

Identificação de assinaturas de cargas de eletrodomésticos residenciais em Smart Meters usando Inteligência Artificial e IoT: Implementação e testbed

Thiago C. Sousa ¹, Artur F. S. Veloso ², Regenildo G. de Oliveira ³, Antônio A. Rodrigues ⁴, Davi L. de Oliveira ⁵, Altamir J Gallas ⁶, José V. V. Sobral ⁷.

Resumo

A identificação de eletrodomésticos individualmente na rede elétrica residencial pode prover um melhor controle do consumo e detecção de anomalias presentes em alguns desses eletrodomésticos. Essa identificação só é possível se cada eletrodoméstico tiver uma assinatura de cargas. A geração da assinatura de carga se dá através de aplicações como o medidor inteligente que fornece informações necessárias para este fim. O trabalho proposto permite a leitura e detecção de eletrodomésticos residenciais presentes na rede, através da assinatura de carga individual, utilizando medidores inteligentes juntamente com Inteligência Artificial. Alguns parâmetros elétricos importantes serão analisados e detectados de forma individual. Com auxílio dos algoritmos Árvore de Decisão e Naive Bayes, os dados da criação de assinatura de cargas são armazenados em um banco de dados e treinados para que a identificação seja possível. Contudo, é fornecido ao consumidor uma aplicação que permite identificar e classificar qualquer equipamento existente na residência quando estiver ativo, assim como anomalias e alterações presentes na rede residencial.

Palavras-chave: Assinatura de Cargas, Medidores Inteligentes, Inteligência Artificial, Internet das coisas, Árvore de Decisão e Naive Bayes

Abstract

The identification of individual household appliances in the residential power grid can provide better control of the consumption and detection of anomalies present in some of these appliances. This identification is only possible if each appliance has a charge signature. The generation of charge signature occurs through applications such as the smart meter that provides information needed for this purpose.

¹Universidade Federal do Piauí (UFPI), PI – Brasil, thiago.engee@gmail.com

²Faculdade Estacio (CEUT), PI – Brasil, arturfdasveloso@gmail.com

³Faculdade Estacio (CEUT), PI – Brasil, nildo.ngo@gmail.com

⁴Faculdade FAETE, PI – Brasil, junioraraujo03@gmail.com

⁵Universidade Federal do Piauí (UFPI), PI – Brasil, daviluis323@gmail.com

⁶Faculdade Maurício de Nassau, PI – Brasil, tami.gallas@gmail.com

⁷Instituto de Telecomunicações, Universidade da Beira Interior - Portugal, jose.sobral@ubi.pt

The proposed work allows the reading and detection of residential household appliances present in the network, through the individual charge signature, using intelligent meters along with Artificial Intelligence. Some important electrical parameters will be analyzed and detected individually. With the aid of the Decision Tree and Naive Bayes algorithms, load signing creation data is stored in a database and trained for identification to be possible. However, an application is provided to the consumer to identify and classify any existing equipment in the residence when it is active, as well as anomalies and changes present in the residential network.

Keywords: Load Signatures, Smart Meters, Artificial Intelligence, Internet of Things, Decision Tree and Naive Bayes

1 Introdução

A expansão acentuada do consumo de energia elétrica apresenta aspectos negativos, como: a possibilidade do esgotamento dos recursos utilizados para a sua produção, o impacto ao meio ambiente e elevados investimentos exigidos tanto na pesquisa de novas fontes de produção de energia como na construção de novas usinas. Esta expansão pode ser verificada pelo consumo de energia elétrica no Brasil que totalizou 38.259 GWh em setembro de 2016, um avanço de 1,4% sobre o mesmo mês de 2015 (POYRAZOGLU; OH, 2016). Hoje, a eficiência energética é uma grande preocupação pública. Isto é, sabe-se que a energia pode ser economizada através de mudanças comportamentais dos usuários. Economizar energia não é apenas financeiramente rentável, mas também ajuda a reduzir as emissões de poluentes. O reconhecimento e o monitoramento das cargas elétricas de forma independente, são funcionalidades essenciais para alcançar padrões comportamentais corretos (DHANANJAYA et al., 2015).

Atualmente está sendo estudada a geração da assinatura de cada carga presente em uma residência (SOUSA et al., 2017). Neste trabalho, criamos assinatura de carga para eletrodomésticos residenciais, e os reconhecemos através de comparações utilizando o matLab. O presente trabalho, busca utilizar Inteligência Artificial para fazer esta análise de forma automática e inteligente. A assinatura de cargas consiste em um conjunto de características elétricas únicas para cada aparelho. Os parâmetros elétricos mais usados para essa descrição, são: tensão e corrente, potências ativa, reativa e aparente, fator de potências e harmônicas do sinal de corrente, que podem ser medidas por *Smart Meter* (SM) e usadas para descrever a carga de cada aparelho (SOUSA et al., 2017). Para que haja a identificação de cargas elétricas de cada aparelho, será necessário saber, com base na estrutura residencial, por exemplo, quais aparelhos estão ativos ou inativos. No modelo tradicional de identificação de

trica individual para cada aparelho. É possível, com este medidor elétrico, saber quais aparelhos estão ativos e não ativos, desde que haja um único medidor implementado em uma rede elétrica da residência. Sendo assim, o medidor deve contar com um sistema de identificação de cargas que vai ser utilizado para armazenar da assinatura elétrica de cada aparelho individualmente.

