

Evento: XXV Jornada de Pesquisa
ODS: 12 - Consumo e produção responsáveis

MODELAGEM DE CARGAS RESIDENCIAIS COM IDENTIFICAÇÃO NÃO INTRUSIVA UTILIZANDO REDES NEURAIS ARTIFICIAIS.¹

MODELING OF RESIDENTIAL LOADS WITH NON-INTRUSIVE IDENTIFICATION USING ARTIFICIAL NEURAL NETWORKS.

Willian Henrique Dambros², Maurício de Campos³, Paulo Sérgio Sausen⁴

¹ Pesquisa desenvolvida no Mestrado em Modelagem Matemática, elaborado no Programa de Pós-Graduação da Unijuí.

² Bolsista Unijuí no Programa de Pós-Graduação em Modelagem Matemática da Unijuí.

³ Professor do Programa de Pós-Graduação em Modelagem Matemática da Unijuí, Orientador.

⁴ Professor do Programa de Pós-Graduação em Modelagem Matemática da Unijuí, Coorientador.

Resumo: O consumo de energia elétrica tem aumentado progressivamente ao longo dos anos. Vários fatores contribuem para isso entre eles está o uso inadequado de energia elétrica. Uma forma de minimizar esse impacto em ambientes residenciais é monitorar e identificar o uso de energia de cada carga, de forma individual. Existem duas formas de realizar esse monitoramento: o monitoramento de cargas intrusivo (ILM), que realiza a medição através de vários sensores, um para cada equipamento a ser analisado, e, o monitoramento de cargas não intrusivo (NILM), que realiza a medição junto ao ponto de entrada de energia (painel do medidor ou quadro geral), utilizando apenas um dispositivo para realizar a medição e a aquisição de dados. Através deste monitoramento, é possível extrair o conhecimento sobre o padrão de consumo de uma determinada residência, possibilitando o planejamento e o gerenciamento do consumo de energia. A proposta deste trabalho, é apresentar o desenvolvimento de uma modelagem de um sistema residencial a partir do monitoramento não intrusivo de cargas residenciais, de forma a identificar e classificar as mesmas de acordo com suas características, utilizando as Redes Neurais Artificiais. Os resultados obtidos demonstram que é possível a partir de um único sistema de monitoramento determinar quais são os equipamentos que estão em uso, em cada período.

Abstract: Electricity consumption has increased over the years. Several factors contribute to this, among them is the inappropriate use of electricity. One way to minimize this impact, in residential environments, is to monitor and identify the use of electricity in each load, individually. There are two ways to perform this monitoring: intrusive load monitoring (ILM), which performs the measurement through several sensors, one for each equipment to be analyzed, and non-intrusive load monitoring (NILM), which performs the measurement next to the energy entry point (meter panel or general board), using only one device to perform the measurement and data acquisition. Through this monitoring, it is possible to extract knowledge about the consumption pattern of a particular residence, making it possible to plan and manage energy consumption. The purpose of this work is to present the development of a modeling of a residential system from the non-intrusive monitoring of residential loads, in order to identify and classify them according to their characteristics, using Artificial Neural Networks. The results obtained show that it is possible from a single monitoring system to determine which equipment is in use, in each period.

Palavras-chave: Monitoramento de cargas intrusivo, monitoramento de cargas intrusivo não intrusivo, Redes Neurais Artificiais.

Evento: XXV Jornada de Pesquisa

ODS: 12 - Consumo e produção responsáveis

Keywords: Monitoring of intrusive loads, monitoring of non-intrusive loads, Artificial Neural Networks.

1 INTRODUÇÃO

Em muitos países, incluindo o Brasil, o consumo de energia elétrica aumentou progressivamente ao longo dos anos. Vários fatores contribuíram para esse aumento, dando destaque para o aumento da população, o crescimento econômico, a evolução tecnológica e o uso inadequado de energia elétrica. Levando em conta este aumento no consumo de energia elétrica, o desenvolvimento de soluções tecnológicas voltados a um consumo mais eficiente podem trazer impactos significativos na otimização do consumo de energia elétrica.

Uma das soluções possíveis nesse caso, é a redução do consumo de energia elétrica obtida através de programas de resposta a demanda, e, por meio de sistemas de gerenciamento de energia. Diante deste cenário, com o intuito de auxiliar os consumidores de energia elétrica, surge o conceito de Home Energy Management Systems - HEMS. De acordo com [1] os sistemas de HEMS, apresentam algumas funções importantes, como:

- Monitorar o funcionamento de equipamentos elétricos, com intuito de mostrar informações sobre o consumo de energia elétrica;
- Controlar o funcionamento dos equipamentos elétricos de maneira local ou remota;
- Gerenciar a produção, armazenamento e consumo de energia elétrica;
- Segurança elétrica, ou seja, gerar e enviar sinais de alerta em caso de detecção de falhas nos equipamentos elétricos;
- Executar o controle de demanda de acordo com as alterações de preços por tarifas em tempo real, quando possível.

Esses sistemas auxiliam na redução do desperdício de energia elétrica minimizando gastos desnecessários. Esta é uma solução tecnológica e sustentável, uma vez que, se baseia no princípio de redução de investimentos em expansão do Sistema Elétrico de Potência (SEP).

O monitoramento de cargas residenciais permite um conjunto de informações úteis para os consumidores de energia elétrica, bem como para as concessionárias de energia. Entre essas informações, está o detalhamento do consumo de energia elétrica de cada residência, por exemplo, que pode ser utilizado pelos consumidores para uma mudança de hábitos, buscando uma economia na conta de energia elétrica. Para [2], o conhecimento do padrão de consumo de energia elétrica de cada carga de uma residência, pode proporcionar uma economia no consumo de energia de 5 % até 20 %.

O monitoramento de cargas é considerado um processo de aquisição de dados de cada carga a partir de medições, em um sistema de energia. Essas medições são realizadas por meio de sensores que devem ser instalados em cada carga, ou ainda diretamente na entrada de energia.

Nesse contexto, de acordo com Hart [3], existe o Monitoramento de Cargas Intrusivo, também conhecido pelo termo inglês Intrusive Load Monitoring (ILM), que requer a instalação de vários sensores, um para cada equipamento a ser analisado, apresentando um hardware complexo, porém o software utilizado para obter o consumo de cada carga é simples. Nessa técnica é necessário o acesso físico as cargas, ou seja, o sistema é intrusivo, além de apresentar um alto custo com a instalação. Fatores esses, tornam essa técnica menos atrativa.

