

UNIVERSIDADE FEDERAL DE OURO PRETO  
INSTITUTO DE CIÊNCIAS EXATAS E BIOLÓGICAS  
DEPARTAMENTO DE COMPUTAÇÃO

EDUARDO LOPES AMARO  
Orientador: Prof. Dr. Anderson Almeida Ferreira

**DESAGREGAÇÃO DE CARGAS USANDO O MODELO FATORIAL DE  
MARKOV OCULTO E A REDE LONG SHORT TERM MEMORY**

Ouro Preto, MG  
2022

UNIVERSIDADE FEDERAL DE OURO PRETO  
INSTITUTO DE CIÊNCIAS EXATAS E BIOLÓGICAS  
DEPARTAMENTO DE COMPUTAÇÃO

EDUARDO LOPES AMARO

**DESAGREGAÇÃO DE CARGAS USANDO O MODELO FATORIAL DE MARKOV  
OCULTO E A REDE LONG SHORT TERM MEMORY**

Monografia apresentada ao Curso de Ciência da Computação da Universidade Federal de Ouro Preto como parte dos requisitos necessários para a obtenção do grau de Bacharel em Ciência da Computação.

**Orientador:** Prof. Dr. Anderson Almeida Ferreira

Ouro Preto, MG  
2022

## SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

A485d Amaro, Eduardo Lopes.

Desagregação de cargas usando o Modelo Fatorial de Markov Oculto e a rede Long Short Term Memory. [manuscrito] / Eduardo Lopes Amaro. - 2022.

33 f.: il.: color., gráf..

Orientador: Prof. Dr. Anderson Almeida Ferreira.

Monografia (Bacharelado). Universidade Federal de Ouro Preto. Instituto de Ciências Exatas e Biológicas. Graduação em Ciência da Computação .

1. Mineração de dados. 2. Desagregação de cargas elétricas. 3. Aprendizado Profundo. I. Ferreira, Anderson Almeida. II. Universidade Federal de Ouro Preto. III. Título.

CDU 004

Bibliotecário(a) Responsável: Luciana De Oliveira - SIAPE: 1.937.800



## FOLHA DE APROVAÇÃO

**Eduardo Lopes Amaro**

### **DESAGREGAÇÃO DE CARGAS USANDO O MODELO FATORIAL DE MARKOV OCULTO E A REDE LONG SHORT TERM MEMORY**

Monografia apresentada ao Curso de Ciência da Computação da Universidade Federal de Ouro Preto como requisito parcial para obtenção do título de Bacharel em Ciência da Computação

Aprovada em 02 de Dezembro de 2022.

#### Membros da banca

Anderson Almeida Ferreira (Orientador) - Doutor - Universidade Federal de Ouro Preto  
Reinaldo Silva Fortes (Examinador) - Doutor - Universidade Federal de Ouro Preto  
Henrique Nogueira Soares (Examinador) - Doutor - Connecta IoT

Anderson Almeida Ferreira, Orientador do trabalho, aprovou a versão final e autorizou seu depósito na Biblioteca Digital de Trabalhos de Conclusão de Curso da UFOP em 02/12/2022.



Documento assinado eletronicamente por **Anderson Almeida Ferreira, PROFESSOR DE MAGISTERIO SUPERIOR**, em 02/12/2022, às 11:45, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site [http://sei.ufop.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **0434868** e o código CRC **093AC980**.

# Agradecimentos

Agradeço a Universidade pelo ensino gratuito e de qualidade e a todas as pessoas que sempre acreditaram no meu potencial!

# Resumo

Com o avanço desenfreado do desmatamento ambiental e o grande número de gases poluentes lançados na atmosfera diariamente, as preocupações em torno do aquecimento global e das mudanças climáticas ao redor do mundo se intensificaram. Esses impactos causam problemas não só para o meio ambiente, mas para o setor de energia elétrica como um todo, influenciando na oferta e demanda de energia elétrica no Brasil. O surgimento de novas tecnologias inteligentes como o Big Data, o Controle de Otimização Inteligente e os Medidores de Consumo Inteligentes, trazem novos artifícios para o controle e gerenciamento da oferta e demanda de energia elétrica. Diante deste desafio, neste trabalho são apresentadas duas abordagens amplamente utilizadas para resolver o problema do Monitoramento de carga não intrusivo (NILM - *Non-intrusive load monitoring*), uma baseada no Modelo fatorial de markov oculto (FHMM - *Hidden markov factorial model*) e a outra baseada em uma rede de Memória longa de curto prazo (LSTM - *Long short term memory*). Os dados de consumo de energia foram obtidos de uma base de dados pública denominada REDD, que contém medições de seis casas em baixa frequência na escala de 1Hz e disponibiliza os dados de consumo total e consumo real dos dispositivos em uma sequência de observações no período de um mês. A arquitetura dos modelos e os experimentos realizados foram descritos no desenvolvimento do trabalho, bem como, as etapas de treinamento e o teste das abordagens propostas. A avaliação dos resultados obtidos na desagregação do consumo de cada aparelho dentro da residência foi realizada usando as métricas da Raiz do erro quadrático médio (RMSE - *Root mean square error*) e do coeficiente de determinação ( $R^2$ ) e informam o erro obtido entre a predição do consumo e o consumo real de cada dispositivo. Com este trabalho, foi possível observar as principais etapas envolvidas na construção dos modelos de desagregação de cargas e conclui-se que as duas abordagens propostas conseguem obter resultados razoáveis na predição do consumo real dos dispositivos e fomenta o uso de duas técnicas para trabalharmos com os dados de consumo total e obter os dados de consumo agregado em uma residência.