Diante da dificuldade de acompanhamento do consumo de energia elétrica em tempo real pelo consumidor, o trabalho de (PRIYANKA; VASISHT, 2015) entra neste contexto para propor implantações de ferramentas de Infraestrutura de Medição Avançada (AMI), que auxilia na identificação das cargas elétricas dos aparelhos. O SM possibilita aos seus usuários obter o devido conhecimento da demanda das cargas elétricas presentes em sua residência. O SM calcula o consumo de eletricidade e envia esses dados ao provedor de serviços para determinadas funções como o faturamento, por exemplo. O provedor de serviços calcula o valor conforme a taxa padrão por unidade e envia esse valor para o SM através de rede de comunicação (PREMNATH; HAAS, 2015). Com uma AMI em funcionamento, a visualização de dados pode ser feita com a ajuda de aplicativos móveis, sistemas desktop ou via web sites (SPANÒ et al., 2015).

Contudo, este trabalho propõe o desenvolvimento de um sistema de medição utilizando SM para Identificação de assinaturas de cargas para cada aparelhos na residência. Foi utilizado Inteligência Artificial (IA) com intuito de identificar cada aparelho eletroeletrônico através do conjunto de características elétricas únicas (parâmetros elétricos) com isso, têm-se uma aplicação de Internet das Coisas para descrever a carga de cada aparelho ativo num dado momento dentro da residência. A partir dos métodos de Aprendizagem Supervisionada, o método escolhido foi por Classificação Probabilística, usando o algoritmo Naive Bayes visando facilitar a identificação de cargas dos aparelhos por meio do SM. Contudo, existem poucos estudos seguindo a mesma linha deste trabalho. Por isso, procura-se contri-

buir de forma significativa para o atual estado da arte, com uma pesquisa que exponha um algoritmo capaz de identificar cargas de forma individual, utilizando um Home Energy Management (HEM), o qual, por sua vez, executa um algoritmo de reconhecimento de padrões integrado ao SM. Possibilita-se, assim, futuras pesquisas mais aprofundadas segundo esta linha de atuação. O trabalho tem como objetivo o resultado prático, assim como vislumbra a fundamentação teórica, ambas foram exploradas e utilizadas em um ambiente real. Foram plotados resultados que validam a parte prática, apresentando a identificação das cargas e seus logs gerados pelo sistema.

Este artigo está organizado na seguinte forma: na seção II são apresentados os trabalhos relacionados. A seção III apresenta a descrição do sistema proposto e a metodologia de desenvolvimento do do sistema. Na Seção IV descreve-se os experimentos realizados. Os resultados dos experimentos são discutidos na Seção V. Finalmente, na seção VI, discutem-se os trabalhos futuros e a conclusão da pesquisa.

Este estudo é uma versão estendida de um artigo já publicado ENUCOMP 2017 (SOUSA et al., 2017). As extensões em relação ao trabalho original incluem a implementação e a incorporação dos algoritmos Árvore de Decisão e Naive Bayes e uma descrição mais profunda do funcionamento dos algoritmos, apresentando suas características no contexto deste trabalho para a análise do experimento no ambiente dos medidores inteligentes o Smart Meters e como caso adicional para o estudo de caso é fornecido ao usuário uma aplicação que permite identificar e classificar qualquer equipamento existente na residência.

2 Trabalhos Relacionados

Conforme o atual estado da arte na área de identificação de cargas, é claro ver a utilização de vários métodos para este fim. As bases desses métodos são as características elétricas, com publicações datando de diferentes décadas. Esta área tem ganhado cada vez mais espaço nos anos atuais, principalmente

devido à enorme quantidade de estudos referentes a Smart Grid(SG) e SM, conforme se observa em (BOUHOUS; MILIOUDIS; LABRIDIS, 2014) (ŠÍRA; ZACHOVALOVÁ, 2015) (YANG; SHEN et al., 2013) (AHMADI; MARTI, 2015).

Em (BURUNKAYA; PARS, 2017), os autores propuseram uma implementação de um SM com interface ZigBee para medir o uso de energia elétrica, registrar dados em tempo real e controle dos dispositivos conectado na saídas da potencia. O protótipo do SM transmite os dados calculados através da comunicação ZigBee para um computador pessoal. Entretanto, neste trabalho não são apresentados, detalhadamente, os protocolos utilizados pra transmissão, a maior distância e quais dados serão enviados para a base de gerenciamento.

