



Grupo de Estudo de Sistemas de Informação e Telecomunicação para Sistemas Elétricos-GTL

Sistema Inteligente de Resposta à Demanda integrado à Microgeração e Armazenamento de Energia utilizando conceitos de Internet of Things

ALISSON TRINDADE SOUZA(1)*; LUCIANE NEVES CANHA(1); RAFAEL GRESSLER MILBRADT(1); CÁSSIO MICHELS TEIXEIRA(1); CHRISTIAN LEMOS(1); TIAGO AUGUSTO SILVA SANTANA(2); UFSM(1); COPEL DIS(2);

RESUMO

Em *Smart Grids*, o uso de casas inteligentes para gerenciamento de cargas residenciais e ações de resposta da demanda de maneira inteligente deve ser uma alternativa pelo lado do consumidor. O presente trabalho apresenta um sistema de gerenciamento inteligente de cargas residenciais e resposta da demanda. O sistema é adaptável à tarifação variável e sistema de microgeração distribuída. Emprega técnicas de Inteligência Artificial e tecnologias de Internet das Coisas. No processo de tomada de decisão são utilizados dados ambientais monitorados, geração de energia e instruções do sistema de gerenciamento de baterias, parte do projeto de P&D COPEL Distribuição e UFSM.

PALAVRAS-CHAVE

Casas Inteligentes, Internet das Coisas, Inteligência Artificial, Resposta da demanda, Sistema de Gerenciamento Inteligente

1.0 - INTRODUÇÃO

2.0 - Nas *Smart Grids*, o papel do usuário residencial torna-se muito mais importante, e o emprego de *Smart Homes* (Casas Inteligentes) pode auxiliar no funcionamento do sistema de distribuição, principalmente com a utilização de sistemas inteligentes que trabalhem com ações de resposta da demanda de forma automática. Com o fluxo de energia e principalmente de informações de forma bidirecional, o desenvolvimento de sistemas residenciais inteligentes que trabalhem em conjunto com a concessionária de distribuição se tornará de fundamental importância.

Com a tecnologia envolvida em ambiente *Smart Grid*, concessionárias de distribuição poderão ter o melhor conhecimento de seus consumidores e poderão trabalhar em conjunto para o gerenciamento do sistema elétrico. A partir do emprego de *Smart Homes*, a energia gerada por usuários proconsumidores (produtor e consumidor de energia elétrica) e injetada na rede poderá ter supervisão da concessionária. Além disso, a partir deste fluxo bidirecional de informações, *Smart Homes* poderão verificar o estado atual do sistema, e ações em cargas residenciais poderão ser realizadas.

Ações de resposta da demanda podem ser entendidas como alterações intencionais na curva de carga, efetuadas direta ou indiretamente pelo consumidor, as quais se destinam a modificar o horário e/ou o nível da demanda instantânea, ou ainda o consumo total de energia elétrica [1]. Com isso, é possível a diminuição do valor gasto com energia elétrica e auxilia a distribuidora de energia elétrica em determinados cenários. Um exemplo de programa de resposta da demanda é a tarifação em tempo real (RTP).

A *Smart Home* utiliza conceitos de automação residencial e *Internet of Things* (IoT), *Internet* das coisas. A instalação de automação residencial permite melhorar o conforto e a segurança de uma casa através da

(*) Av. Roraima, nº 1000, Campus UFSM, Prédio 7 – CEP 97105-900, Santa Maria, RS – Brasil
Tel: (+55 55) 98438-7664 – Email: alissonts2010@hotmail.com

integração dos conceitos tradicionalmente associados ao ambiente doméstico com tecnologias de nova geração [2]. A IoT pode ser entendida em um conceito geral de coisas que são legíveis, reconhecíveis, localizáveis, endereçáveis e controláveis pela *Internet* - seja via radiofrequência (RF), redes locais sem fio, redes de longa distância ou outros meios [3].

O presente trabalho busca apresentar um sistema de gerenciamento de cargas residenciais com base no comportamento dos usuários, variáveis climáticas e possibilidade de integração com geração distribuída e *Smart Grid*. É chamado de Sistema Inteligente de Gerenciamento de Cargas Residenciais (SIGCR) e possui foco em ares-condicionados, carga de grande importância na residência.

O sistema emprega técnicas de inteligência artificial para tomada de decisões em cada carga automatizada. O monitoramento de diversos dados são utilizados para a tomada de decisão. No gerenciamento de temperatura, o comportamento dos residentes na modificação de parâmetros dos ares-condicionados é utilizado para previsão de temperatura. Além disso, o sistema possui um módulo propositivo que busca fazer tentativas de colocar a temperatura de ares-condicionados o mais próximo de uma faixa de operação de 22°C a 24°C, recomendadas em ambientes internos.