**Palavras-chave:** Mineração de dados. - Desagregação de cargas elétricas. - Aprendizado Profundo.

# Lista de Ilustrações

Figura 2.1 – Oferta Interna de Energia Elétrica por Fonte. . . . .	4
Figura 2.2 – Consumo de Energia Elétrica por Setor. . . . .	5
Figura 2.3 – Principais etapas da metodologia do sistema NILM. . . . .	7
Figura 2.4 – Uma visão geral das etapas que compõem o processo KDD. . . . .	8
Figura 2.5 – Rede Neural Simples e Rede Neural Profunda (Deep Learning). . . . .	10
Figura 2.6 – Unidade da Rede LSTM. . . . .	11
Figura 2.7 – Visualização da classe MeterGroup. . . . .	12
Figura 2.8 – Técnicas utilizadas para resolver o problema de desagregação de cargas elétricas. . . . .	14
Figura 2.9 – Arquitetura do Modelo Fatorial de Markov Oculto. . . . .	17
Figura 3.1 – Consumo total de energia na residência. . . . .	21
Figura 3.2 – Consumo real de energia dos dispositivos. . . . .	21
Figura 3.3 – Conjunto de entrada com todas as medições. . . . .	22
Figura 3.4 – Arquitetura do modelo FHMM. . . . .	23
Figura 3.5 – Arquitetura do modelo LSTM. . . . .	23
Figura 3.6 – Entrada e saída da etapa de treinamento. . . . .	24
Figura 3.7 – Entrada e saída da etapa de teste. . . . .	25
Figura 3.8 – Treinamento do modelo FHMM. . . . .	25
Figura 3.9 – Treinamento do modelo LSTM. . . . .	26
Figura 4.1 – RMSE obtido na desagregação do modelo FHMM. . . . .	28
Figura 4.2 – Perda obtida na etapa de treino e validação com o modelo LSTM. . . . .	28
Figura 4.3 – RMSE obtido na desagregação com o modelo LSTM. . . . .	29
Figura 4.4 – Comparação entre o consumo real, consumo predito e a média do consumo em um dia. . . . .	30

# Lista de Abreviaturas e Siglas

ABNT	Associação Brasileira de Normas Técnicas
DECOM	Departamento de Computação
UFOP	Universidade Federal de Ouro Preto
ICEB	Instituto de Ciências Exatas e Biológicas
Aneel	Agência Nacional de Energia Elétrica
RVD	Redução Voluntária de Demanda
BEN	Balanco Energético Nacional
NILM	Non-intrusive load monitoring
KDD	Knowledge Discovery in Databases
DAE	Denosing Autoencoder
RNN	Recurrent Neural Network
LSTM	Long short term memory
GRU	Gated Recurrent Unit
IAWE	Indian Dataset for Ambient Water and Energy
UKdale	UK Domestic Appliance-Level Electricity
NILMTK	Non-Intrusive Load Monitoring Toolkit
REDD	Reference Energy Disaggregation Data Set
FHMM	Hidden markov factorial model
HMM	Hidden markov model
GMM	Gaussian Mixture Model
BH-FHMM	Hidden Markov Human-Factor Model
CNN	Convolutional Neural Network
ReLU	Rectified Linear Unit
EM	Baum-Welch



# Sumário

<b>1</b>	<b>Introdução</b>	<b>1</b>
1.1	Formulação do Problema	2
1.2	Justificativa	2
1.3	Objetivos	2
1.3.1	Objetivo Geral	3
1.3.2	Objetivos Específicos	3
1.4	Estrutura do Trabalho	3
<b>2</b>	<b>Revisão Bibliográfica</b>	<b>4</b>
2.1	Fundamentação Teórica	4
2.1.1	Matriz energética	4
2.1.2	Consumo de energia elétrica no setor residencial	5
2.1.3	Monitoramento do consumo de energia elétrica	6
2.1.4	Desagregação de energia	6
2.1.5	Processo de descoberta de conhecimento	8
2.1.6	Aprendizagem Profunda	9
2.1.7	Long Short Term Memory (LSTM)	10
2.1.8	Descrição do Conjunto de dados REDD	12
2.2	Trabalhos Relacionados	12
2.2.1	A Comprehensive Review on the NILM Algorithms for Energy Disaggregation	13
2.2.2	NILMTK: An Open Source Toolkit for Non-intrusive Load Monitoring	15
2.2.3	REDD: A Public Data Set for Energy Disaggregation Research	16
2.2.4	Non-intrusive load monitoring algorithm based on household electricity use habits	17
2.2.5	A practical solution based on convolutional neural network for non-intrusive load monitoring	18
<b>3</b>	<b>Desenvolvimento</b>	<b>20</b>
3.1	Ferramentas utilizadas na construção dos modelos	20
3.2	Pré processamento	20
3.3	Ajustes e configuração dos modelos	20
3.4	Arquitetura dos modelos	22
3.5	Conjunto de dados de treinamento e teste	24
<b>4</b>	<b>Resultados</b>	<b>27</b>
4.1	Métricas para avaliação das abordagens propostas	27
4.2	Resultados obtidos	27
4.2.1	Experimento usando o modelo FHMM	27

4.2.2	Experimento usando o modelo LSTM . . . . .	28
<b>5</b>	<b>Considerações Finais . . . . .</b>	<b>31</b>
5.1	Conclusão . . . . .	31
5.2	Trabalhos Futuros . . . . .	31
	<b>Referências . . . . .</b>	<b>32</b>

# 1 Introdução

A energia elétrica é um recurso fundamental para a sociedade humana, devido à sua infinidade de utilidades e sua grande eficiência tanto na geração quanto no consumo. Ela possibilita a utilização da iluminação dos ambientes, a refrigeração dos alimentos em freezers, o banho com água aquecida e o uso cada vez maior de aparelhos eletrodomésticos e eletrônicos. Este recurso tão importante viabiliza-se por meios renováveis e não renováveis e, suas principais fontes são as quedas d'água (Usina Hidrelétricas), vento (Usinas Eólicas), raios solares (Energia Fotovoltaica) ou combustíveis fósseis, como é o caso do carvão mineral ou gás natural (Usinas Termelétricas) (CAMPAGNANI, 2021).

No entanto, com esse avanço desenfreado do desmatamento ambiental e o grande número de gases poluentes lançados na atmosfera diariamente, surgem preocupações como o aquecimento global e as mudanças climáticas ao redor do mundo. Esses impactos têm produzido períodos secos mais longos, secas mais comuns e maior frequência de temperaturas extremas. Em 2021, foi registrada a “maior crise hídrica dos últimos 91 anos” que levou o governo brasileiro a emitir um alerta de emergência hídrica de junho a setembro na bacia do rio Paraná (DUTRA; FIGER, 2021).