Em (PEREIRA et al., 2015), os autores propuseram um sistema de gerenciamento da energia elétrica com a integração de SM a uma SG residencial. O trabalho desenvolvido apresenta a implementação de uma plataforma utilizando o protocolo ZigBee. O distribuidor possui um SM utilizando a comunicação com fio sobre o protocolo ModBus para sistemas SCADA (Supervisory Control And Data Acquisition) que supervisiona a rede de controladores programáveis de PLC. A estratégia dos autores foi implementar um controlador em cascata hierárquico onde os loops internos são executados por PLCs locais e o loop externo é gerenciado por um sistema SCADA centralizado, que interage com toda a rede local do PLC.

Em (MINCHALA-AVILA et al., 2016), os autores propuseram um modelo de SM integrado a recursos de demand response (DR). Neste trabalho é implementado um protótipo sobre uma infraestrutura de medição avançada (AMI), que permite a comunicação bidirecional entre os SMs domésticos e o sistema de gerenciamento de distribuição. Entretanto, as desvantagens do sistema proposto é que não é considerado o conforto do usuário, o que é importante para desenvolver uma estratégia de redução de carga menos agressiva. Além disso, o sistema trabalha com fundamentação teórica

e simulação, o que não permite coletar dados em ambiente real.

Em (AHMADI; MARTI, 2015), os autores propõem um processo de identificação baseado no comportamento do equipamento elétrico/eletrônico em regime estacionário, com baixo consumo de recurso computacional e de memória, onde a caracterização da carga é baseada em apenas três vertentes: entropia de Shannon, entropia de Renyi e energia da banda espectral. Os resultados obtidos pelos autores indicam que a técnica se mostrou bastante eficiente para a identificação de cargas individuais.

O monitoramento e identificação de carga de aparelhos não-intrusivos e sistema de identificação para Smart Homes (SH) são explorados em (HUI; LOGENTHIRAN; WOO, 2016). Desde a aquisição da forma de onda de cada assinatura, até a identificação de assinaturas de carga. Ainda neste trabalho, são fornecidas outras formas de obter os resultados. O sistema pode seja dividido em 3 seções principais: aquisição de assinatura de carga, pré-filtragem e identificação de carga.

Em (XU et al., 2014), é apresentado um método para quebrar demanda de energia total medida por um SM usado por aparelhos individuais. Tem como principal objetivo ajudar na identificação e rastreamento das cargas de energia de aparelhos domésticos. A principal proposta dos autores é modelar todo o funcionamento do ciclo da carga e identificá-las com base em janelas de eventos. Foi implementado um algoritmo para a modelagem dos dados e identificações posteriores.

Em (AMRY; GAIDI; NACHTANE, 2016), os autores propuseram a implementação do SM para casas marroquinas por meio de seus múltiplos serviços, estimativas e exibições em tempo real. O objetivo do trabalho foi encorajar os usuários a se conscientizarem sobre seus consumos de energia elétrica. Como resultado, a implantação desta tecnologia irá auxiliar o usuário sobre problemas do consumo de energia assim como incentivá-lo a mudar seu perfil de consumo.

Devido à necessidade dos consumidores ras-

trearem seu uso diário e entender os padrões de consumo para controlar esses recursos, o artigo (ELAKSHUMI; PONRAJ, 2017) analisa o desempenho de um sistema de SM e a transmissão eficiente. Adicionalmente, explora como as Electric Power Companies (EPCs) exploram novos desenvolvimentos em benefício dos consumidores e de si mesmo, monitorando remotamente o consumo de energia. Em (PAWAR; MOMIN, 2017), foi realizada uma breve revisão da literatura sobre a utilização do SM integrado no sistema de SG. Os autores afirmam que a funcionalidade principal dos SMs é medir, capturar e transformar dados relacionados ao uso ou consumo de eletricidade, gás ou água e eventos como o status do medidor e a qualidade da energia elétrica.

Conforme estudado, os autores dos trabalhos presentes no atual estado da arte propõem diversos métodos para a coleta de informações dos SMs para obter dados estatísticos, assim como possibilitar a identificação e monitoramento de cargas de aparelhos eletrônicos, assim como monitoramento de cargas não-intrusivas para SHs. Contudo, este trabalho propõe a utilização do SM para coletar dados de assinatura de cargas para fazer uma pré-filtragem e identificação de aparelhos por meio de HEM usados para ajudar na exibição de dados e monitoramento do consumo de energia elétrica residencial. A identificação é efetuada através de um sistema composto pelo algoritmo de inteligência artificial baseado no algoritmo de Naive Bayes.