Por outro lado, Hart [3] propôs o Monitoramento de Cargas Não Intrusivo, do inglês Non Intrusive Load Monitoring (NILM), como alternativa para se obter informação de consumo de energia elétrica sem a necessidade de sensores em cada equipamento, sendo que a medição é realizada com apenas

Evento: XXV Jornada de Pesquisa

ODS: 12 - Consumo e produção responsáveis

um sensor colocado na entrada de energia (quadro geral). Essa técnica tem como principal vantagem a redução significativa no custo da instalação (hardware), além de, não necessitar de acesso físico às residências, menor quantidade de componentes na instalação, maior confiabilidade, menor manutenção, bem como, permite que mais cargas sejam monitoradas.

No entanto, como os dados estão sendo coletados a partir de um único ponto, é necessária alguma técnica que permita determinar o consumo individual de cada carga. Uma das possibilidades, é utilizar técnicas e algoritmos para identificação das cargas e classificação das mesmas. Devido aos resultados satisfatórios e sua fácil implementação através do software MATLAB, optou-se por utilizar as Redes Neurais Artificiais (RNAs), que são técnicas de inteligência artificial (IA), que tem por finalidade aprender padrões, simulando o comportamento dos neurônios biológicos [4].

Um sistema NILM, que tenha uma boa sensibilidade na identificação das cargas pode auxiliar os consumidores, como o melhor horário para utilizá-las, mostrando assim a importância de monitorar e gerenciar cargas, evitando perdas desnecessárias, tanto para o consumidor, como as concessionárias de energia elétrica.

2 METODOLOGIA

O referencial teórico, ora apresentado, representa o estudo criterioso da bibliografia sobre o monitoramento não intrusivo de cargas elétricas residenciais, utilizado como base para o desenvolvimento do sistema proposto para identificação de cargas elétricas residências, por meio de técnicas de monitoramento não intrusivo, utilizando Redes Neurais Artificiais.

2.1 MONITORAMENTO INTRUSIVO DE CARGAS

O monitoramento de cargas intrusivo, apresentado na Figura 2.1 é aquele que requer acesso físico às cargas, ou seja, a instalação de um sensor para cada equipamento. Após a realização das medições, os dados obtidos em cada sensor são armazenados, organizados, e exibidos por um software [3].

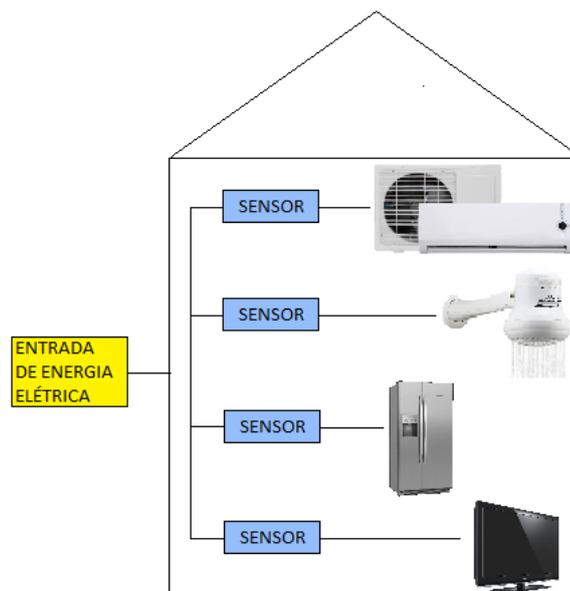


Figura 2.1: Esquema do monitoramento intrusivo de cargas [Fonte: Autor]

Evento: XXV Jornada de Pesquisa

ODS: 12 - Consumo e produção responsáveis

Como já afirmando, estes sistemas de monitoramento intrusivo, apresentam uma estrutura de hardware mais complexa. Uma vez que é necessária, a instalação dos sensores em cada equipamento, por outro lado um software mais simples, já que os dados são monitorados individualmente [3]. Instalações deste tipo, podem trazer informações detalhadas e precisas, informando o consumo, rotina de uso, e ciclo de funcionamento, sendo de grande utilidade para o gerenciamento do uso de energia elétrica. Apesar de ser uma boa solução, a necessidade de acesso físico é um obstáculo, além disso, o grande número de sensores utilizados, determina altos custos. Portanto, uma boa alternativa, é a utilização do monitoramento de cargas não intrusivo, o qual será o tema principal deste trabalho.

2.2 MONITORAMENTO NÃO INTRUSIVO DE CARGAS

O monitoramento de carga não intrusivo, é uma alternativa utilizada para fornecer a informação de consumo de energia elétrica desagregada por equipamento ou dispositivo. Esta técnica, apresenta como característica principal o fato de não haver necessidade de acesso físico no interior das instalações, sendo que a medição é realizada com apenas um sensor colocado no circuito principal (quadro geral ou medidor) [3], conforme Figura 2.2.

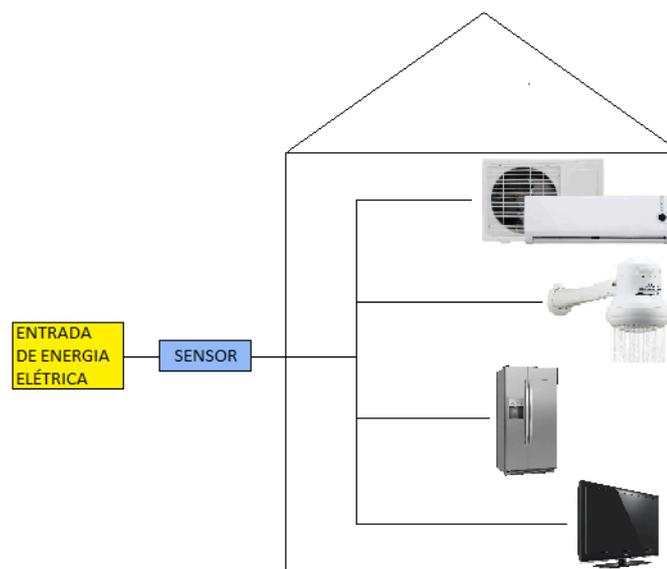


Figura 2.2: Esquema do monitoramento não intrusivo de cargas [Fonte: Autor].

Este tipo de monitoramento, apresenta um hardware menos complexo, uma vez que, apenas um sensor é instalado junto ao ramal principal, porém, exige um software bem complexo, uma vez que, necessita desagregar as informações de cada carga. Portanto, neste caso, o maior benefício está na redução de custos com a instalação [3].

O consumo individual de cada carga é determinado a partir da análise e do tratamento dos dados de tensão e corrente na interface com a fonte de energia elétrica que alimenta a instalação elétrica. Ou seja, as formas de onda de tensão e corrente são registradas, analisadas e processadas, com objetivo de gerar a estimativa de consumo individual das cargas. Resumidamente, esta análise, permite a partir de características elétricas, conhecidas como assinaturas elétricas, identificar as cargas no momento em que elas são acionadas ou desligadas [3].