Em paralelo à esses fatores, a crise hídrica de junho de 2021, levou a Agência Nacional de Energia Elétrica (Aneel) acionar a bandeira vermelha com um adicional de R\$ 0,06243 para cada Kwh consumido, impactando diretamente no bolso do consumidor. Outro ponto que agrava a crise energética é o isolamento social ocasionado pela pandemia da Covid-19, onde as pessoas tendem a ficar mais tempo em casa e, conseqüentemente, acabam utilizando com mais frequência os dispositivos que consomem energia.

Um artifício utilizado para auxiliar no controle e no gerenciamento da oferta e demanda de energia elétrica foi a Redução Voluntária de Demanda (RVD), que possibilitou aos consumidores do mercado livre uma redução de consumo de eletricidade em troca de uma recompensa financeira, produzindo um equilíbrio de mercado com ganhos de eficiência (CCEE, 2021). Este mecanismo foi utilizado como peça fundamental na crise do racionamento de 2001-2, quando foram impostas metas de redução de consumo de 20% para usuários de baixa tensão e variando entre 15 e 25% para aqueles conectados em alta tensão, dependendo da atividade econômica (DUTRA; FIGER, 2021).

No entanto, com o surgimento de novas tecnologias inteligentes como o Big Data, o Controle de Otimização Inteligente e os Medidores de Consumo Inteligentes, novos artifícios para o controle e gerenciamento da oferta e demanda de energia elétrica foram emergindo. O desenvolvimento da Rede Elétrica Inteligente conhecido como “Smart Grid” foi acelerado para melhorar a taxa de utilização de energia elétrica e fornecer serviços elétricos de alta qualidade.

Atualmente, com o avanço destas tecnologias, a quantidade de dados de consumo de eletricidade tornou-se abundante para a rede, e a utilização desses dados com eficácia ainda é um desafio (YIN et al., 2021).

## 1.1 Formulação do Problema

O problema abordado neste trabalho consiste em identificar o consumo individual de energia elétrica de cada dispositivo dentro de uma residência. Logo, dado o consumo de todo o ambiente  $C[ti]$  no instante  $ti$  e, seja  $Xj$  o conjunto que contém as leituras em cada instante de tempo de um dispositivo  $j$ , então,  $Xj = \{X1j, \dots, Xij\}$  onde  $i$  é o instante final. Já o consumo agregado, é a soma do consumo de todos os dispositivos presentes no ambiente, ou seja,  $C[ti] = \sum_{j=1}^{|A|} Xij$ , onde  $Xj \in A$ , tal que,  $A$  é o conjunto de dispositivos no ambiente o qual estamos interessados.

A desagregação é feita para cada intervalo de tempo, dado o consumo  $C[ti]$ , deve-se inferir o consumo de cada dispositivo  $Xij$  individualmente. A abordagem recebe uma janela do sinal agregado, ou seja,  $Cw = \{C[t1], C[t2], \dots, C[tw]\}$ , tal que  $w$  é o tamanho da janela.

## 1.2 Justificativa

Como relatado por (VERMA et al., 2021), vem ocorrendo um grande número de pesquisas e publicações sobre desagregação de energia, monitoramento de carga não intrusiva, gerenciamento de energia doméstica e classificação de eletrodomésticos. Com o desenvolvimento da sociedade e o crescimento exponencial no consumo de energia no setor residencial a cada ano, o desafio da conservação de energia se torna ainda mais difícil.

Com essas mudanças, os medidores inteligentes emergiram e permitiram a estimativa do consumo de energia específico de cada aparelho a partir da leitura do consumo de energia agregado da residência. Essa crescente demanda por energia não afeta apenas a economia de um país, mas também traz implicações negativas sobre o meio ambiente e, portanto, a única maneira eficaz de conservar energia agora é encorajar seu uso de forma eficiente.

Este trabalho tem o intuito de auxiliar profissionais no monitoramento e gerenciamento do consumo de energia elétrica dentro de residências, mostrando as principais abordagens e métodos capazes de classificar e prever os dados de consumo elétrico de cada dispositivos com eficácia, de acordo com a medição total do consumo da residência.

## 1.3 Objetivos

Nesta seção, são apresentados o objetivo geral e os objetivos específicos propostos neste trabalho.

### 1.3.1 Objetivo Geral

O objetivo geral deste trabalho é realizar um estudo que visa investigar quais são as principais etapas envolvidas no processo de desagregação de energia, e avaliar a aplicação do Modelo fatorial de markov oculto (FHMM - *Hidden markov factorial model*) e da rede Memória longa de curto prazo (LSTM - *Long short term memory*) para obter o consumo individual dos dispositivos.

### 1.3.2 Objetivos Específicos

Os objetivos específicos visam ressaltar os impactos ambientais do consumo de energia elétrica residencial e, como os métodos de desagregação de cargas podem contribuir com a pesquisa de desagregação de energia.

- Investigar as principais abordagens usadas no processo de desagregação de cargas;
- Construir os modelos de desagregação de cargas e, avaliar as principais etapas envolvidas nesse processo;
- Avaliar os resultados obtidos com o método baseado no Modelo Fatorial de Markov Oculto (FHMM) e com o método baseado na Long Short Term Memory (LSTM), em um estudo de caso.

## 1.4 Estrutura do Trabalho

Este trabalho está organizado em **cinco capítulos**, incluindo a presente introdução. O **segundo capítulo** descreve a revisão de literatura, a fundamentação teórica e os trabalhos relacionados. O **terceiro capítulo** detalha desenvolvimento proposto para resolver o problema de desagregação. O **quarto capítulo** mostra e detalhar os resultados obtidos durante a elaboração do trabalho. E o **quinto capítulo** apresenta as conclusões obtidas com os estudos realizados.