A geração de energia a partir do sistema fotovoltaico e a opinião do sistema inteligente de armazenamento de energia elétrica em baterias (*Battery Energy Storage Systems* - BESS) são utilizadas no processo de tomada de decisão em ares-condicionados e iluminação. Ao consultar o BESS, o SIGCR recebe como resposta a possibilidade ou não de utilizar a energia armazenada em bateria. Com estes dados, além do consumo de energia e a tarifação atual, o sistema pode realizar ações de resposta da demanda de forma automática, sem que haja grande interferência dos residentes.

Os resultados apresentados neste trabalho são parte de um projeto em desenvolvimento entre COPEL Distribuição (PD 2866-0462 / 2016) e a Universidade Federal de Santa Maria (UFSM), controlado pela Agência Nacional de Energia Elétrica (ANEEL)- P&D estratégico para o Setor Elétrico Brasileiro -P021/2016. Este estudo também é financiado em parte pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES/PROEX) – Código de financiamento 001.

3.0 - SISTEMA INTELIGENTE DE GERENCIAMENTO DE CARGAS RESIDENCIAIS (SIGCR)

3.1 Recursos do Sistema

O Sistema Inteligente de Gerenciamento de Cargas Residenciais (SIGCR) é um sistema de gerenciamento de cargas residenciais, com foco no gerenciamento de ares-condicionados, e com possibilidade de inserção em ambiente *Smart Grid*. Além do gerenciamento de temperatura, é gerenciada a iluminação do ambiente. Para a possibilidade de inserção em ambiente *Smart Grid*, o sistema é integrado com: *Smart Meter* (Medidor Inteligente), sistema fotovoltaico e sistema de gerenciamento inteligente de armazenamento de energia em bateria (BESS) instalado.

O sistema foi dividido em três elementos: Unidade de Controle e Monitoramento Residencial (UCMR), Dispositivos de Monitoramento (DM) e Dispositivos de Atuação (DA) e é representado na Figura 1, a seguir.

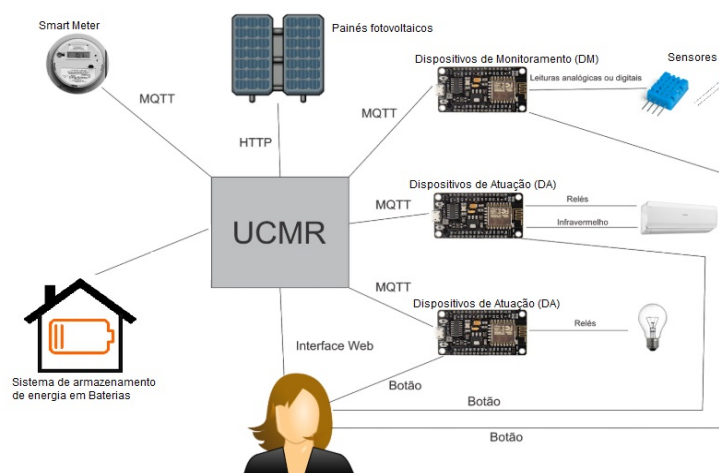


FIGURA 1 – Sistema Inteligente de Gerenciamento de Cargas Residenciais – Representação dos envolvidos no sistema

A UCMR recebe, armazena e processa dados dos dispositivos de monitoramento, do sistema de geração de energia elétrica, *Smart Meter* e do sistema de gerenciamento do BESS. Com os dados armazenados, a partir de técnicas de inteligência artificial a UCMR cria tomadas de decisão de controle inteligentes e envia para os dispositivos de atuação responsáveis por atuar em cada carga.

3.2

3.3 Dispositivos de monitoramento e atuação

O SIGCR possui dois tipos de dispositivos distribuídos nos diferentes cômodos de uma residência:

- a. Dispositivos de Monitoramento (MD): para monitoramento de ambiente residencial, tendo sensores conectados. Exemplo de dados monitorados: luminosidade; temperatura; umidade; ocorrência de presença de pessoas; estado e potência consumida de cargas.
- b. Dispositivos de Atuação (AD): presentes para a execução de comandos recebidos da UCMR, como ligar uma lâmpada ou mudar a temperatura do ar condicionado.

A comunicação entre os dispositivos de monitoramento e atuação e a UCMR é feita a partir da utilização do protocolo *Message Queue Telemetry Transport* (MQTT), de pequeno *payload*, apropriado para hardwares modestos, característicos de IoT. Foi buscado utilizar o protocolo MQTT em detrimento ao *HyperText Transfer Protocol* (HTTP) por conta deste um protocolo pesado com muitos cabeçalhos e regras, além de ser síncrono, diferentemente do protocolo MQTT. No protocolo HTTP, o cliente espera que o servidor responda, causando assim baixa escalabilidade, que pode ser problema em ambientes com grande número de dispositivos conectados. O MQTT é um protocolo assíncrono, muito mais adequado para aplicativos de IoT. [4]. Os sensores podem enviar leituras e permitir que a rede descubra o caminho e a sincronização ideais para entregar aos dispositivos e serviços de destino. Com a utilização do protocolo MQTT foi possível utilizar *hardware* de baixo custo com comunicação *wireless*, sem necessidade de cabeamento *ethernet*, flexíveis na colocação nos diferentes cômodos das residências.