Evento: XXV Jornada de Pesquisa

ODS: 12 - Consumo e produção responsáveis

Sabe-se que as assinaturas elétricas contêm importantes informações para a identificação dos tipos de cargas. Quando observado o sinal em regime permanente, adquire-se informações como o nível de potência ativa e reativa, que podem ser usadas como um primeiro filtro. Porém, existem outras informações relacionadas ao regime transitório que podem auxiliar na identificação das cargas, como, a forma de onda da corrente, admitância da carga, transitório de partida, componentes harmônicos da corrente, entre outros [6].

A partir desta análise, o consumo de energia elétrica residencial pode ser desagregado, sendo assim, possível determinar quais os aparelhos que participam do consumo. Hart [3], apresenta o equacionamento da desagregação da potência elétrica, conforme Equação 3.2, destacando que, um dos elementos importantes é a determinação do estado de operação dos aparelhos a cada instante de tempo:

$$P(t) = \sum_{i=1}^n a_i(t)P_i + e(t) \quad (2.1)$$

onde: $P(t)$ é o vetor com os valores da potência total medida para cada instante de tempo t ; $a_i(t)$ é o vetor do estado de cada equipamento conhecido; P_i é o valor da potência estimada do i -ésimo equipamento, para $i = 1, \dots, n$; e $e(t)$ é a parcela de potência não conhecida ou o erro na estimação de potência referente aos equipamentos conhecidos.

Vários estudos foram desenvolvidos a partir do final de 1980 até os dias atuais, dando destaque para Hart (1992), que é considerado o marco principal dessa área. Apesar de o NILM ter recebido uma atenção significativa nos últimos anos através de pesquisas, e de seu alto potencial, ainda não foi desenvolvido um algoritmo capaz de detectar todos os tipos de cargas presentes em uma residência. Além de que, não foi possível definir uma assinatura padrão para todos os aparelhos.

De acordo com Zeifman e Roth [7], existem vários trabalhos que apresentam metodologias diferentes no desenvolvimento de algoritmos para a desagregação de cargas, porém, pode-se considerar três etapas: detecção de eventos, reconhecimento da carga e estimação do consumo.

Ainda, segundo constatação de Zeifman e Roth [7], as metodologias de NILM são divididas basicamente em três etapas:

- Instalar medidores ou sensores com capacidade de obter os dados onde seja possível identificar as assinaturas elétricas;
- Descrever matematicamente as assinaturas elétricas dos equipamentos;
- E, detectar as assinaturas elétricas através de algoritmos matemáticos.

Portanto, as técnicas de NILM são muito úteis para o monitoramento de cargas, devido a sua facilidade na instalação, uma vez que, permite que vários aparelhos sejam monitorados simultaneamente. Tem como características principais, menor custo, melhor resolução, bem como maior facilidade na instalação, remoção e manutenção. Vantagens essas, fazem com que o NILM seja utilizado por diversos públicos, incluindo analistas de cargas, analistas de taxas, formuladores de políticas públicas, além de projetistas de dispositivos/aparelhos [8].

Portanto, o NILM pode ser útil em diversas aplicações, como por exemplo: gerenciamento de cargas, auditorias energéticas, pesquisas sobre o regime de uso de cargas, acompanhamentos de cargas de difícil acesso, além de sistemas de detecção de falhas em equipamentos elétricos [5].

Assim pode-se concluir que, o NILM pode ser aplicado em três classes de clientes, residenciais, comerciais e industriais, contudo o tratamento ocorre de maneira diferenciada, devido aos diferentes tipos e características de cargas. Entretanto, até o momento, a maioria das implementações e pesquisas realizadas, foram voltadas para cargas residenciais [9].

Evento: XXV Jornada de Pesquisa

ODS: 12 - Consumo e produção responsáveis

2.2.1 Modelos de Aparelhos

Hart [3], classificou os equipamentos em três classes:

- ON/OFF: Representam uma grande parte das cargas presentes em residências, são aquelas que têm único estado quando estão ligadas. Exemplos: Torradeiras, lâmpadas, chuveiro;
- Máquinas de Estados Finitos (MEF), ou do inglês, Finite State Machine (FSM): Podem possuir um número arbitrário de estados e de transições entre elas. Exemplo: Máquina de lavar roupas, máquina de lavar louças;
- Continuamente Variáveis: Apresentam um número infinito de estados, porém, são pouco utilizadas em ambientes residenciais. Exemplo: Refrigeradores que usam inversores de frequência para controlar a velocidade do compressor, furadeiras;

Apesar de Hart [3], listar apenas três modelos de cargas, de acordo com Zeifman e Roth [7], o mais adequado seria tratar a divisão com quatro classes, sendo acrescido as cargas consideradas continuamente ligadas. Este tipo de carga, consome energia, durante 24 horas por dia, 7 dias por semana, com potências ativas e reativas aproximadamente constantes. Como exemplos deste tipo de cargas, pode citar os roteadores, utilizados para internet.

Portanto, quando analisado os modelos de cargas, os equipamentos presentes na categoria continuamente ligadas, que estão sempre operacionais sem variação de cargas, e os presentes na continuamente variáveis, que apresentam variações contínuas na demanda, são difíceis de diferenciá-los pela curva. Esses tipos de equipamentos, possuem baixa demanda de energia, ou são poucos utilizados, dependendo do caso, contribuindo assim de uma forma pouco significativa para o consumo total. Já para as categorias ON/OFF e Máquinas de Estados Finitos, são aquelas que representam a maioria dos equipamentos nas residências, apresentando uma identificação mais facilitada, visto que é possível observar os degraus de demanda na curva de carga quando entram e saem de operação. Nesse sentido, vale ressaltar que, quanto maior a resolução dos dados, mais detalhes podem ser representados pelas assinaturas elétricas dos equipamentos [10].

2.2.2 Aquisição do Sinal

A aquisição do sinal passa a ser a primeira etapa do NILM, ou seja, recolhe-se os dados de consumo de eletricidade de uma determinada residência a uma taxa adequada de medição para que os diferentes tipos de cargas possam ser identificados. A taxa de amostragem, ou seja, a frequência utilizada no recolhimento dos dados, depende de diversos fatores, como: o tipo de algoritmo a utilizar, o intervalo de precisão pretendido e das características dos medidores utilizados. Tendo em vista isso, pode-se fazer de duas maneiras [11]:

- Baixa frequência de amostragem: São medidores que trabalham com uma baixa taxa de amostragem, ou seja, inferior a 1 Hz (superiores ou igual a 1 segundo). Apresentam como ponto relevante o baixo custo na aquisição dos dados, por ser um hardware simples. Esses dados adquiridos através de uma baixa frequência, permitirão adquirir características macroscópicas (exemplo, a potência ativa e reativa).
- Alta frequência de amostragem: São medidores que trabalham com uma alta taxa de amostragem, ou seja, superiores a centenas de Hz. Apresentam um alto custo, devido ao hardware ser sofisticado. Com os dados obtidos em alta frequência, é possível observar as características microscópicas (harmônicas e as formas de onda de tensão e corrente).