## 2 Revisão Bibliográfica

Neste capítulo, é discutida a base teórica necessária para melhor entendimento do trabalho. Nele, são expostas as informações a respeito da matriz energética brasileira, dos impactos ambientais negativos do consumo de energia elétrica no setor residencial, dos dispositivos utilizados para realizar as medições e das técnicas de mineração de dados mais utilizadas para realizar a desagregação de energia.

### 2.1 Fundamentação Teórica

Esta seção, relata os principais conceitos utilizados no desenvolvimento do trabalho e o embasamento teórico necessário para entender o contexto da necessidade do uso de técnicas de mineração de dados para realizar a desagregação de energia.

#### 2.1.1 Matriz energética

O Brasil possui uma matriz energética com diversas fontes de geração de energias, como mostrado no gráfico da Figura 2.1, e se destaca por ser o país com maior quantidade de recursos hídricos disponíveis, sendo hoje sua matriz hídrica responsável por cerca de 65,2% do total produzido de energia elétrica.




Figura 2.1 – Oferta Interna de Energia Elétrica por Fonte.

Fonte: Balanço Energético Nacional (BEN), 2021.

O funcionamento das usinas hidrelétricas se dá através da transformação de energia cinética em energia elétrica a partir da captação do movimento das águas (QUEIROZ et al., 2013). As usinas hidrelétricas são compostas, basicamente, por barragem, casa de força, vertedouro e sistemas de captação e adução de água, sendo que funcionam em conjunto e de maneira integrada. A barragem interrompe o curso normal do rio e desvia para um determinado local formando grandes reservatórios, que estocam a água e permitem a formação de grandes quedas. Estas produzem força, que é utilizada para movimentar turbinas e acionar o gerador elétrico (PANZERA; GOMES; MOURA, 2010).

Porém, a energia hídrica também gera graves impactos ambientais negativos. Pois, influenciam diretamente no meio ambiente devido à construção de represas, que provocam inundações em imensas áreas de matas, interfere no fluxo de rios, destroem espécies vegetais, prejudica a fauna, e interfere na ocupação humana. Além dos pontos citados, as inundações das florestas fazem com que as plantas de cobertura do solo entrem em processo de decomposição, liberando uma quantidade prejudicial de metano na atmosfera. Sendo este, um dos gases responsáveis pelo efeito estufa e pela rarefação da camada de ozônio (QUEIROZ et al., 2013).

### 2.1.2 Consumo de energia elétrica no setor residencial

O setor residencial brasileiro apresenta uma alta dependência da rede de fornecimento, uma vez que 99,5% dos domicílios utilizam a energia elétrica proveniente das concessionárias, sendo apenas 0,12% do consumo gerado no próprio domicílio (ABRAHÃO; SOUZA, 2021).

De acordo com o gráfico exposto na Figura 2.2, o setor residencial é responsável por consumir cerca de 27,6% do total de energia elétrica produzida no país.




Figura 2.2 – Consumo de Energia Elétrica por Setor.

Fonte: Balanço Energético Nacional (BEN), 2021.

Apesar dos avanços em eficiência energética, esse consumo cresce a cada ano e leva a

uma preocupação dos impactos relacionados à segurança energética e à necessidade de ampliação da capacidade instalada. Tendo isso em vista, o monitoramento do consumo de energia nesse setor se torna uma ferramenta essencial para auxiliar no gerenciamento da energia.

### 2.1.3 Monitoramento do consumo de energia elétrica

Em uma rede elétrica residencial, os medidores inteligentes de eletricidade são usados para obter o consumo agregado total de energia e informações relacionadas a alguns intervalos diferentes de tempo. Todas as informações de consumo de energia em diferentes áreas da residência são coletadas pelos medidores inteligentes e transmitidas em tempo real para um banco de dados central, onde podem ser analisadas por um processo posterior. Essas informações são úteis para realizar previsões de demanda, conservação de energia, gerenciamento do lado da demanda, resposta a demanda e atividades semelhantes para operações de análise (ALI; BUCCELLA; CECATI, 2016).

Com a introdução de medidores inteligentes nas residências, os dados de consumo ficam disponíveis para análise. A partir do consumo agregado total de energia, é possível obter o consumo de energia de cada dispositivo separado e o padrão de uso de eletricidade de um consumidor. Assim, pode auxiliar no gerenciamento energético e na resposta de demanda do consumo, além de minimizar o uso de eletricidade e aumentar a eficiência na cadeia de abastecimento das concessionárias de eletricidade (DENT; AICKELIN; RODDEN, 2011).

### 2.1.4 Desagregação de energia

A desagregação de energia, também conhecida como Monitoramento de carga não intrusivo (NILM - *Non-intrusive load monitoring*), é a tarefa de usar um sinal de energia agregado, como aquele vindo de um monitor de energia, para fazer referências sobre as diferentes cargas individuais do sistema de uma residência (KOLTER; JOHNSON, 2011).

Para realizar o processo de desagregação de carga em uma residência como mostrado na Figura 2.3, os seguintes passos devem ser seguidos: Aquisição dos dados, Detecção dos eventos, Extração das características e Identificação dos equipamentos.

Para realizar a Aquisição dos dados, é preciso acessar as medições de energia coletadas da residência em uma taxa suficiente para detectar padrões de carga específicos. As grandezas elétricas podem ser obtidas por meio de monitoramento local ou banco de dados públicos. A taxa de amostragem das grandezas elétricas é realizada em baixa frequência, sendo necessárias na frequência de 1Hz as seguintes grandezas elétricas: tensão elétrica, potência ativa e potência reativa (MEDEIROS et al., 2019).