3.4 Unidade de controle e monitoramento residencial (UCMR)

A Unidade de Controle e Monitoramento Residencial (UCMR) é o dispositivo principal do sistema, pois tem como funcionalidade principal tomar decisões inteligentes de controle de cargas de iluminação e de ares-condicionados.

Para o processo de tomada de decisão das cargas automatizadas, são utilizados dados de: Comportamento do usuário no controle de temperatura; Variáveis importantes como tarifa de energia elétrica, geração do sistema de microgeração distribuída e consumo da residência. Dados de monitoramento dos cômodos, como luminosidade, temperatura e presença de pessoas.

Dados de microgeração são coletados pela UCMR através do protocolo *HTTP*, utilizando a arquitetura de *software REST*. Para isso é necessário o cadastro do endereço do *webservice REST* do inversor utilizado diretamente na *interface* do sistema proposto. O *REST* foi apresentado por Roy Fielding [5], e define um modelo contendo um conjunto de restrições e propriedades baseadas no protocolo *HTTP*. É muito utilizado para comunicação entre aplicações.

A UCMR aplica as seguintes técnicas de Inteligência Artificial (IA): *Machine Learning* (ML) e Lógica *Fuzzy* para o gerenciamento de ares-condicionados; Lógica *Fuzzy* para o gerenciamento de cargas de iluminação. Para o ML utilizou-se a biblioteca *Sklearn* para o *Python* [6], enquanto que para a aplicação da Lógica *Fuzzy* foi utilizada a biblioteca *JFuzzy Logic* para o *Java* [7].

O *Machine Learning* pertence à área de AI, cujo objetivo é desenvolver métodos computacionais capazes de tomar decisões com base em conhecimentos já existentes [8]. No ML há a alteração de aspectos de comportamento do algoritmo à medida que a experiência é adquirida com o monitoramento de dados.

A Lógica *Fuzzy*, diferente da lógica Booleana que admite apenas valores booleanos, verdadeiro e falso, trata de valores que variam entre 0 e 1. Assim, uma pertinência entre 0.5 pode representar meio verdade, logo 0.9 e 0.1, representam quase verdade e quase falso, respectivamente [9]. Ou seja, é possível representar temperatura como “muito frio”, “frio”, “quente”, por exemplo, possibilitando o melhor tratamento de inconsistências nos dados. Além disso, permite a criação de regras a serem executadas sem nenhum tipo de treinamento, criadas com base em conhecimento de especialista no problema a ser resolvido.

A utilização de ML no gerenciamento de ares-condicionados tem como objetivo fazer o controle de temperatura de acordo com o comportamento dos usuários, ou seja, constantemente aprender a partir da utilização deste tipo de aparelho. Com o aprendizado, o sistema é capaz de comandar de forma semelhante aos usuários,

respeitando suas preferências. A utilização da Lógica *Fuzzy* em conjunto à ML no gerenciamento de ar-condicionados, e sozinha no gerenciamento de iluminação, ocorreu pela necessidade de buscar uma técnica que propicie a criação de modos de operação especialistas, apropriados aos cenários de variação na geração e armazenamento de energia elétrica, consumo e tarifação dinâmica. Com isso, é possível programar ações de resposta da demanda no sistema.

Dentro dos controladores *Fuzzy* utiliza-se como uma das entradas a decisão tomada pelo sistema de gerenciamento inteligente de baterias, desenvolvido em P&D de Projeto Estratégico ANEEL, que tem como finalidade buscar definir o momento de uso da energia gerada e o momento de realização do armazenamento de energia. A tomada de decisão ocorre com a utilização de variáveis em tempo real, tais como: nível de armazenamento da bateria, existência de geração de energia elétrica, custo cobrado pela energia elétrica no momento da análise e principalmente a resposta da demanda.

Os seguintes modos de operação foram desenvolvidos e disponibilizados para escolha do usuário na *interface*: Modo Conforto: não intrusivo, visto que não faz restrições de utilização de cargas residenciais; Modo Padrão: faz pequenas restrições na utilização de cargas em determinados cenários de tarifa e consumo acentuado, baixa geração, etc; Modo Econômico: modo de operação com maior intrusão do sistema em corte de carga, utilizado para usuários que desejam diminuição de utilização de energia oriunda da rede, mesmo em cenários de baixa geração de energia.

Dados atualizados e ações de controle estão disponíveis em tempo real na *interface Web*, tais como: consumo de energia elétrica; geração pelo sistema fotovoltaico (ver Figura 2) e nível de armazenamento de energia em um BESS; valor atualizado da tarifa cobrada pela concessionária de energia elétrica contratada; dados monitorados de cargas automatizadas.