A crescente implementação das Redes Inteligentes (do inglês, Smart Grids), e conseqüentemente, a implementação e utilização de Medidores Inteligentes (do inglês, Smart Meters), proporcionará um grande incentivo nas pesquisas voltadas ao NILM. Esses medidores, além de possuírem a capacidade de fornecer informações de consumo e demanda de energia mais detalhados e em intervalos de tempo programáveis, apresentam a capacidade de comunicação com a concessionária e uma interface para

Evento: XXV Jornada de Pesquisa

ODS: 12 - Consumo e produção responsáveis

interação com os usuários, permitindo que a gestão de energia seja feita em tempo real [12].

Portanto, aplicando as técnicas do NILM juntamente com os medidores inteligentes, será possível torná-lo definitivamente inteligente, uma vez que, fará com que o próprio medidor além de realizar a medição e transmissão dos dados, seja capaz de processar algoritmos com técnicas não intrusiva capazes de identificar, classificar e determinar o consumo individual de cada carga naquela edificação.

Com o objetivo de tentar tornar as pesquisas mais equivalentes no sentido de futuras comparações, pesquisadores têm disponibilizado as medições de energia utilizadas em seus trabalhos. Esses conjuntos de dados, apresentam características próprias, devido as diferentes metodologias apresentadas por cada pesquisador, que variam desde o local aonde foram realizadas as medições, bem como, nos equipamentos analisados, frequência de amostragem utilizada e as grandezas elétricas disponibilizadas. Essas medições, podem abranger os dados agregados, normalmente, de toda a instalação, bem como, em alguns casos, dados independentes por circuito, facilitando a identificação. Existem diversos conjuntos de dados disponíveis, como [13]: o REDD (do inglês, (Reference Energy Disaggregation Dataset), BLUED (do inglês, Building-Level fully-labeled dataset for Electricity Disaggregation), iAWE (do inglês, Indian data for Ambient Water and Electricity Sensing, UK-DALE (do inglês, United Kingdom Domestic Appliance Level Electricity, entre outros conjuntos de dados disponibilizados publicamente.

Com intuito de avaliar a metodologia desenvolvida nesta dissertação são utilizados os dados disponibilizados do banco de dados REDD, por este apresentar os dados em baixa e alta frequência de amostragem, além do monitoramento agregado e individual (por circuito) dos aparelhos.

2.2.3 Desagregação das cargas

No Monitoramento Não Intrusivo de Cargas, uma das principais etapas, é a desagregação de cargas, devido a isso, faz-se necessário entender as três etapas envolvidas nesse processo, que são: a detecção de eventos, o reconhecimento das cargas, e por fim, a estimação do consumo de cada carga.

A detecção de eventos, é fase em que detecta-se o estado de operação dos equipamentos a partir da análise do sinal agregado. As mudanças ON/OFF ocorridas nos níveis de potência são denominadas de transitórios, à medida que, o intervalo entre essas mudanças, ou seja, o tempo em que um equipamento ficou ligado, representam os eventos. É considerada uma etapa complexa devido aos diferentes tipos de cargas presentes nas residências, bem como, os diferentes estados em que podem estar.

Esta é uma etapa executada pelo algoritmo de desagregação, sendo que, o processo para determinar o estado de operação dos equipamentos, pode ser baseada em eventos ou não baseada em eventos [14]. No método baseado em eventos, utilizam as variações das grandezas elétricas para determinar os aparelhos que foram ligados ou desligados. Enquanto, o método não baseado em eventos, utilizam-se valores agregados para estabelecer os equipamentos que podem estar participando do consumo.

Após realizar a detecção de eventos, faz-se necessário realizar a classificação (ou desagregação) das cargas residenciais, classificando-as de acordo com as assinaturas extraídas de cada carga. São essas assinaturas utilizadas para afirmar se um evento é diferente ou igual aos de uma determinada carga.

O reconhecimento dos eventos pode ser realizado de três maneiras diferentes:

- O aprendizado supervisionado, que exige um treinamento das possíveis cargas presentes nas residências (ou seja, um conjunto de eventos já rotulados), para em seguida, após a detecção das cargas, classificá-las com as assinaturas semelhantes que já estavam rotuladas [14]. De acordo com Ridi, Gisler e Hennebert [15], este tipo de aprendizado é o mais utilizado nas abordagens NILM, por apresentar melhores resultados;

- Já no aprendizado não supervisionado, os eventos semelhantes são agrupados, sendo que cada

Evento: XXV Jornada de Pesquisa

ODS: 12 - Consumo e produção responsáveis

grupo representa um tipo de carga. Neste caso, não há a necessidade do treinamento inicial das cargas [16]. Contudo, para Zhang et. al [17], este tipo de método, apresenta baixa precisão, uma vez que, baseiam-se no reconhecimento das cargas através de assinaturas semelhantes presentes em bancos de dados;

- Por fim, o aprendizado semi-supervisionado, que é um misto das técnicas mencionadas anteriormente [14].

Além disso, existe ainda, duas propostas distintas para a classificação das cargas: algoritmos de otimização e algoritmos de reconhecimento de padrões. Quando utiliza-se algoritmos de otimização, obtém-se resultados satisfatórios na classificação de apenas uma carga. Porém, sabe-se que em residências, ocorre a utilização de mais de uma carga ao mesmo tempo, sendo necessário utilizar a programação inteira [18], ou então algoritmos genéticos [19], para realizar a classificação.

Outra forma de realizar a classificação é através de algoritmos de reconhecimento de padrões (algoritmos genéticos e redes neurais artificiais), baseados em métodos de transição de estado, detecção de transitório de partida e análise de harmônicos [20].

A terceira etapa envolvida no processo de desagregação de cargas é a estimação do consumo de energia elétrica consumida por cada carga analisada. Existem diversas formas de estimar o consumo de energia elétrica em uma residência, dependendo sempre do tipo de carga estudada. Considera-se um processo complexo, uma vez que, está diretamente relacionado as duas etapas iniciais, detecção e classificação de cada carga. Pois, se ocorrer qualquer erro nas etapas iniciais, como a não detecção de um evento, ou a classificação de uma carga errada, os valores finais estimados de consumo de energia apresentarão erros.