Já na etapa de Detecção dos eventos é necessário definir como um evento será considerado, para isso, é estabelecido o valor da potência ativa utilizada para definir a ocorrência de um evento e o instante de tempo da ocorrência do evento. A ocorrência de um evento é considerada quando



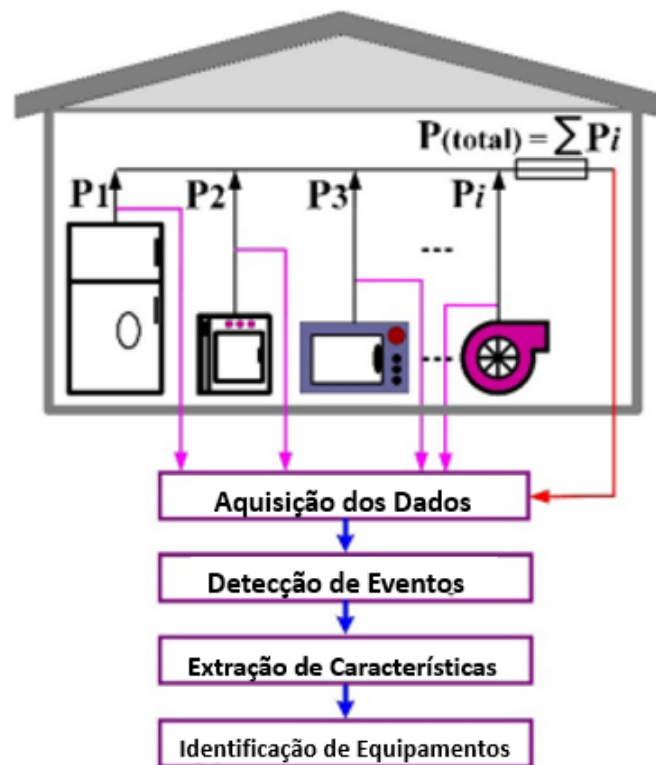


Figura 2.3 – Principais etapas da metodologia do sistema NILM.

Fonte: (MORADZADEH et al., 2021).

observada uma variação no valor da potência ativa da rede elétrica com amplitude maior que o limiar utilizado para definir um evento de ativação, ou com amplitude maior que o limiar utilizado para definir um evento de desativação. A variação no valor da potência ativa durante um evento é positiva para um evento de ativação ou negativa para um evento de desativação. Depois da detecção de um evento de ativação ou desativação, deve-se estabelecer os instantes de tempo em que houve o evento. Os instantes de tempo são utilizados na extração das assinaturas do perfil de consumo agregado da residência, onde os valores que compõem as assinaturas para cada eventos são obtidas a partir das variações dos valores de potência ativa e reativa na ocorrência de um evento de ativação e desativação (MEDEIROS et al., 2019).

A etapa de Extração de características visa obter do monitoramento agregado às características elétricas que permitem diferenciar cada carga elétrica das demais, estas características determinam as assinaturas dos aparelhos. As assinaturas baseadas em sinais amostrados em baixa frequência são normalmente construídas a partir da potência ativa, potência reativa, potência aparente ou valor eficaz da corrente elétrica. Este modo de assinatura é apontado como mais próximo de ser utilizada em aplicações práticas devido ao menor custo dos aparelhos de monitoramento (MEDEIROS et al., 2019). Selecionar um método ou algoritmo adequado para extrair os recursos e reconhecer os padrões do consumo de energia de cada aparelho elétrico a partir dos

dados totais registrados no medidor inteligente, é a escolha mais importante nesta etapa.

Depois de obter os padrões de consumo de energia de cada aparelho elétrico, identificar os tipos de aparelhos elétricos na residência é uma parte importante do processo. Quanto melhor for o processo de aprendizagem de características e reconhecimento de padrões, mais bem-sucedida será a operação de identificação.

### 2.1.5 Processo de descoberta de conhecimento

Em (CAMILO; SILVA, 2009), os autores afirmam que grandes volumes de dados são coletados diariamente em diversos setores por todo o mundo e a necessidade de analisar esses dados tornou-se cada vez maior. De acordo com (FAYYAD; PIATETSKY-SHAPIRO; SMYTH, 1996), os modelos tradicionais para transformar dados em informação (conhecimento), consiste em um processamento manual de toda essa informação. Que em grande parte das situações, torna-se impraticável devido ao grande volume de dados.

A Descoberta de Conhecimento em Bases de Dados (KDD - *Knowledge Discovery in Databases*) se refere ao processo geral de descoberta de conhecimento útil a partir de dados, e a mineração de dados se refere a uma etapa específica desse processo. A mineração de dados é a aplicação de algoritmos específicos para extrair padrões dos dados. No entanto, a aplicação cega de mineração de dados pode ser uma atividade perigosa, levando facilmente à descoberta de padrões sem sentido e inválidos (FAYYAD; PIATETSKY-SHAPIRO; SMYTH, 1996).

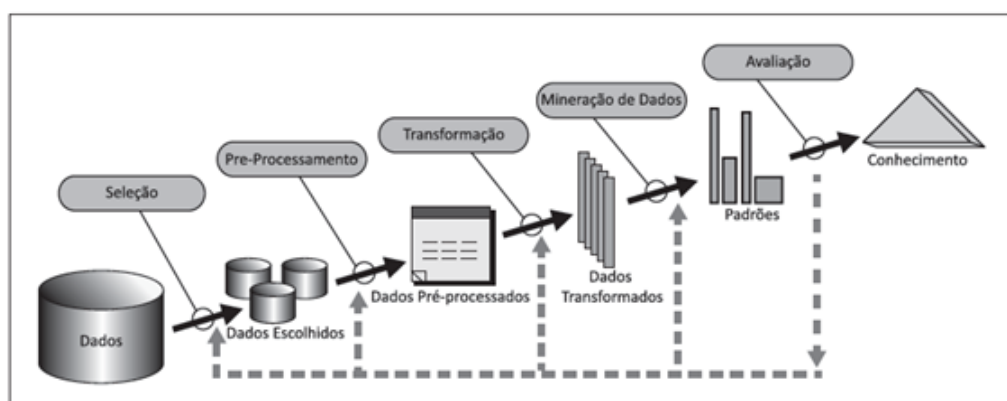


Figura 2.4 – Uma visão geral das etapas que compõem o processo KDD.

Fonte: (FAYYAD; PIATETSKY-SHAPIRO; SMYTH, 1996).