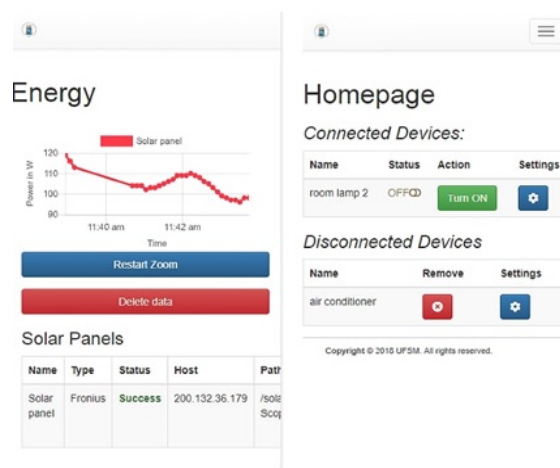


FIGURA 2 – *Interface* – Sistema

Para que o sistema desenvolvido possa atuar de forma adaptativa aos costumes dos usuários no gerenciamento de ar condicionado, os residentes precisam utilizar a *interface* na modificação de temperatura. Com isso, o sistema armazena as ações realizadas e utiliza estes registros no aprendizado de ML para predição de novas ações de forma automática.

3.4.1 Módulo de proposição de temperatura ao usuário residencial.

Para a melhor utilização do ar-condicionado, o sistema possui um módulo encarregado de tentar fazer com que o usuário residencial utilize temperaturas intermediárias. O ar-condicionado ao trabalhar com temperaturas como 17°C no verão e 27°C no inverno possui maior dificuldade de chegar na temperatura proposta, passando mais tempo ligado e conseqüentemente consumindo mais energia elétrica.

Segundo [10], a faixa recomendável de operação em condições internas para o verão, deve variar de 23°C a 26°C, enquanto que para condições internas para o inverno, a faixa recomendável de operação deve variar de 20°C a 22°C. Pensando nisso, o módulo propositivo desenvolvido trabalha com o objetivo de influenciar o hábito do usuário de forma não intrusiva, e para que isso ocorra o sistema faz tentativas de aumentar ou diminuir a temperatura do ar-condicionado controlado para uma faixa de operação de temperatura intermediária (22°C a 24°C).

O sistema analisa se a temperatura modificada foi aceita pelo usuário residencial, verificando se o mesmo alterou

a temperatura do ar condicionado no período de dez minutos após a ação tomada pelo módulo propositivo. O sistema espera pelo *Feedback* indireto do usuário residencial, ou seja, monitora se o aumento ou a diminuição de temperatura foi aceita com base na modificação de temperatura pelo usuário via *interface*. Em caso de não modificação, o sistema entende que a tentativa de colocação da temperatura o mais próximo de uma faixa de temperatura intermediária ocorreu com sucesso. As tentativas são realizadas aumentando ou diminuindo sempre 1°C, de forma não intrusiva e visando trabalhar junto ao comportamento do usuário armazenado e utilizado na predição de temperatura.

O sistema armazena a ação realizada e se houve sucesso ou falha na proposição. Junto ao comando realizado, são armazenados os dados de temperatura do exterior, temperatura do cômodo e umidade. Os dados armazenados são utilizados na aplicação do *Machine Learning* para predição de ações a serem realizadas no ar-condicionado de forma automática.

O módulo propositivo de temperatura pode fazer com que hábitos de usuários mudem ao longo do tempo, dependendo do perfil de utilização de ar-condicionado. Exemplo: No verão, o usuário passa a não utilizar o ar-condicionado na faixa de 18°C-19°C mas sim entre 23°C e 24°C.

3.4.2 Aplicação de *machine learning* na predição de temperatura.

Para detectar e entender o comportamento do usuário na atuação de ares-condicionados buscou-se utilizar métodos pertencentes de aprendizado de *Machine Learning*. Conforme [11] o aprendizado pode ser dividido em três categorias: aprendizado supervisionado, aprendizado não supervisionado e aprendizado semissupervisionado.

Como o sistema armazena ações de usuário diante do clima atual, é possível utilizar aprendizado supervisionado, visto é possível treinar o algoritmo com dados rotulados com conhecimento de uma saída correta. Após isso, o algoritmo é capaz de classificar exemplos não rotulados.

No aprendizado supervisionado, a tarefa de aprendizado pode ser de classificação ou regressão, de acordo com o tipo a qual pertence o atributo a ser predito. Segundo [12], quando o atributo classe (saída) assume um valor discreto, como, por exemplo, classe A, classe B, ou classe C, o problema é conhecido como problema de classificação, e neste caso o objetivo é classificar futuros casos em cada uma das classes pré-estabelecidas. Por outro lado, quando o atributo assume valores contínuos, como, por exemplo, o preço esperado de um produto de acordo com suas características, o problema é geralmente conhecido como problema de regressão, e o objetivo é prever o valor deste atributo com base nas características dos demais exemplos.

Pensando nestas características do aprendizado supervisionado, verificou-se a possibilidade de realizar a tarefa de aprendizado de classificação, e com isso foram montadas duas bases com dados para treinamento e teste de algoritmo, (leiaute da Tabela 1). Foram colocados dados de temperaturas gerais armazenadas durante o segundo semestre do ano de 2018, com utilização do ar condicionado pelo usuário neste período junto às ações realizadas pelo módulo propositivo.