3 Descrição do sistema

Para que os SMs possam atuar de forma padrão e organizada dentro de uma SG, alguns parâmetros deverão ser considerados. Primeiramente, além de simplesmente as EPCs possam distribuir energia para as residências, deverá também haver uma comunicação bidirecional entre ambas. Para que possa haver essa comunicação, deverá ter uma troca de dados entre SMs via IEEE 802.16 (WiMax) (DARYAPURKAR; KARANDIKAR, 2017), até que a informação possa chegar ao Metering Data

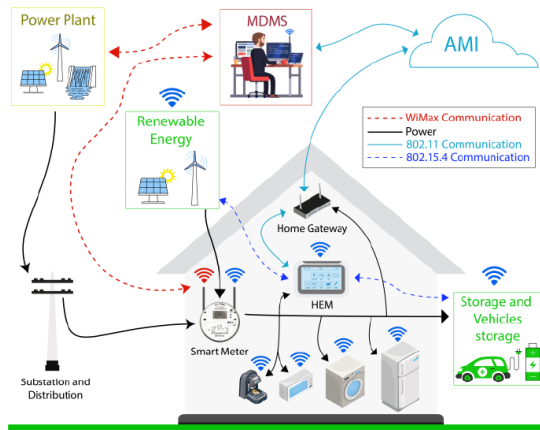


Figura 1: Arquitetura geral do sistema proposto

Management Systems (MDMS) (KABALCI, 2016). Além dessa comunicação, foi implementada a troca de dados com o HEM via IEEE 802.15.4, por meio da rede ZigBee local (LUAN et al., 2009). Com a comunicação implementada, a MDMS será capaz de ler vários parâmetros dos SMs residenciais. Assim como também poderá fornecê-los para um serviço na nuvem chamado Advanced Metering Infrastructure (AMI) (TONG et al., 2016). O AMI fornece diversos controles específicos que são distribuídos como serviços na nuvem. É através dele que o HEM irá coletar vários dados como por exemplo o preço da energia naquele intervalo de tempo.

Dentro da casa, haverá um sistema de gerenciamento com IA que irá funcionar no HEM, que é um dispositivo que se conecta com a internet local, e com a rede ZigBee local, para fazer a troca de dados com a API (Application Programming Interface) (DESHMUKH; JAGTAP, 2017) do AMI e com os eletrodomésticos presentes na casa. É no HEM que o algoritmo de identificação de assinatura de cargas irá atuar. Ele irá verificar qual eletrodoméstico estarão sendo ligados/desligados em tempo real. Essa identificação irá gerar logs e registros que serão armazenados no banco de dados para futuras pesquisas, geração de relatórios e controle personalizados do consumo de energia da residência.

3.1 Home Energy Management - HEM

O HEM (ULLAH et al., 2015) será o eletrodoméstico fundamental para possibilitar a identificação de cargas em tempo real, pois ele estará conectado diretamente com o SM via rede local ZigBee, coletando todos os principais parâmetros da rede elétrica. Poderá, assim, fornecer esses dados para uma aplicação que estará sendo executada nele. Esta aplicação estará treinada com uma IA e possuirá um BD para armazenar os logs e históricos de identificação realizados ao longo do dia. O HEM irá mostrar, de forma visual, assim como poderá gerar futuros relatórios e pesquisas personalizadas de dados importantes sobre o consumo e eletrodomésticos, como por exemplo, informações da qualidade dos eletrodomésticos, anomalias nas redes, consumo individual, e entre outras informações que poderá auxiliar bastante o consumidor ao controlar sua conta de energia elétrica.

3.2 Coleta de dados e Serviços na nuvem

Como o SM está lendo constantemente os dados da rede elétrica, esses dados serão enviados em tempo real para o HEM. O pacote de dados enviado consiste em: Current, Voltage, Power Factor, Active Power, Apparent Power and Consumed Energy. Esse pacote de dados é enviado para o HEM, para que ele possa processá-los por meio do algoritmo de IA e então possa identificar a carga que estará sendo ligada/desligada naquele momento. A representação dessa comunicação é apresentada na Fig. 2. A cada 20 segundos, o HEM envia esses dados e os logs para o serviço na nuvem (AMI) via RESTful (SELVAKUMAR; KAVIYA, 2016). O objetivo desse envio é o monitoramento remoto via web sites ou aplicativos mobile, para conhecimento do que estará acontecendo na residência.

A identificação da carga só se faz necessária neste cenário, quando os consumidores querem ter o controle total e personalizado do que está acontecendo em sua residência. Ou até mesmo, a identificação de anomalias e/ou detalhes mais importantes que farão diferença




Figura 2: Detalhe da comunicação

no consumo da rede elétrica. Foram coletados 10799 registros relacionados aos parâmetros elétricos dos aparelhos, sendo classificados como Geladeira 3600 registros, 3599 registros como Máquina de lavar e 3600 registros como TV. Os dados coletados foram salvos em arquivos CSV (Comma Separated Values) para posterior pré-classificação, realização de treinamento e de teste.