O processo de KDD é iterativo e iterativo, envolvendo várias etapas como muitas decisões tomadas pelo usuário, como apresentado na Figura 2.4. Algumas de suas etapas básicas são descritas a seguir:

A etapa de Seleção consiste em desenvolver uma compreensão do domínio da aplicação e do conhecimento prévio relevante, identificando o objetivo do processo KDD do ponto de vista do consumidor. Essa etapa também busca criar um conjunto de dados de destino, selecionando um

conjunto de dados ou um subconjunto de variáveis ou amostras de dados, nos quais a descoberta deve ser realizada.

A etapa de Pré-processamento inclui as operações básicas como a remoção de ruído, se apropriado, a coleta das informações necessárias para modelar ou contabilizar o ruído, a decisão sobre estratégias para lidar com dados ausentes e a contabilização das informações de sequência de tempo e mudanças conhecidas.

A etapa Transformação visa encontrar os recursos úteis para representar os dados dependendo do objetivo da tarefa. Com métodos de redução ou transformação de dimensionalidade, o número efetivo de variáveis em consideração pode ser reduzido ou representações invariáveis para os dados podem ser encontradas.

A etapa de Mineração de Dados consiste em combinar os objetivos do processo KDD (etapa Seleção) a um método de mineração de dados específico. Por exemplo, sumarização, classificação, regressão, agrupamento e assim por diante, bem como em (FAYYAD; PIATETSKY-SHAPIRO; SMYTH, 1996). A análise exploratória e a seleção de modelos e hipóteses, definem os algoritmos de mineração de dados e selecionam os métodos a serem usados para a busca de padrões de dados. Este processo inclui decidir quais modelos e parâmetros que podem ser apropriados e combinar um método de mineração de dados particular com os critérios gerais do processo KDD. A mineração de dados, busca por padrões de interesse em uma forma representacional específica ou um conjunto de tais representações, incluindo regras de classificação ou árvores, regressão e agrupamento. O usuário pode auxiliar significativamente o método de mineração de dados executando corretamente as etapas anteriores.

A etapa de Avaliação visa interpretar os padrões extraídos, possivelmente retornando a qualquer uma das etapas para iteração posterior. Esta etapa também pode envolver a visualização dos padrões e modelos extraídos ou visualização dos dados, dados os modelos extraídos. Com base na avaliação, o conhecimento descoberto pode ser diretamente incorporando ao conhecimento em outro sistema para ação posterior ou simplesmente documentado e relatado às partes interessadas.

## 2.1.6 Aprendizagem Profunda

Aprendizagem Profunda, ou Deep Learning, é uma sub-área da Aprendizagem de Máquina, que emprega algoritmos para processar dados e imitar o processamento feito pelo cérebro humano (Deep Learning Book, 2021).

Deep Learning usa camadas de neurônios matemáticos para processar dados, compreender a fala humana e reconhecer objetos visualmente. A informação é passada através de cada camada, com a saída da camada anterior fornecendo entrada para a próxima camada. A primeira camada em uma rede é chamada de camada de entrada, enquanto a última é chamada de camada de saída. Todas as camadas entre as duas são referidas como camadas ocultas. Cada camada é tipicamente um algoritmo simples e uniforme contendo um tipo de função de ativação (Deep Learning Book,

2021).




Figura 2.5 – Rede Neural Simples e Rede Neural Profunda (Deep Learning).

Fonte: (Deep Learning Book, 2021).

O aprendizado profundo é baseado no conceito de redes neurais artificiais, ou sistemas computacionais que imitam a maneira como o cérebro humano funciona como mostrado na Figura 2.5. A extração de recursos é outro aspecto da Aprendizagem Profunda, que usa um algoritmo para construir automaticamente “recursos” significativos dos dados para fins de treinamento, aprendizado e compreensão (Deep Learning Book, 2021).

### 2.1.7 Long Short Term Memory (LSTM)

Memória longa de curto prazo (LSTM - *Long short term memory*) é um tipo de rede neural recorrente (RNN - *Recurrent neural network*). Nos últimos anos, tem havido um incrível sucesso ao aplicar as RNNs a uma variedade de problemas: reconhecimento de fala, modelagem de idiomas, tradução, legendas de imagens. Entretanto, boa parte do sucesso das RNNs se deve a uma de suas variações, as LSTMs, um tipo muito especial de rede neural recorrente que funciona, para muitas tarefas, muito melhor do que a versão padrão. Quase todos os resultados empolgantes baseados em redes neurais recorrentes são alcançados com LSTMs (Deep Learning Book, 2022).

A LSTM é uma arquitetura da RNN que “lembra” valores em intervalos arbitrários. A LSTM é bem adequada para classificar, processar e prever séries temporais com intervalos de tempo de duração desconhecida. A insensibilidade relativa ao comprimento do gap dá uma vantagem à LSTM em relação a RNNs tradicionais (também chamadas “vanilla”), Modelos Ocultos de Markov (HMM - *Hidden Markov Models*) e outros métodos de aprendizado de sequências (Deep Learning Book, 2022).

A estrutura de uma RNN é muito semelhante ao HMM. No entanto, a principal diferença é como os parâmetros são calculados e construídos. Uma das vantagens da LSTM é a insensibilidade ao comprimento do gap. RNN e HMM dependem do estado oculto antes da emissão da sequência.

Se quisermos prever a sequência após 1.000 intervalos em vez de 10, o modelo esquece o ponto de partida até então. Mas um modelo LSTM é capaz de “lembrar” por conta de sua estrutura de células, sendo o diferencial da arquitetura LSTM (Deep Learning Book, 2022).

A LSTM possui uma estrutura em cadeia que contém quatro redes neurais e diferentes blocos de memória chamados células como mostrado na Figura 2.6. A informação é retida pelas células e as manipulações de memória são feitas pelos portões (Deep Learning Book, 2022).




Figura 2.6 – Unidade da Rede LSTM.

Fonte: (Deep Learning Book, 2022).

**Forget Gate:** As informações que não são mais úteis no estado da célula são removidas com o forget gate. Duas entradas:  $x_t$  (entrada no momento específico) e  $h_{t-1}$  (saída de célula anterior) são alimentadas ao gate e multiplicadas por matrizes de peso, seguidas pela adição do bias. O resultante é passado por uma função de ativação que fornece uma saída binária. Se para um determinado estado de célula a saída for 0, a informação é esquecida e para a saída 1, a informação é retida para uso futuro (Deep Learning Book, 2022).