TABELA 1 – Leiaute de conjunto de treino e teste

| Feedback do Usuário (Representação) | Ok | Not Ok | Atividade do Usuário | Temp. do Sensor (°C) | Umidade | Ocupação do cômodo | Temp. do Exterior (°C) | Temp. Set (°C) | Saída |
|-------------------------------------|----|--------|----------------------|----------------------|---------|--------------------|------------------------|----------------|----------|
| Not Ok | 0 | 1 | 0 | 20 | 83 | 1 | 21 | 23 | Manter |
| Ok | 1 | 0 | 0 | 18 | 80 | 0 | 20 | 24 | Desligar |
| Ok | 1 | 0 | 0 | 33 | 85 | 1 | 34 | 24 | Manter |
| Ok | 1 | 0 | 0 | 5 | 90 | 1 | 3 | 27 | Reduzir |
| Atividade do Usuário | 0 | 0 | 1 | 23 | 84 | 1 | 26 | 22 | Aumentar |

A coluna “Feedback do Usuário” possui variáveis categóricas, representadas por “Not Ok”, “Ok” e “Atividade do Usuário”. Os valores “Ok” e “Not Ok” são dados pelo sucesso ou insucesso da ação realizada pelo módulo propositivo de temperatura, enquanto que “Atividade do Usuário” representa as ações realizadas pelo usuário residencial diretamente na *interface*, ou seja, o hábito do usuário na carga presente. Para a utilização destas variáveis categóricas no treinamento e teste dos algoritmos escolhidos foi necessária a transformação em variáveis numéricas. De acordo com [13], se um coluna presente em um matriz tem k valores distintos, é necessário derivar em matriz com k colunas contendo todos 1’s e 0’s. Com isso, as colunas “Ok” e “Not Ok” e “Atividade do Usuário” foram colocadas para representação das variáveis tratadas, conhecidas como dummies.

As saídas “Aumentar”, “Desligar”, “Manter” e “Reduzir” foram escolhidas para predição, onde “Aumentar” “Manter” e “Diminuir” são saídas relacionadas à temperatura set (°C) colocada no ar condicionado.

3.4.3 Validação e testes de algoritmo de *machine learning* para predição de temperatura.

Para a escolha do algoritmo de *Machine Learning* para a predição de temperatura foi realizado dez testes de validação cruzada utilizando o *StratifiedKFold* do *Sklearn*, aplicando uma base de dados de treino. Em cada teste a base de dados é dividida em 10 partes (splits), onde partes da base de dados são utilizadas no treinamento e outra parte no teste dos algoritmos de classificação.

O *StratifiedKFold* fornece índices de treino/teste em uma base de dados para dividir os dados da mesma em conjuntos de treinamento/teste. As divisões são feitas preservando a porcentagem de amostras para cada classe presente na base de dados [14]. Com isso, o treinamento e teste sem disparidade de classes de saída, permitindo que o treinamento não fique ajustado em apenas determinada classe.

Cada teste se caracteriza pela mudança do atributo *random_state* (semente geradora aleatória) do *StratifiedKFold*, com o incremento de 1 a 10 para separação dos dados para treino e teste. O resultado de cada incremento da semente geradora aleatória é a média da acurácia de 10 testes internos, visto que o número de divisões da base de dados foi definido como 10. Como cada teste de incremento da semente geradora possui 10 testes internos (nº de divisões), ao todo o processo contém 100 interações na base de dados escolhida. O resultado dos 10 testes de incremento da semente geradora é apresentado na Tabela 2.

TABELA 2 – *StratifiedKFold* em Algoritmos de Classificação – 10 Testes

| Testes (Random State) | <i>AdaBoost</i> | <i>Decision Tree</i> | <i>Gradient Boosting Classifier</i> | <i>LightGBM</i> | <i>NaiveBayes</i> | <i>SVM</i> | <i>Random Forrest</i> | <i>XGBoost</i> |
|--------------------------|-----------------|----------------------|-------------------------------------|-----------------|-------------------|---------------|-----------------------|----------------|
| 1 | 0,9000 | 0,9200 | 0,9350 | 0,9650 | 0,6850 | 0,8200 | 0,9350 | 0,9700 |
| 2 | 0,8850 | 0,9000 | 0,9450 | 0,9600 | 0,7050 | 0,8100 | 0,9100 | 0,9600 |
| 3 | 0,8900 | 0,8950 | 0,9400 | 0,9450 | 0,7050 | 0,8050 | 0,9300 | 0,9500 |
| 4 | 0,9150 | 0,9300 | 0,9400 | 0,9400 | 0,7100 | 0,8200 | 0,9400 | 0,9500 |
| 5 | 0,9200 | 0,9300 | 0,9400 | 0,9550 | 0,7150 | 0,8200 | 0,9300 | 0,9600 |
| 6 | 0,9050 | 0,9050 | 0,9250 | 0,9300 | 0,6950 | 0,7900 | 0,9050 | 0,9450 |
| 7 | 0,9100 | 0,9250 | 0,9350 | 0,9450 | 0,7050 | 0,8200 | 0,9500 | 0,9650 |
| 8 | 0,9050 | 0,9150 | 0,9250 | 0,9500 | 0,6950 | 0,8200 | 0,9200 | 0,9550 |
| 9 | 0,9050 | 0,9150 | 0,9450 | 0,9500 | 0,7100 | 0,8150 | 0,9400 | 0,9650 |
| 10 | 0,9000 | 0,9000 | 0,9350 | 0,9700 | 0,7050 | 0,8050 | 0,9150 | 0,9500 |
| Média da Acurácia | 0,9035 | 0,9135 | 0,9365 | 0,9510 | 0,7030 | 0,8125 | 0,9275 | 0,9570 |