2.3 REDES NEURAIS ARTIFICIAIS

As Redes Neurais Artificiais, são técnicas de inteligência computacional (IC), que tem por finalidade aprender padrões, simulando o comportamento dos neurônios. Esta técnica, pode ser aplicada em diversas classes, como: reconhecimento e classificação de padrões, processamento de imagens digitais (PID), processamento de sinais, identificação e controle de sistemas, visão computacional, robótica, análise do mercado financeiro, entre outros [4].

A Rede Neural Artificial é constituída pela combinação de diversos neurônios artificiais interligados, sendo normalmente organizadas em camadas, conforme Figura 2.3. As entradas podem se conectar com muitos neurônios, resultando assim em várias saídas, uma para cada neurônio [21].

De acordo com Dhar e Stein [22], as RNAs são constituídas basicamente por três camadas:

- Camada de entrada (input): Tem como objetivo de receber e armazenar os dados de entrada para que possam ser inseridos na próxima camada;
- Camada Intermediária (hidden): Também conhecida como camada oculta, são aquelas que encontram-se entre a camada de entrada e de saída, sendo de grande importância, pois é nela que ocorre a maior parte do processamento;
- Camada de Saída (output): É aquela, que tem por finalidade, concluir e apresentar o resultado final, fornecendo os valores de saída que formam o vetor resposta da Rede Neural.

Evento: XXV Jornada de Pesquisa
ODS: 12 - Consumo e produção responsáveis

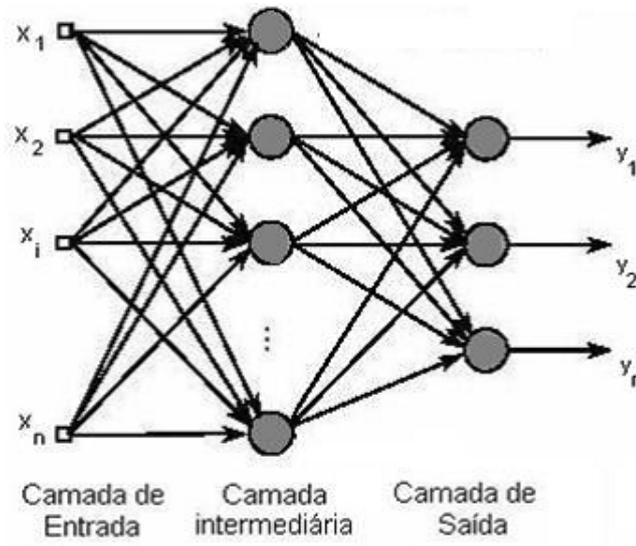


Figura 2.3: Rede Neural tipo Perceptron múltiplas camadas [21].

As RNA são como modelos matemáticos simplificados do sistema nervoso central. Basicamente, resultam em três componentes derivados do estudo do cérebro: Os neurônios e as forças sinápticas, que são semelhantes as estruturas encontradas no cérebro; e os mecanismos de aprendizado, que determinam o comportamento. Vale ressaltar, que os processos reais do funcionamento da inteligência biológica são complexos, dificultando muito na elaboração dos modelos matemáticos, responsáveis por simulá-los [23].

Ainda, a inteligência de uma RNA, é a combinação dos valores encontrados no vetor de entrada com os pesos existentes em cada neurônio, que resultam em uma determinada saída.

A RNA, passa por um processo de treinamento, que é a atribuição de valores aos pesos que combinarão as entradas em uma saída desejada, através de casos reais já conhecidos. Portanto, a rede neural, é capaz de extrair características básicas a partir dos dados reais, conseguindo assim, executar adequadamente o processo desejado, ao contrário, da programação computacional, que é preciso definir um conjunto de regras rígidas pré-fixadas e algoritmos [24].

Diante disso, é importante ressaltar, que existem vários tipos de RNA, que variam de acordo com os tipos de conexões, número de neurônios e do tipo de treinamento utilizado.

2.4 ESTUDO DE CASO

A metodologia utilizada para o desenvolvimento do sistema proposto, baseia-se em técnicas de monitoramento não intrusivas, utilizando para classificação das cargas as Redes Neurais Artificiais. A figura 2.4, representa o sistema de identificação de equipamentos elétricos baseados em RNAs.

Evento: XXV Jornada de Pesquisa
ODS: 12 - Consumo e produção responsáveis

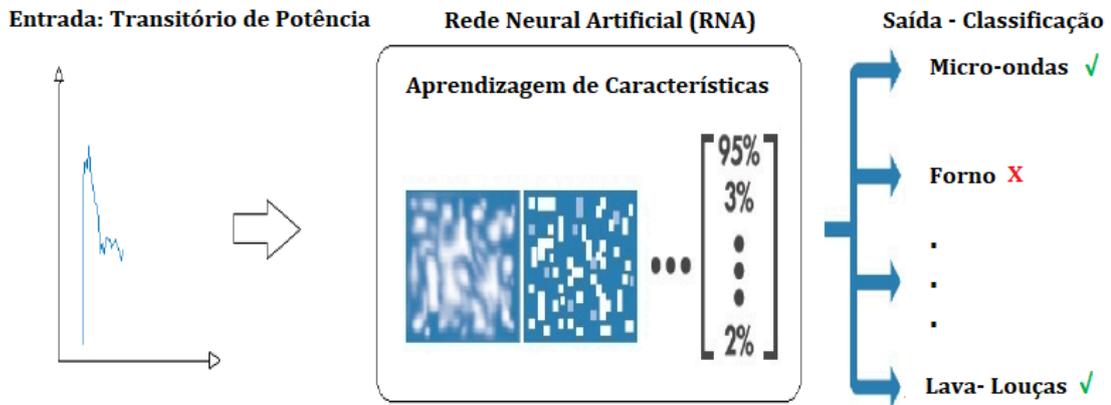


Figura 2.4: Sistema de identificação de equipamentos elétricos baseado em RNAs [Fonte: Autor].

Primeiramente, é necessário realizar a aquisição do sinal, ou seja, do consumo de energia elétrica em uma determinada residência, ou utilizar um conjunto de dados públicos já disponibilizado por outros pesquisadores. Diante disso, optou-se por utilizar o conjunto de dados REED, que é amplamente utilizado por pesquisadores desta área. Os dados analisados, foram adquiridos em baixa amostragem, 3 a 4 segundos, por um período de aproximadamente 17 dias.

O sistema foi desenvolvido para identificação de 5 equipamentos elétricos (Forno, Micro-ondas, Secador, Lava-louças e lavadora), utilizando a potência ativa como assinatura elétrica, para identificar se determinada carga elétrica estava em estado de funcionamento, ou seja, ligada ou desligada.