3.3 Assinaturas de Aparelhos Residenciais

A assinatura de cargas (CARDENAS; AG-BOSSOU; GUZMÁN, 2016)(DINESH et al., 2014) consiste em um conjunto de características elétricas únicas para cada aparelho, que podem ser medidas e utilizadas para a identificação de cargas. Os parâmetros elétricos utilizados para essa discriminação são: tensão e corrente, potências ativa, reativa e aparente, e o fator de potência (CHEN et al., 2016). Neste trabalho foi utilizado o sistema intrusivo para discriminação do consumo por aparelho, que consiste em uma medição de cada carga individualmente, ou seja, o medidor é instalado antes dos aparelhos de forma que a identificação é feita a partir do momento em que um dos eletrodomésticos é ligado/desligado. Consequentemente, limita-se a utilização do medidor para apenas um aparelho. O algoritmo de IA irá identificar qual aparelho foi ligado, com base em seu treinamento que será realizado antes da identificação (momento de inserção do aparelho no sistema) (BACURAU et al., 2015) (BACURAU et al., 2014).

Primeiramente foram realizadas medições

com o SM para obtenção dos valores dos parâmetros elétricos necessários para formação da assinatura de carga de cada eletrodoméstico. As medições tiveram um total de 3600 amostragens, sendo lidas a cada segundo num intervalo de 1h. Os dados utilizados para definição da assinatura de carga e para criação do algoritmo responsável pela identificação dos aparelhos em funcionamento são lidos e enviados para o HEM.

3.4 Identificação Inteligente

Aprendizagem de máquina (AM) é um campo de pesquisa da Inteligência Artificial que cria e usa modelos que são aprendidos a partir dos dados históricos. Em geral, os diversos algoritmos de AM são utilizados de forma a gerar modelos preditivos (classificadores) para um conjunto de exemplos (GRUS, 2015). Ao longo desta seção será apresentados algumas técnicas utilizadas neste trabalho.

3.4.1 Árvore de Decisão

A Árvore de Decisão utiliza uma estrutura de árvore para representar um número de possíveis caminhos de decisão e um resultado para cada caminho (GRUS, 2015). De acordo com (SEGARAN, 2008) é um das técnicas extremamente simples de aprendizado de máquina. Esses caminhos de decisão são convertidos em um série de afirmações if-then a fim de classificar as observações. A figura 3 mostra um exemplo.




Figura 3: Exemplo Árvore de Decisão (SEGARAN, 2008)

As decisões são tomadas seguindo o caminho da árvore onde as ligações entre os nós representam os valores possíveis do teste do nó superior, e as folhas indicam a classe (categoria) a qual o registro pertence. assim respon-

dendo a cada pergunta corretamente é possível chegar em uma resposta. Traçando de volta do nó onde você acabou dá uma justificativa para a classificação final.

3.4.2 Naïve Bayes

Naïve Bayes é um classificador probabilístico, baseado no teorema de Bayes e utiliza dados de treino para formar um modelo probabilístico baseado na evidência das características no dado.

$$P(A|B) = P(B|A)P(A)P(B) \quad (1)$$

A fórmula 1, calcula a probabilidade da posteriori $P(A|B)$ de uma determinada classe, dado o conjunto de probabilidades condicionais dividido pela probabilidade a priori $P(B)$, probabilidade de uma classe conhecida (GOEL; GAUTAM; KUMAR, 2016). Para calcular $P(B|A)$ a probabilidade condicional, é necessário um conjunto de dados treinados que já foram classificados. Dessa forma, pode-se calcular a probabilidade de um determinado evento de acordo com sua frequência. Mas já sabendo qual foi o evento que o antecedeu. Isto é, avalia-se a probabilidade de um registro ter uma polaridade específica, ou a probabilidade de um evento acontecer de acordo como o especialista classificou os registros (GOEL; GAUTAM; KUMAR, 2016).

3.5 Identificação da assinatura de cargas de eletrodomésticos residenciais

A abordagem proposta da Identificação usando inteligência artificial é resumido na Fig. 4. Primeiramente, os parâmetros elétricos são utilizados para criar os modelos classificadores A e B. Modelo A faz uso do algoritmo Árvore de Decisão que podem converter os atributos das cargas elétricas em regras de classificação, enquanto que o modelo B (Naïve Bayes) baseia-se na evidência das características dos dados. Primeiramente tem-se como parâmetros de entrada, os cinco valores referentes as cargas elétricas. Os algoritmos iram utilizar a base e o conhecimento já adquirido para identificar a

carga. E terá como saída, o nome do eletrodoméstico.

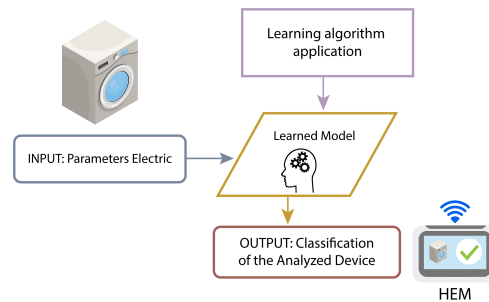


Figura 4: Fluxograma da identificação dos algoritmos.

4 Testbed e Resultados experimentais

Primeiramente, para que possa ser possível identificar as cargas, deverá haver uma assinatura de cargas (AC) para cada eletrodoméstico. Iremos utilizar neste trabalho um Refrigerator, uma TV e uma máquina de lavar. As assinaturas foram obtidas em um trabalho realizado pelos mesmo autores deste trabalho em (SOUSA et al., 2017). Os principais dados gerados na AC são: Corrente, Fator de potência, Potência aparente e ativa, e tensão. Essas assinaturas são representadas na Fig. 5.