Para a verificação do desempenho dos algoritmos utilizados nos testes foi feito o ranqueamento dos resultados obtidos na Tabela 2. O ranqueamento é feito com a função *RANK.AVG* do *Software Microsoft Office Excel* [15]. A função retorna a posição de um número em uma lista de números, ou seja, faz a comparação dos dados em cada linha e retorna a posição de cada um em um ranking. O ranqueamento é apresentado na Tabela 3.

TABELA 3 – Ranqueamento dos Algoritmos de Classificação – 10 Testes

| Testes (Random State) | <i>AdaBoost</i> | <i>Decision Tree</i> | <i>Gradient Boosting Classifier</i> | <i>LightGBM</i> | <i>NaiveBayes</i> | <i>SVM</i> | <i>Random Forrest</i> | <i>XGBoost</i> |
|-----------------------|-----------------|----------------------|-------------------------------------|-----------------|-------------------|------------|-----------------------|----------------|
| 1 | 6 | 5 | 3,5 | 2 | 8 | 7 | 3,5 | 1 |
| 2 | 6 | 5 | 3 | 1,5 | 8 | 7 | 4 | 1,5 |
| 3 | 6 | 5 | 3 | 2 | 8 | 7 | 4 | 1 |
| 4 | 6 | 5 | 3,5 | 2 | 8 | 7 | 3,5 | 1 |
| 5 | 6 | 4,5 | 3 | 2 | 8 | 7 | 4,5 | 1 |
| 6 | 5 | 5 | 3 | 2 | 8 | 7 | 5 | 1 |
| 7 | 6 | 5 | 4 | 3 | 8 | 7 | 2 | 1 |
| 8 | 6 | 5 | 3 | 2 | 8 | 7 | 4 | 1 |
| 9 | 6 | 5 | 3 | 2 | 8 | 7 | 4 | 1 |
| 10 | 5,5 | 5,5 | 3 | 1 | 8 | 7 | 4 | 2 |
| Média | 5,9 | 5,0 | 3,2 | 2,0 | 8,0 | 7,0 | 3,9 | 1,2 |

A partir do ranqueamento foi possível verificar que o *XGBoost*, o *LightGBM*, e o *Gradient Boosting Classifier* conseguiram ter desempenho melhor no processo de validação cruzada utilizando a base de treinamento. Com a realização do ranqueamento notou-se que algoritmos de ML que utilizam árvores tiveram melhor desempenho na predição de temperatura de acordo com dados de comportamento do usuário e do módulo positivo.

Após a validação, os três primeiros algoritmos do ranking foram escolhidos para o processo de treinamento com a base de temperaturas gerais (base de treino) e teste com uma base reduzida, com valores não vistos no treinamento. As métricas de qualidade para os três algoritmos escolhidos são apresentadas na Tabela 4 a seguir.

TABELA 4 – Métricas de qualidade para os três primeiros algoritmos – Base de treino e teste: “geral”

| Nome | Acurácia | Recall | F1 | Tempo Treinamento |
|----------------------|----------|---------|---------|-------------------|
| <i>XGBoost</i> | 0.92308 | 0.92309 | 0.92309 | 0.1316 |
| <i>LightGBM</i> | 0.94231 | 0.94231 | 0.94231 | 0.0429 |
| <i>GB Classifier</i> | 0.93269 | 0.93269 | 0.93269 | 0.1426 |

Com resultados muito parecidos para a aplicação, decidiu-se utilizar o *LightGBM* [16] com 94.23% de acurácia, como algoritmo de classificação no sistema por conta do tempo de treinamento ser menor, o que em bases com maior número de dados pode ser mais nítido. O *LightGBM* é um algoritmo de *gradient boosting* usa algoritmos de aprendizado baseados em árvore de decisão.

3.4.4 Controlador *fuzzy* – ares-condicionados

Em conjunto ao algoritmo de ML, foi desenvolvido um controlador *Fuzzy* com modos de operação diferentes, contendo regras especialistas para diferentes cenários de geração, consumo e tarifação de energia.