Os equipamentos escolhidos foram os que mais consomem energia em uma residência. Segundo Batra [25], deve-se priorizar a identificação de equipamentos com maior consumo de energia nas residências, pois estes aparelhos contribuem de uma forma mais significativa na carga agregada, podendo os outros aparelhos, com menos consumo, serem considerados apenas ruído na carga total agregada.

Considerando o sistema proposto, utilizou-se o software MATLAB, basicamente o toolbox nftool, para a realização das simulações, devido a sua fácil implementação e resultados satisfatórios.

Como parâmetros de entrada para a RNAs, utilizou-se uma matriz (1x 404107) composta pelo somatório das amostras de potência consumida dos 5 equipamentos elétricos analisados.

Através da análise da matriz de entrada (somatório das potências), e do comportamento de cada carga elétrica, criou-se um algoritmo de detecção de eventos, semelhante a metodologia utilizada por Hart [3], ou seja, tendo como base a análise da potência elétrica. Para isso, atribuiu-se para cada carga elétrica um peso diferenciado, bem como, para as possíveis combinações de cargas que funcionassem ao mesmo tempo. Este algoritmo, resultou em uma matriz de mesma dimensão (1x404107), sendo utilizada como o alvo da rede neural, ou seja, o que desejamos que a RNA aprende, para na sequência, realizar a classificação das cargas.

Além disso, no toolbox nftool, existem alguns parâmetros, que influenciam em um melhor aprendizado da rede e consequentemente em resultados mais satisfatórios, como: quantidade de neurônios, algoritmos de treinamento (Levenberg–Marquardt; Bayesian–Regulatization; Scaled Conjugate Gradient), bem como, quantidade de dados utilizados para treinamento, validação e teste da rede. Diante destes cenários, foram realizadas diversas simulações, alterando estes parâmetros, em busca da melhor solução possível.

Evento: XXV Jornada de Pesquisa
 ODS: 12 - Consumo e produção responsáveis

3 RESULTADOS E DISCUSSÃO

Realizada as simulações, os melhores resultados obtidos, foram utilizando os seguintes parâmetros:

- O número de neurônios na camada oculta foi definido como 50. Portanto, quanto menor for esse número de neurônios, a possibilidade de a rede não convergir aumenta, e quanto maior, os resultados são semelhantes, porém, o tempo de processamento aumenta significativamente;
- Dentre os três algoritmos de treinamentos existentes no toolbox nftool, o algoritmo de Levenberg-Marquardt, obteve o melhor resultado em um tempo de processamento menor;
- E por fim, os dados foram divididos em dados de treinamento, validação e teste, correspondendo respectivamente, a 50%, 25% e 25%. Vale ressaltar, que na configuração apresentada pelo software MATLAB, os dados de treinamento são compostos por treinamento e validação, portanto os dados foram divididos em treinamento (75%) e teste (25%).

O desempenho obtido pela técnica desenvolvida, é avaliado usando o erro quadrático médio e a análise de regressão. A Figura 3.1, apresenta o gráfico do erro quadrático médio, sendo que, quando mais próximo de 0, melhor o desempenho da rede.

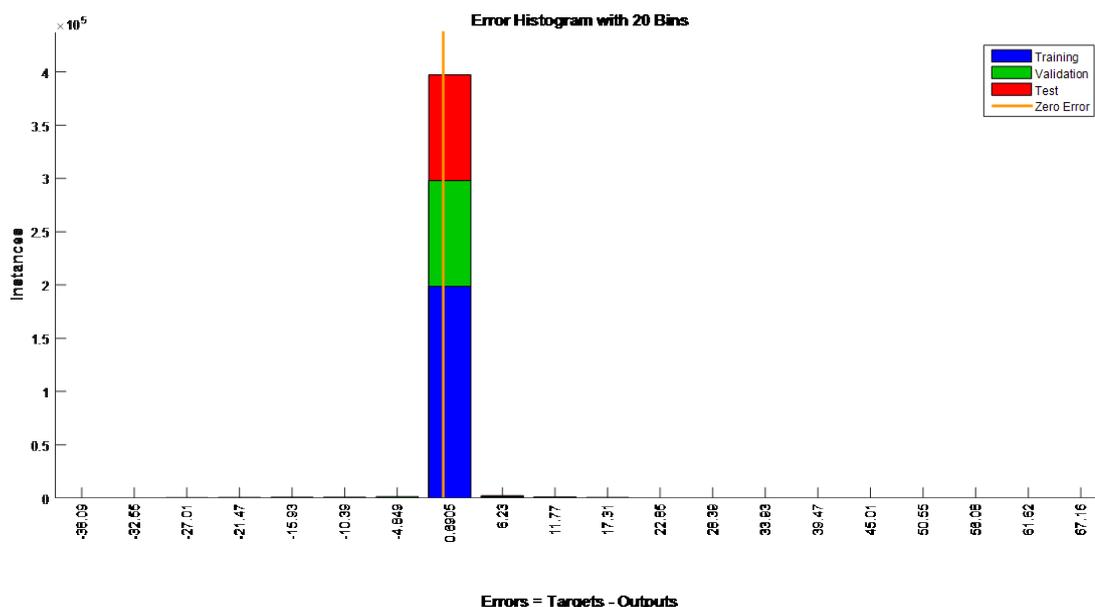


Figura 3.1: Gráfico do erro quadrático médio [Fonte: Autor].

E a Figura 3.2, apresenta a análise da regressão, sendo que quanto mais próximo de 1 for o valor da regressão, melhor o desempenho da rede neural desenvolvida.