**Input Gate:** A adição de informações úteis ao estado da célula é feita pelo input gate. Primeiro, a informação é regulada usando a função sigmoide que filtra os valores a serem lembrados de forma similar ao forget gate usando as entradas  $h_{t-1}$  e  $x_t$ . Então, um vetor é criado usando a função tanh que dá saída de -1 a +1, que contém todos os valores possíveis de  $h_{t-1}$  e  $x_t$ . Os valores do vetor e os valores regulados são multiplicados para obter as informações úteis (Deep Learning Book, 2022).

**Output Gate:** A tarefa de extrair informações úteis do estado da célula atual para ser apresentadas como uma saída é feita pelo output gate. Primeiro, um vetor é gerado aplicando a função tanh na célula. Então, a informação é regulada usando a função sigmoide que filtra os valores a serem lembrados usando as entradas  $h_{t-1}$  e  $x_t$ . Os valores do vetor e os valores regulados são multiplicados para serem enviados como uma saída e entrada para a próxima célula

(Deep Learning Book, 2022).

### 2.1.8 Descrição do Conjunto de dados REDD

O Conjunto de Dados de Desagregação de Energia de Referência (REDD - *Data Set for Energy Disaggregation Research*) consiste em vários agrupamentos de medidores de eletricidade, onde é possível agrupar os medidores por casa, pelo tipo de aparelho, pela taxa de amostragem e identificar se o medidor é um medidor local de toda casa ou um submedidor de nível de aparelho. Ao utilizar a ferramenta NILMTK, é possível identificar as principais classes do conjunto de dados e selecionar as variáveis que são mais importantes para realização deste trabalho.

A principal classe utilizada é a “MeterGroup”, que armazena uma lista de medidores e nos permite selecionar apenas o consumo de energia agregado total e as informações dos dispositivos presentes nas residências do conjunto.

Como mostrado na Figura 2.7, temos que as colunas se referem aos submedidores existentes na residência e as linhas ao período de tempo definido para a amostra. É possível observar também que os dois primeiros submedidores avaliam o consumo de energia medidos em toda a rede e o restante dos submedidores avaliam o consumo individual de cada aparelho.

	(1, 1, REDD)	(2, 1, REDD)	(5, 1, REDD)	(6, 1, REDD)	(7, 1, REDD)	(8, 1, REDD)	(9, 1, REDD)	(11, 1, REDD)	(12, 1, REDD)	(13, 1, REDD)	(14, 1, REDD)	(15, 1, REDD)	(16, 1, REDD)	(17, 1, REDD)	(18, 1, REDD)	(19, 1, REDD)	((3, 1, REDD), (4, 1, REDD))	R
2011-04-18 09:22:12-04:00	222.350006	118.820000	6.0	0.0	34.0	21.0	81.0	5.0	1.0	0.0	0.0	2.0	0.0	65.0	46.0	0.0	0.0	
2011-04-18 09:22:15-04:00	222.853333	119.120003	6.0	0.0	34.0	21.0	81.0	5.0	1.0	0.0	0.0	2.0	0.0	65.0	46.0	0.0	0.0	
2011-04-18 09:22:18-04:00	222.706665	118.976662	6.0	0.0	34.0	22.0	81.0	5.0	1.0	0.0	0.0	2.0	0.0	65.0	46.0	0.0	0.0	
2011-04-18 09:22:21-04:00	222.646667	119.150002	6.0	1.0	35.0	21.0	81.0	5.0	1.0	0.0	0.0	1.0	0.0	65.0	46.0	0.0	0.0	
2011-04-18 09:22:24-04:00	222.463333	118.866669	6.0	0.0	34.0	21.0	81.0	5.0	1.0	0.0	0.0	2.0	0.0	65.0	46.0	0.0	0.0	

Figura 2.7 – Visualização da classe MeterGroup.

## 2.2 Trabalhos Relacionados

Nesta seção são apresentados os trabalhos relacionados ao tema e os métodos mais utilizados na literatura para realizar a desagregação do consumo de energia de uma residência.

### 2.2.1 A Comprehensive Review on the NILM Algorithms for Energy Disaggregation

Como exposto por (VERMA et al., 2021) em seu trabalho, com o desenvolvimento da sociedade e o crescimento exponencial no consumo de energia no setor residencial a cada ano, o desafio da conservação de energia se torna ainda mais difícil.

Ele relata que há quase duas décadas, um método de desagregação de medidas elétricas foi proposto por (HART, 1992), que exigia apenas o exame dos dados gerais de carga para identificar assinaturas do consumo de energia de cada aparelho entre eles. A metodologia proposta não exigia a instalação de nenhum equipamento dentro da propriedade do cliente e, por isso, é considerada não intrusiva. Os dados agregados do consumo de energia podem ser obtidos de fora da residência usando o painel elétrico principal. A separação dos dados de consumo de toda a casa no consumo de cada dispositivos é o objetivo completo deste processo.

Os algoritmos NILM têm a capacidade de determinar a desagregação de energia específica do dispositivo usando apenas os dados agregados coletados de um único ponto de medição, a ideia por trás consiste em analisar o fluxo de energia para registrar as condições de operação dos aparelhos. O reconhecimento de uma mudança de degrau na potência ativa ou reativa da carga total é o princípio de trabalho para o monitoramento da carga. Portanto, o monitoramento de carga não intrusiva continua sendo um método atraente para a desagregação de energia.

Ao longo dos anos, algoritmos de processamento de sinal e aprendizado de máquina foram combinados e adaptados para realizar a desagregação de energia. Este artigo fornece um levantamento de algumas estruturas eficazes para o sistema NILM, como apresentado na Figura 2.8 e analisa o desempenho dos algoritmos de uma maneira abrangente.

Nesse trabalho, o método proposto utiliza uma abordagem baseada em cinco algoritmos de rede neural, dentre eles são o Denoising Autoencoder (DAE), Rede Neural Recorrente (RNN), Sequência para Sequência, Sequência para Ponto e Online GRU descritos a seguir.