Como entrada do controlador *Fuzzy* está predição realizada pelo algoritmo ML de temperatura, além de: resposta de consulta ao sistema BESS sobre utilização de energia elétrica armazenada; presença de pessoas no cômodo do ar condicionado; consumo, geração e valor de tarifa atual; e a possibilidade de atuação do ar condicionado em caso de cômodo desocupado. A saída escolhida no controlador é o estado do ar condicionado controlado, onde: conectado (mantendo predição de temperatura pelo ML ser diferente de desligar), ou desligado para corte de carga.

Na Figura 3 são apresentadas as entradas e saídas em uma execução do controlador *Fuzzy* no modo padrão.

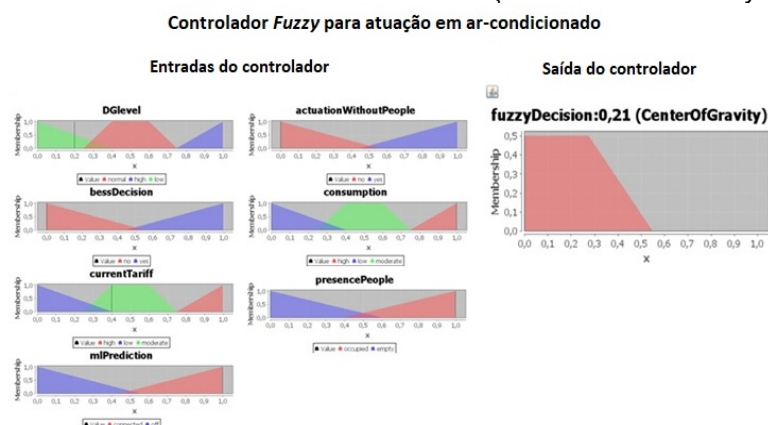


FIGURA 3 – Execução no controlador *Fuzzy* para ar condicionado - Entradas estabelecidas e Saída gerada

3.4.5 Gerenciamento de iluminação

Para o gerenciamento de iluminação residencial foi desenvolvido um controlador *Fuzzy* com modos de operação diferentes, contendo regras especialistas. A luminosidade do ambiente e o período do dia são entradas estabelecidas, assim como: a resposta de consulta ao sistema BESS sobre utilização de energia elétrica armazenada; presença de pessoas no cômodo do ar condicionado; consumo, geração e valor de tarifa atual. A saída escolhida no controlador é ligar ou desligar a iluminação a ser controlada. Na Figura 4 são apresentadas as entradas e saídas em uma simulação de execução do controlador *Fuzzy* no modo padrão.

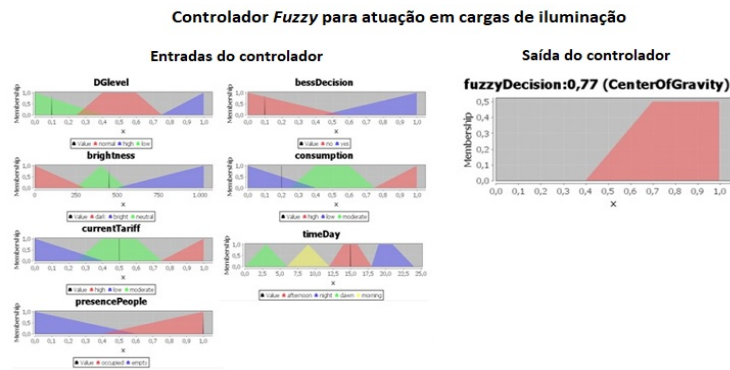


FIGURA 4 – Execução no controlador *Fuzzy* para iluminação - Entradas estabelecidas e Saída gerada.

4.0 - CONCLUSÃO

O sistema proposto trabalha com conceitos e tecnologias que tendem a serem importantes no desenvolvimento de casas inteligentes, de grande papel na arquitetura *Smart Grid*. A utilização de técnicas pertencentes à Inteligência Artificial, como *Machine Learning* e Lógica *Fuzzy* traz importantes benefícios em um cenário de comunicação bidirecional de informações entre consumidor e concessionárias de distribuição de energia elétrica. A crescente necessidade de conhecimento do sistema elétrico como um todo se faz necessário, com a busca por atuação inteligente em tempo real.

Na arquitetura *Smart Grid*, casas inteligentes serão mais comuns e terão maior papel no funcionamento do sistema. O maior conhecimento de seus consumidores pode fazer com que concessionárias de distribuição estabeleçam melhores investimentos em infraestrutura do sistema. A apresentação do sistema proposto visa apresentar a importância da Internet das Coisas e Inteligência Artificial no mercado elétrico e conduzir a novas possibilidades de geração, consumo e comercialização de energia no setor residencial.

5.0 - AGRADECIMENTOS

Os autores são gratos pelo suporte técnico e financeiro de Universidade Federal de Santa Maria, Santa Maria – RS, Brasil, Colégio Politécnico, ANEEL Chamado Estratégico P021/2016, COPEL- DIS (PD 2866-0462 / 2016), financiamento de CNPq PQ 1-D 310761/2018-2, CNPq processo 465640/2014-1, CAPES processo n°. 23038.000776/2017-54 e FAPERGS 17/2551-0000517-1, suporte de CNPq, Conselho Nacional de Desenvolvimento Científico e Tecnológico. Este estudo também foi financiado em parte pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES/PROEX) - Código de financiamento 001.