Evento: XXV Jornada de Pesquisa
ODS: 12 - Consumo e produção responsáveis

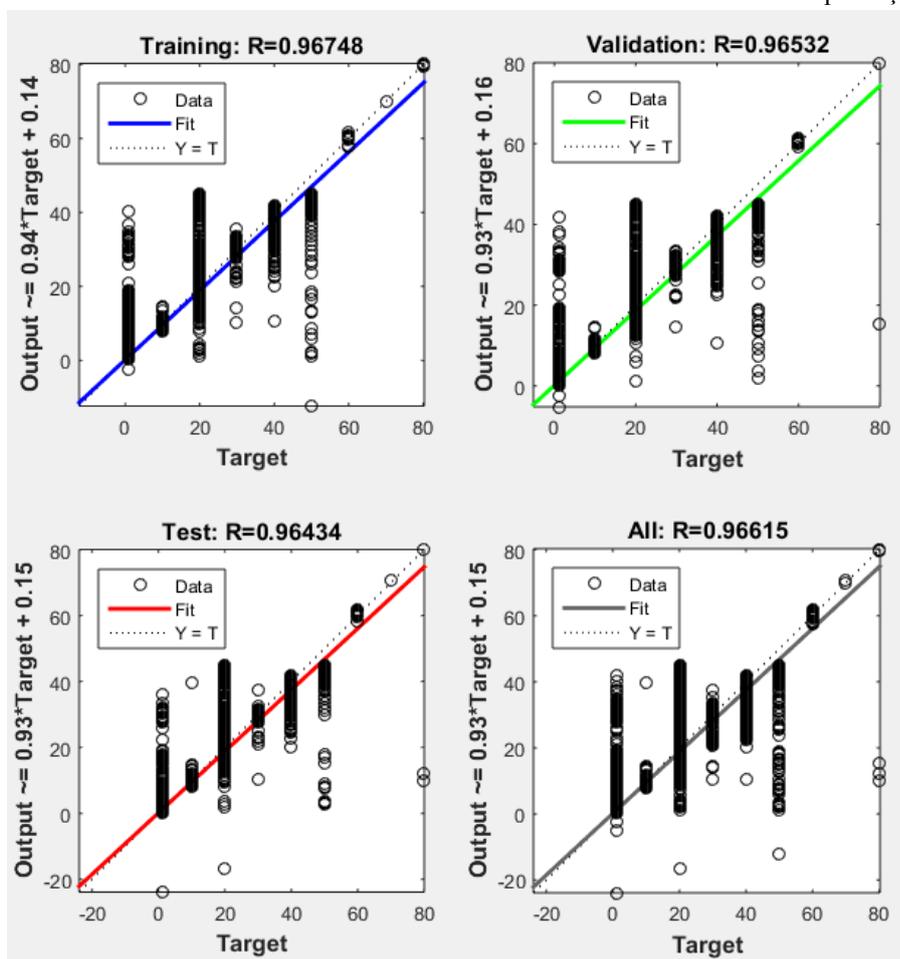


Figura 3.2: Gráfico da análise de regressão [Fonte: Autor].

Além disso, analisando a Figura 3.3, quando comparado o alvo da rede (linha azul), com o que a rede reconheceu (linha laranja), percebe-se que na maioria dos eventos, a rede teve um ótimo desempenho, classificando as cargas corretamente, porém, em alguns casos ocorreu alguns erros na classificação. Para melhor o desempenho da rede, evitando a ocorrência destes erros de classificação, faz-se necessário ajustar os pesos considerados no algoritmo de detecção de ventos.

Evento: XXV Jornada de Pesquisa
ODS: 12 - Consumo e produção responsáveis

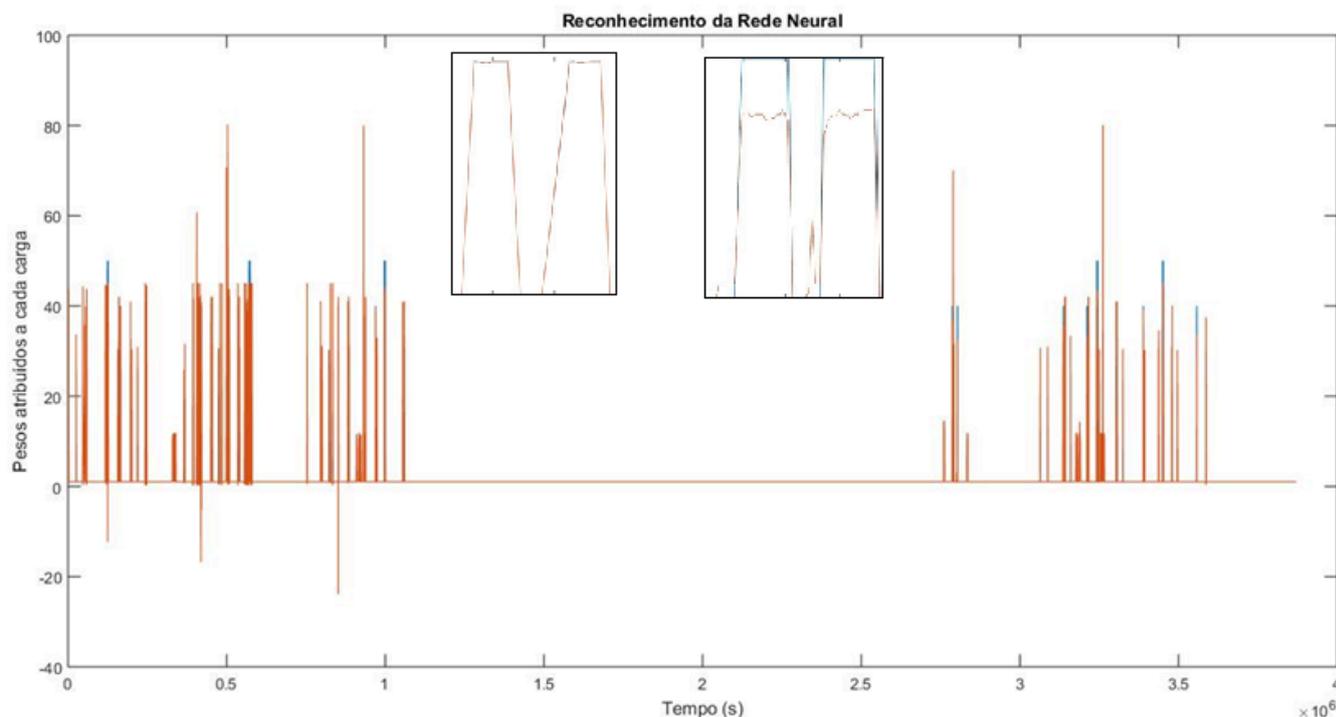


Figura 3.3. Gráfico do reconhecimento da Rede Neural desenvolvida. [Fonte: Autor].

Portanto, tendo como base, o erro quadrático médio de aproximadamente 0,7% e os valores de regressão de aproximadamente 0,96, conclui-se que a técnica desenvolvida para a identificação de cargas elétricas através do monitoramento não intrusivo, obteve um resultado satisfatório.

4 CONSIDERAÇÕES FINAIS

Neste trabalho foi apresentando um sistema desenvolvido para identificação de cargas elétricas através do monitoramento não intrusivo utilizando Redes Neurais Artificiais. Os resultados obtidos, indicam a eficiência do sistema proposto, onde se obteve uma taxa de erro em torno de 0,7%. Quando comparado aos demais sistemas de identificação já apresentados na literatura, os resultados são satisfatórios. Porém, vale ressaltar, que os cenários utilizados pelos demais pesquisadores são diferentes, podendo diferenciar-se de acordo com: o tipo de amostragem do sinal, assinatura elétrica utilizada, técnica de desagregação, tipos e quantidades de cargas analisada, período de aquisição, dentre outros fatores.

