisas (IoT) e Indústria 4.0: revolucionando o mundo dos negócios. *Revista Interface Tecnológica*, [S. l.], v. 15, n. 2, p. 72-85, 2018. DOI: 10.31518/rifa.v15i2.496. Disponível em: <https://revista.fatectq.edu.br/interfacetecnologica/article/view/496>. Acesso em: 10 out. 2021.
- CPFL Energia. Tarifa Branca. *CPFL [online]*, 2020. Disponível em: <https://www.cpfl.com.br/tarifa-branca>. Acesso em: out. 2020.
- DATA SCIENCE ACADEMY. Deep Learning Book. 2021. Disponível em: <https://www.deeplearningbook.com.br>. Acesso em: 12 out. 2021.
- ENERGETICA, E. D. P. Anuário Estatístico de Energia Elétrica 2021. Brasília, 2021.
- ERNST, D.; GELRTS, P.; WEHENKEL, L. Tree-based batch mode reinforcement learning. *Journal of Machine Learning research*. Liège, [s.n.], 2005.
- ERNST, G. E. W. Tree-based batch mode reinforcement learning. *Journal of Machine Learning Research*. [S.l.]: [s.n.], 2005.

FELICIANO, R. Alimentação de dispositivos IoT na indústria, 2021. Disponível em: <https://venturus.org.br/alimentacao-de-dispositivos-iot-na-industria>. Acesso em: 2021.

GARG, N.; GARG, R. Energy harvesting in iot devices. *International Conference on Intelligent Sustainable Systems (ICISS)*. Palladam, Índia: [s.n.], 07 ago. 2017.

GOLDEMBERG, J.; LUCON, O. Energia e meio ambiente no Brasil. *Estudos Avançados [online]*, v. 21, n. 59 p. 7-20. 2007. Disponível em: [https://www.scielo.br/ea/a4k9tsKdqdK8y3CzMH3\\$V9bw/abstract?lang=pt&Modal=Articles](https://www.scielo.br/ea/a4k9tsKdqdK8y3CzMH3$V9bw/abstract?lang=pt&Modal=Articles). Acesso em: 10 out. 2021.

HAYKIN, S. *Redes Neurais: Princípios e Práticas*. Porto Alegre: Bookman, 2007.

HONDA, F.; FACURE, M.; YAOHAO, P. Os Três Tipos de Aprendizado de Máquina. Laboratório de Aprendizado de Máquina em Finanças e Organizações (LAMFO), Universidade de Brasília [online]. 27 jul. 2017. Disponível em: <https://lamfo-ufb.github.io/2017-07/27-tres-tipos-axx>. Acesso em: 02 out. 2021.

IBM. Getting to know MQTT. Why MQTT is one of the best network protocols for the Internet of Things. IBM [online]. 9 dez. 2021. 2021. Disponível em: <https://developer.ibm.com/articles/iot-mqtt-why-good-for-iot/>. Acesso em: 10 out. 2021.

JUNIPER RESEARCH. IOT connections to reach 83 billion by 2024, driven by maturing industrial use cases, Juniper Research [online]. 31 mar. 2020. Disponível em: <https://www.juniperresearch.com/press/iot-connections-to-reach-83-bn-by-2024>. Acesso em: 12 out. 2021.

JUNIPER RESEARCH. IOT connections to reach 83 billion by 2024, driven by maturing industrial use cases, Juniper Research [online]. 2020. Disponível em: <https://www.juniperresearch.com/press/iot-connections-to-reach-83-bn-by-2024>. Acesso em: 10 out. 2021.

LACERDA, Dania Antonio. *Aprendizado por reforço em Iota: um estudo de caso para o problema de tomada de decisão em processos de venda*. 2013. Dissertação (Mestrado) – Universidade de São Paulo, São Paulo, 2013. Disponível em: http://www.teses.usp.br/teses-disponiveis/45/45134_tde-03072014-101251. Acesso em: 14 dez. 2021.

LOGENTHIRAN, T.; PHAN, V.-T.; WOO, W. L. Implemented IoT-Based Self-Learning Home Management System (SHMS) for Singapore. *IEEE Internet of Things Journal*, v. 5, n. 3, p. 2212-2219, 2018.

MACHORRO-CANO, I. E. EMS-IoT: A Big Data and Machine Learning-Based Smart Home System for Energy Saving. *Energies*, n.13, v. 5, P. 1097, 2020. Disponível em: <https://www.mdpi.com/1996-1073/13/5/1097>. Acesso em: 14 dez. 2021.

MARCICANO, J. P. Qual é a diferença entre economia de energia e eficiência energética? *Energia Arion [online]*. 14 out. 2021. Disponível em: <https://energiaarion.com.br/2019/12/17/economia-de-energia-e-eficiencia-energetica/>. Acesso em: 17 dez. 2019.

MUNIZ, A. H. et al. Estudo de caso transição do protocolo IPv4 para IPv6. *Revista Gestão em Foco*, n. 9, p. 539 - 541, 2017. Disponível em: https://portal.unisepe.com.br/unifia/wp-content/uploads/sites/10001/2018/06/055_estudo8.pdf. Acesso em: 25 nov. 2021.

OLIVEIRA, T. de A. Redes dinâmicas de sensores sem fio ZigBee para aplicações de monitoramento e controle. 2015. 115 f. Dissertação (mestrado) - Universidade Estadual Paulista Júlio de Mesquita Filho, Faculdade de Engenharia, 2015. Disponível em: <https://repositorio.unesp.br/bitstream/handle/11449/135996/0/0358611.pdf?sequence=1&isAllowed=y>. Acesso em: 12 out. 2021.

PEDRO, B. L. Sistema de Domótica para Melhoria da Eficiência Energética em Edifícios. 2021. 132f. Dissertação (Mestrado em Engenharia Eletrotécnica), Instituto Superior de Engenharia de Lisboa, 2021. Disponível em: <https://repositorio.isel.pt/handle/10400.21/13812>. Acesso em: 12 out. 2021.

REDDY, M. R. V.; RABBANI, M. T. A.; OO, A. M. Iot for energy efficiency and demand management. 29th Australasian Universities Power Engineering Conference (AUPEC), Australia, p. 1-6, 2019. Disponível em: <https://ieeexplore.ieee.org/document/9084520/citations?tabFilter=papers#citations>. Acesso em: 12 out. 2021.

SALAT, M. O lado escuro dos dispositivos IoT. *Avant [online]*, 16 out. 2017. Disponível em: <https://blog.rv-st.com/the-dark-side-of-iot-devices>. Acesso em: 30 out. 2021.

UFRJ: Bluetooth Low Energy, *UFRJ [online]*, 2017. Disponível em: <https://www.gta.ufrj.br/ensino/eel879/trabalhos/20122/bluetooth/ble.htm>. Acesso em: 2017.

UFRJ: Protocolo Zigbee, *UFRJ [online]*, 2017. Disponível em: <https://www.gta.ufrj.br/ensino/eel879/trabalhos>. Acesso em: 10 out. 2021.