6.0 - REFERÊNCIAS BIBLIOGRÁFICAS

- (1) ALBADI, M. H.; EL-SAADANY, E. F. A Summary of Demand Response in Electricity Markets. *Electric Power Systems Research*, Lausanne, v. 78, n. 11, p. 1989–1996, May 2008.
- (2) SECHI, F.; FANUCCI, LUCA; LUSCHI, S; MADESANI, M.. Design of a Distributed Embedded System for Domotic Applications. *Digital System Design Architectures, Methods and Tools. DSD '08. 11th EUROMICRO Conference on* (2008).
- (3) Intelligence, S. C. B. National Intelligence Council: *Disruptive Technologies Global Trends 2025*. SRI Consulting Business Intelligence, Appendix F-2. (2008).
- (4) MQTT Home Page. Web site: <https://www.mqtt.org/>
- (5) Roy Thomas Fielding, “Architectural Styles and the Design of Networkbased Software Architectures,” Doctoral dissertation, 2000.
- (6) Scikit-Learn Home Page. Web site: <https://scikit-learn.org/stable/index.html>
- (7) JFuzzy Logic Home Page. Web site: <http://jfuzzylogic.sourceforge.net/html/index.html>
- (8) MICHALSKI, R. S.; CARBONELL, J. G.; MITCHELL, T. M. *Machine learning: An artificial intelligence approach*. [S.I.]: Springer Science and Business Media, 2013.

(9) SILVA, RENATO AFONSO COTA. Inteligência artificial aplicada à ambientes de Engenharia de Software: Uma visão geral. Universidade Federal de Viçosa, 2005.

(10) Agência Nacional de Vigilância Sanitária (ANVISA). RESOLUÇÃO-RE N° 09. Web site: http://portal.anvisa.gov.br/documents/10181/2718376/RE_09_2003_1.pdf/629ee4fe-177e-4a78-8709-533f78742798?version=1.0

(11) MONARD, M. C.; BARANAUSKAS, J. A. Conceitos sobre aprendizado de máquina. Sistemas Inteligentes-Fundamentos e Aplicações, v. 1, n. 1, 2003.

(12) PRATI, R. C. Novas abordagens em aprendizado de máquina para a geração de regras, classes desbalanceadas e ordenação de casos. Tese (Doutorado) — ICMC-USP, São Carlos, 2006.

(13) MCKINNEY, W. Python for Data Analysis. Pág 219. 2013.

(14) Scikit-Learn. `sklearn.model_selection.StratifiedKFold`. Web site: https://scikit-learn.org/stable/modules/generated/sklearn.model_selection.StratifiedKFold.html

(15) Microsoft. `RANK.AVG` function. Web site: <https://support.office.com/en-ie/article/rank-avg-function-bd406a6f-eb38-4d73-aa8e-6d1c3c72e83a>

(16) LightGBM's documentation. Web site: <https://lightgbm.readthedocs.io/en/latest/>

7.0 - DADOS BIOGRÁFICOS



Alisson Trindade Souza

Técnico em Eletrotécnica (Colégio Técnico Industrial de Santa Maria, 2013).

Tecnologia em Sistemas para Internet (UFSM, 2018).

Mestrando no Programa de Pós-Graduação em Engenharia Elétrica (2018-Atualmente).

Rafael Gressler Milbradt

Ciência da Computação (UFSM, 2004).

Mestrado em Programa de Pós-Graduação em Engenharia Elétrica (UFSM, 2007).

Doutorado em Engenharia Elétrica (UFSM, 2015).

Professor Adjunto da Universidade Federal de Santa Maria.

Luciane Neves Canha

Engenharia Elétrica (UFSM, 1994).

Mestrado em Engenharia Elétrica (UFSM, 1996).

Doutorado em Engenharia Elétrica (UFSM, 2004).

Professora Associada 3 da Universidade Federal de Santa Maria.

Pesquisadora PQ-1D do CNPQ.

Cássio Michels Teixeira

Aluno do Curso Superior de Tecnologia em Sistemas para Internet (2016-Atualmente).

Bolsista no projeto de pesquisa “Desenvolvimento de um protótipo de sistema de resposta da demanda integrado à geração fotovoltaica” - UFSM.

Christian Lemos

Aluno do Curso Superior de Tecnologia em Sistemas para Internet (2016-Atualmente).

Bolsista no projeto de pesquisa “Desenvolvimento de um protótipo de sistema de resposta da demanda integrado à geração fotovoltaica” - UFSM.

Tiago Augusto Silva Santana

Engenharia Elétrica (Universidade Estadual de Londrina, 2010).

Especialização em Engenharia de Confiabilidade Aplicada à Manutenção (Universidade Tecnológica Federal do Paraná, 2012).

Gerente - Superintendência de *Smart Grid* e Projetos Especiais - Companhia Paranaense de Energia (COPEL).