Além disso, a maior limitação do método desenvolvido, está relacionado ao número de cargas analisada. Caso, uma nova carga seja acrescentada, o algoritmo tentará classificar os eventos detectados com as cargas que já foram treinadas, podendo cometer erros na identificação. Tratando-se de uma RNA, para cada carga nova adicionada, necessita-se de um novo treinamento.

Portanto, o estudo desenvolvido permitiu identificar as principais vantagens de se utilizar o monitoramento não intrusivo de cargas, tendo como principal, o baixo custo na instalação e a não intrusividade nas residências. Percebe-se que muitos estudos vêm sendo desenvolvidos nessa área, porém, ainda não se tem um algoritmo capaz de identificar todas as cargas presentes em

Evento: XXV Jornada de Pesquisa

ODS: 12 - Consumo e produção responsáveis

uma residência. Portanto, um sistema NILM, que tenha uma boa sensibilidade na identificação das cargas pode auxiliar os consumidores, como o melhor horário para utilizá-las, mostrando assim a importância de monitorar e gerenciar cargas, evitando perdas desnecessárias, tanto para o consumidor, como as concessionárias de energia elétrica.

REFERÊNCIAS

- [1] ZHOU, B. et al. Smart home energy management systems: Concept, configurations, and scheduling strategies. *Renewable and Sustainable Energy Reviews*, Elsevier, v. 61, p. 30–40, 2016.
- [2] ZHUANG, M.; SHAHIDEHPOUR, M.; LI, Z. An overview of non-intrusive load monitoring: Approaches, business applications, and challenges. In: IEEE. 2018 International Conference on Power System Technology (POWERCON). [S.l.], 2018. p. 4291–4299.
- [3] HART, G. W. Nonintrusive appliance load monitoring. *Proceedings of the IEEE*, IEEE, v. 80, n. 12, p. 1870–1891, 1992.
- [4] PEDRYCZ, W.; GOMIDE, F. *Fuzzy systems engineering: toward human-centric computing*. [S.l.]: John Wiley & Sons, 2007.
- [5] PROPER, E. R. Automated classification of power signals. [S.l.], 2008.
- [6] ONZANI, R. C. et al. Monitoramento não invasivo e identificação do consumo de energia individual de cargas residenciais. [sn], 2016.
- [7] ZEIFMAN, M.; ROTH, K. Nonintrusive appliance load monitoring: Review and outlook. *IEEE transactions on Consumer Electronics*, IEEE, v. 57, n. 1, p. 76–84, 2011.
- [8] GELLER, H. S. Energy-efficient residential appliances: Performance issues and policy options. *IEEE Technology and Society Magazine*, IEEE, v. 5, n. 1, p. 4–10, 1986.
- [9] ANDREWS, C. Nonintrusive monitoring device for electric loads in commercial buildings. MIT Laboratory for Electrical and Electromagnetic Systems Technical Report, 1988.
- [10] AZZINI, H. A. D. Sistema de monitoramento de cargas residenciais usando informações on-off e modelos de consumo. [sn], 2017.
- [11] ZOHA, A. et al. Non-intrusive load monitoring approaches for disaggregated energy sensing: A survey. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 12, n. 12, p. 16838–16866, 2012.
- [12] PENHA, D. d. P. et al. Rede neural convolucional aplicada à identificação de equipamentos residenciais para sistemas de monitoramento não-intrusivo de carga. Universidade Federal do Pará, 2018.
- [13] BATRA, N. et al. Nilmtk: an open source toolkit for non-intrusive load monitoring. In: ACM. *Proceedings of the 5th international conference on Future energy systems*. [S.l.], 2014. p. 265–276.
- [14] ABUBAKAR, I. et al. An overview of non-intrusive load monitoring methodologies. In: IEEE. 2015 IEEE Conference on Energy Conversion (CENCON). [S.l.], 2015. p. 54–59.
- [15] RIDI, A.; GISLER, C.; HENNEBERT, J. A survey on intrusive load monitoring for appliance recognition. In: IEEE. 2014 22nd international conference on pattern recognition. [S.l.], 2014. p. 3702–3707.
- [16] MAIMON, O.; ROKACH, L. *Data mining and knowledge discovery handbook*. Springer, 2005.
- [17] ZHANG, X. et al. Iehouse: A non-intrusive household appliance state recognition system. In: IEEE. 2017 IEEE SmartWorld, Ubiquitous Intelligence & Computing, Advanced & Trusted Computed, Scalable Computing & Communications, Cloud & Big Data Computing, Internet of People and Smart City Innovation (SmartWorld/SCALCOM/UIC/ATC/CBDCOM/IOP/SCI). [S.l.], 2017. p. 1–8.
- [18] SUZUKI, K. et al. Nonintrusive appliance load monitoring based on integer programming. In: IEEE. 2008 SICE Annual Conference. [S.l.], 2008. p. 2742–2747.
- [19] ARDELEANU, A. S.; DONCIU, C. Nonintrusive load detection algorithm based on variations



Evento: XXV Jornada de Pesquisa

ODS: 12 - Consumo e produção responsáveis

in power consumption. In: IEEE. 2012 International Conference and Exposition on Electrical and Power Engineering. [S.l.], 2012. p. 309–313.

[20] CHANG, H.-H. et al. A new measurement method for power signatures of nonintrusive demand monitoring and load identification. IEEE Transactions on Industry Applications, IEEE, v. 48, n. 2, p. 764–771, 2012.

[21] TATIBANA, C. Y.; KAETSU, D. Y. Redes neurais. Universidade Estadual de Maringá, Departamento de Informática, Grupo de Sistemas Inteligentes, Capturado de <http://www.din.uem.br/ia/neurais>, Disponível em, v. 16, n. 02, 2006.

[22] DHAR, V.; STEIN, R. Seven methods for transforming corporate data into business intelligence. [S.l.]: Prentice-Hall, Inc., 1997.

[23] RAMOS, J. P. S. et al. Aplicação de redes neurais artificiais multicamadas estáticas no processo de seleção de frutos. [sn], 2001.

[24] TAFNER, M.; XEREZ, M. d.; FILHO, R. N. A. I. Introdução e princípios de neurocomputação. Blumenau: EKO: Editora da FURB, 11ª edição, 1996.

[25] BATRA, N.; SINGH, A.; WHITEHOUSE, K. If you measure it, can you improve it? exploring the value of energy disaggregation. In: Proceedings of the 2nd ACM International Conference on Embedded Systems for Energy-Efficient Built Environments. [S.l.: s.n.], 2015. p. 191–200.

Parecer CEUA: Protocolo nº 2260474