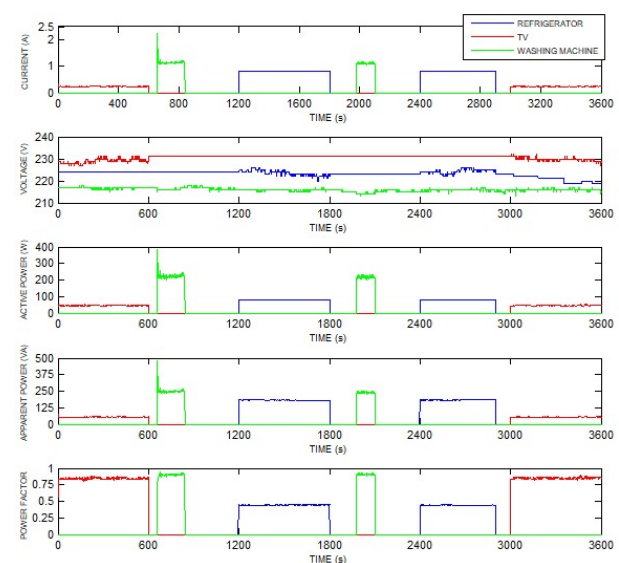


Figura 5: Assinaturas de cargas dos aparelhos utilizados nos testes

A leitura desses parâmetros é feita pelo SM, que está ligado na rede elétrica. O teste teve

duração de 1 hora, e os eletrodomésticos são ligados separadamente em horários diferentes. É possível notar quais são os cinco parâmetros de cada eletrodoméstico e isso torna mais simples a identificação dos rótulos como pode ser visto 6. Onde 0 representa geladeira, 1 máquina de lavar e 2 TV. Todos são enviados ao HEM que armazenará em um banco de dados local.




Figura 6: Identificação dos Rótulos

5 Resultados

Os algoritmos foram aplicados na base de dados de assinatura de cargas por identificação. A validação cruzada de 5 vezes é utilizada para avaliação de desempenho dos modelos (ASTUTI; NUGROHO; ADJI, 2015). Os resultados do modelo A e modelo B foram apresentados na Tabela 1. Os resultados mostram que a precisão geral para o modelo A e modelo B é de 93,5% e 99,9% respectivamente. O modelo B é um pouco menos preciso que o modelo A, mas comparando esses resultados na literatura o modelo A e modelo B tiveram um desempenho ótimo.

Tabela 1: Conjunto de Parâmetros Elétricos de Aparelhos Proposto para o Modelo A e Modelo B

Fold	Acurácia (modelo A)	Acurácia (modelo B)
5	0.935	0.999

A validação cruzada de 5 vezes onde é feito aleatoriamente as escolhas das amostras para treinamento e validação, o que pode levar a uma pequena variação na precisão geral em cada treinamento conforme mostra a Tabela II. Através deste experimento, pode-se mostrar que armazenar parâmetros elétricos de aparelhos não diminuir o desempenho da assinatura de cargas (ALI et al., 2016).

Tabela 2: Precisão dos Rótulos

	Modelo A	Modelo B
Geladeira	100%	100%
Maquina de lavar	84%	100%
TV	100%	100%
Média	95%	100%

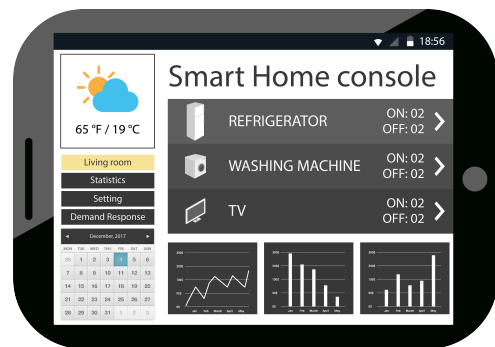


Figura 7: Aparelho do Home Energy Management

Contudo, o HEM irá apresentar para o usuário, de forma visual, informações sobre o consumo de energia e, principalmente, a identificação da quantidade de vezes que aquele eletrodoméstico será ligado/desligado. Além da quantidade, o usuário tem acesso a informações mais detalhadas como: O tempo que cada eletrodoméstico estará ligado/desligado, horários de funcionamento, consumo individual em cada horário, alerta de anomalias ou atividades incomum na rede, entre outras informações importantes que facilmente poderão ser apresentadas via software.

6 Conclusões e Trabalhos relacionados

Este trabalho propõe uma implementação de um HEM composto por algoritmos de IA ca-

paz de identificar cargas de aparelhos residenciais utilizando a comunicação com SMs. Possui como base trabalhos presentes no atual estado da arte. Foram trabalhadas tecnologias bem atuais como a implementação do SM, aplicativos móveis para o HEM e para o app mobile, implementação do AMI na nuvem e dispositivos presentes no cenário de IoT. Este trabalho possui um grande desafio, que é prover a identificação das cargas dos eletrodomésticos com a utilização das métricas fornecidas pelo SM. Adicionalmente, a implementação algoritmos de IA para fazer o treino e a identificação de forma ágil e inteligente. E seu objetivo foi alcançado através de testes práticos que forneceram a validação da implementação proposta.

Contudo, o atual estado da arte ainda possui poucas pesquisas que façam a identificação de cargas utilizando este cenário. Portanto, a principal contribuição desse trabalho é apresentar uma abordagem completa para identificação de cargas, que envolva tanto os aspectos teóricos quanto os práticos. A implementação de um HEM que irá trabalhar juntamente com o SM, também foi um grande salto para novas pesquisas neste sentido. Além de remover um grande trabalho que deveria ser feito pelo SM, o HEM irá prover dados estatísticos, informações visuais e a possibilidade de utilizações futuras em sites, apps ou até mesmo algoritmos de Demand Response para atuar no cenário de automação residencial, possibilitando o usuário ou sistemas, que liguem/desliguem eletrodomésticos presentes no sistema. O controle de forma detalhada irá fornecer facilidades ao usuário, possibilitando que ele possa monitorar e alterar seu perfil de consumo de energia elétrica. O principal benefício seria a redução da conta de energia elétrica ou mesmo o simples monitoramento dos fatores que influenciaram a fatura. A integração do HEM com as EPCs também será possível, o que tornará mais prático o fornecimento da conta de energia elétrica, assim como o pagamento. Ambos poderão ser de forma instantânea ou até mesmo automática.

Este trabalho tem como limitação a unici-

dade de identificação de carga de forma individual, o que ainda inviabiliza sua implantação antecipada. Entretanto, como trabalhos futuros, pretende-se pesquisar e desenvolver um módulo de identificação de cargas que seja capaz de fazer esta identificação em aparelhos que estarão em funcionamento em conjunto. Ainda como trabalhos futuros, aponta-se a comparação desse modelo com outros algoritmos propostos na literatura.

Referências

- AHMADI, H.; MARTI, J. R. Load decomposition at smart meters level using eigenloads approach. *IEEE Transactions on Power Systems*, IEEE, v. 30, n. 6, p. 3425–3436, 2015.
- ALI, N. M. et al. Object classification and recognition using bag-of-words (bow) model. In: IEEE. *2016 IEEE 12th International Colloquium on Signal Processing & Its Applications (CSPA)*. [S.l.], 2016. p. 216–220.
- AMRY, Y.; GAIDI, M. E.; NACHTANE, M. Design and optimization of a smart meter to meet the growing needs of energy in morocco. In: IEEE. *2016 International Renewable and Sustainable Energy Conference (IRSEC)*. [S.l.], 2016. p. 1115–1118.
- ASTUTI, T.; NUGROHO, H. A.; ADJI, T. B. The impact of different fold for cross validation of missing values imputation method on hepatitis dataset. In: IEEE. *2015 International Conference on Quality in Research (QiR)*. [S.l.], 2015. p. 51–55.
- BACURAU, R. et al. Experimental investigation on the load signature parameters for non-intrusive load monitoring. *Przeglad Elektrotechniczny*, v. 91, n. 8, p. 86–90, 2015.
- BACURAU, R. M. et al. Techniques for efficient implementation of firmware in microcontroller s based energy consumption breakdown smart meters. *VIVECHAN International Journal of Research*, v. 5, n. 1, 2014.
- BOUHOUBAS, A. S.; MILIOUDIS, A. N.; LABRIDIS, D. P. Development of distinct load

- signatures for higher efficiency of nilm algorithms. *Electric Power Systems Research*, Elsevier, v. 117, p. 163–171, 2014.
- BURUNKAYA, M.; PARS, T. A smart meter design and implementation using zigbee based wireless sensor network in smart grid. In: . [S.l.]: IEEE, 2017.
- CARDENAS, A.; AGBOSSOU, K.; GUZMÁN, C. Development of real-time admittance analysis system for residential load monitoring. In: IEEE. *2016 IEEE 25th International Symposium on Industrial Electronics (ISIE)*. [S.l.], 2016. p. 696–701.
- CHEN, H.-Y. et al. Identifying variable-power appliances in non-intrusive load monitoring systems. In: IEEE. *Innovative Mobile and Internet Services in Ubiquitous Computing (IMIS), 2016 10th International Conference on*. [S.l.], 2016. p. 452–457.
- DARYAPURKAR, R.; KARANDIKAR, R. Wimax for data aggregation in smart grid communication network—a review. In: IEEE. *2017 International Conference on Wireless Communications, Signal Processing and Networking (WiSPNET)*. [S.l.], 2017. p. 97–100.
- DESHMUKH, R. S.; JAGTAP, V. A survey: Software api and database for emotion recognition. In: IEEE. *2017 International Conference on Intelligent Computing and Control Systems (ICICCS)*. [S.l.], 2017. p. 284–289.
- DHANANJAYA, W. et al. Appliance-level demand identification through signature analysis. In: IEEE. *2015 Moratuwa Engineering Research Conference (MERCOn)*. [S.l.], 2015. p. 70–75.
- DINESH, H. et al. A subspace signature based approach for residential appliances identification using less informative and low resolution smart meter data. In: IEEE. *2014 9th International Conference on Industrial and Information Systems (ICIIS)*. [S.l.], 2014. p. 1–6.
- ELAKSHUMI, S.; PONRAJ, A. A server based load analysis of smart meter systems. In: IEEE. *2017 International Conference on Next-Gen Electronic Technologies: Silicon to Software (ICNETS2)*. [S.l.], 2017. p. 141–144.
- GOEL, A.; GAUTAM, J.; KUMAR, S. Real time sentiment analysis of tweets using naive bayes. In: IEEE. *2016 2nd International Conference on Next Generation Computing Technologies (NGCT)*. [S.l.], 2016. p. 257–261.
- GRUS, J. *Data science from scratch: first principles with python*. [S.l.]: "O'Reilly Media, Inc.", 2015.
- HUI, L. Y.; LOGENTHIRAN, T.; WOO, W. Non-intrusive appliance load monitoring and identification for smart home. In: IEEE. *2016 IEEE 6th International Conference on Power Systems (ICPS)*. [S.l.], 2016. p. 1–6.
- KABALCI, Y. A survey on smart metering and smart grid communication. *Renewable and Sustainable Energy Reviews*, Elsevier, v. 57, p. 302–318, 2016.
- LUAN, S.-W. et al. Development of a smart power meter for ami based on zigbee communication. In: IEEE. *International Conference on Power Electronics and Drive Systems, 2009. PEDS 2009*. [S.l.], 2009. p. 661–665.
- MINCHALA-AVILA, L. I. et al. *Design and Implementation of a Smart Meter with Demand Response Capabilities*. [S.l.]: IEEE, 2016. v. 103.
- PAWAR, S.; MOMIN, B. Smart electricity meter data analytics: A brief review. In: IEEE. *2017 IEEE Region 10 Symposium (TENSYP)*. [S.l.], 2017. p. 1–5.
- PEREIRA, R. et al. *Consumer energy management system with integration of smart meters*. [S.l.]: IEEE, 2015. v. 1.
- POYRAZOGLU, G.; OH, H. The impacts of electric power market simulation on engineering education. In: IEEE. *2016 IEEE/PES*

- Transmission and Distribution Conference and Exposition (T&D)*. [S.l.], 2016. p. 1–5.
- PREMNATH, S. N.; HAAS, Z. J. Security and privacy in the internet-of-things under time-and-budget-limited adversary model. *IEEE Wireless Communications Letters*, IEEE, v. 4, n. 3, p. 277–280, 2015.
- PRIYANKA, N.; VASISHT, A. Smart cities. *International Journal of Engineering Science Invention*, p. 43–49, 2015.
- SEGARAN, T. *Programming collective intelligence: building smart web 2.0 applications*. [S.l.]: "O'Reilly Media, Inc.", 2008.
- SELVAKUMAR, G.; KAVIYA, B. J. A survey on restful web services composition. In: IEEE. *2016 International Conference on Computer Communication and Informatics (ICCCI)*. [S.l.], 2016. p. 1–4.
- ŠÍRA, M.; ZACHOVALOVÁ, V. N. System for calibration of nonintrusive load meters with load identification ability. *IEEE Transactions on Instrumentation and Measurement*, IEEE, v. 64, n. 6, p. 1350–1354, 2015.
- SOUSA, T. et al. Implementação de um módulo medidor para criação de assinatura de cargas utilizando internet das coisas. In: UESPI. *Anais Eletrônicos ENUCOMP 2017*. [S.l.], 2017. p. 353–360. ISBN 978-85-8320-201-1.
- SPANÒ, E. et al. Last-meter smart grid embedded in an internet-of-things platform. *IEEE Transactions on smart grid*, IEEE, v. 6, n. 1, p. 468–476, 2015.
- TONG, W. et al. A survey on intrusion detection system for advanced metering infrastructure. In: IEEE. *2016 Sixth International Conference on Instrumentation & Measurement, Computer, Communication and Control (IMCCC)*. [S.l.], 2016. p. 33–37.
- ULLAH, I. et al. A survey of home energy management for residential customers. In: IEEE. *2015 IEEE 29th International Conference on Advanced Information Networking and Applications (AINA)*. [S.l.], 2015. p. 666–673.
- XU, W. et al. An event window based load monitoring technique for smart meters. p. 1–1, 2014.
- YANG, S.-l.; SHEN, C. et al. A review of electric load classification in smart grid environment. *Renewable and Sustainable Energy Reviews*, Elsevier, v. 24, p. 103–110, 2013.