O DAE consiste em estruturas neurais simplistas e compartilham semelhanças com a análise de componentes principais. Para seu uso em NILM, o sinal da rede elétrica foi tratado como um sinal de energia do aparelho ruidoso e o sinal da rede elétrica é considerado a soma da energia total consumida pelo aparelho alvo e algum ruído adicional. Como o DAE desativa um aparelho por vez, ele precisa de vários modelos treinados para que um grupo de aparelhos seja desagregado. O DAE obtém como entrada uma janela de tempo das leituras da rede e produz os valores de consumo induzido do aparelho para a mesma janela de tempo da saída.

A RNN consiste em um conjunto de algoritmos comumente usados para predição de séries temporais, processamento de linguagem natural e outras consultas de processamento de sequência. Ela funciona bem para dados sequenciais como no caso do NILM, pois permitem conexões de neurônios na mesma camada da rede neural. O modelo RNN empregado é alimentado com uma sequência de leituras da rede elétrica como entrada e produz um único valor de saída que



Figura 2.8 – Técnicas utilizadas para resolver o problema de desagregação de cargas elétricas.

Fonte: (VERMA et al., 2021).

dá a potência consumida pelo aparelho em teste. A rede também utiliza algumas unidades LSTM e armazena valores nas células de memória embutidas para superar o problema de gradientes de desaparecimento.

O modelo de aprendizado de sequência para sequência consiste em um conceito de aprendizado profundo usado para converter uma sequência para outra. Ele contém um codificador RNN para entender a sequência de entrada e um decodificador RNN para decodificar o vetor de pensamento, construindo assim uma sequência de saída. O modelo aqui tenta mapear a sequência de leitura da rede elétrica para a sequência do dispositivo de destino, aprendendo um mapa regressivo entre eles.

A aprendizagem de sequência para ponto opera modificando a entrada de rede recebida para funcionar como uma janela principal, enquanto a saída para o dispositivo de destino aparece funcionando no ponto médio de sua janela. O modelo acredita que o ponto médio do dispositivo de destino deve ser correlacionado com as informações do sinal de rede recebido, antes e depois do momento em que ele ocorre.

A Gated Recurrent Unit (GRU) é uma nova geração de Redes Neurais que substituem as unidades LSTM por GRU leves, reduzindo assim os requisitos computacionais ao mesmo tempo em que oferece desempenho equivalente. O modelo GRU online para NILM recebe como entrada, as leituras de rede mais recentes disponíveis do aparelho de teste e emite o consumo de energia calculado do aparelho no teste, para o último ponto no tempo.

Para avaliar os métodos propostos, em cada conjunto de dados a rede foi treinada por um período de 30 dias com base nos dados e testada nos 20 dias subsequentes para prever a energia



consumida por aparelho e relatar o erro absoluto médio em cada caso. No entanto, os resultados experimentais realizados em três conjuntos de dados disponíveis publicamente, denominados IAWE, REDD e UKdale, não indicam a presença de quaisquer padrões de saída. Isso pode ser resultado das grandes diferenças nos conjuntos de dados.

### **2.2.2 NILMTK: An Open Source Toolkit for Non-intrusive Load Monitoring**

De acordo com (BATRA et al., 2014), comparar empiricamente algoritmos de desagregação é uma tarefa complicada. Isso se deve aos diferentes conjuntos de dados usados, à falta de implementações de referência desses algoritmos e à variedade de métricas de precisão empregadas.

Nesse trabalho, é proposto o Kit de Ferramentas de Monitoramento de Carga Não-intrusiva (NILMTK - *Non-Intrusive Load Monitoring Toolkit*), um kit de ferramentas de código aberto projetado especificamente para permitir a comparação de algoritmos de desagregação de energia de maneira reproduzível. Este artigo apresenta e compara várias abordagens de desagregação em vários conjuntos de dados disponíveis publicamente.

O kit de ferramentas inclui analisadores para uma gama de conjuntos de dados existentes, uma coleção de algoritmos de pré-processamento, um conjunto de estatísticas para descrever conjuntos de dados, dois algoritmos de desagregação de benchmark de referência e um conjunto de métricas de avaliação. Ele demonstra também uma gama de análises reproduzíveis que são possíveis com o kit de ferramentas, incluindo a análise de seis conjuntos de dados disponíveis publicamente e a avaliação de ambos os algoritmos de desagregação de referência em tais conjuntos de dados.

O NILMTK foi projetado com dois casos de uso principais em mente. Em primeiro lugar, deve permitir a análise de conjuntos de dados e algoritmos existentes. Em segundo lugar, deve fornecer uma interface simples para a adição de novos conjuntos de dados e algoritmos.

Como resultado, o primeiro kit de ferramentas de código aberto permite que sejam feitas comparações empíricas entre algoritmos de desagregação de energia em vários conjuntos de dados. Ele define um formato comum para os dados, inclui analisadores para os seis conjuntos de dados, facilita ainda mais o cálculo das estatísticas e realiza o diagnóstico de problemas por meio de funções de pré-processamento.

Além disso, o kit de ferramentas inclui implementações de dois algoritmos de desagregação baseados em otimização combinatória e no Modelo Fatorial de Markov Oculto (FHMM - *Hidden Markov Factorial Model*). Ele também inclui implementações de um conjunto de métricas de desempenho que permite pesquisas futuras comparar diretamente as abordagens de desagregação por meio de um conjunto comum de medidas de precisão. Com isso, ele consegue auxiliar bastante em pesquisas futuras na desagregação de energia.

### 2.2.3 REDD: A Public Data Set for Energy Disaggregation Research

Segundo (KOLTER; JOHNSON, 2011), as questões de energia e sustentabilidade levantam um grande número de problemas que podem ser resolvidos usando abordagem de mineração de dados e aprendizado de máquina. No entanto, tais problemas tem uma grande dificuldade de serem resolvidos pela falta de dados publicamente disponíveis.

Este trabalho tem o intuito de disponibilizar publicamente uma base de dados denominada Conjunto de Dados de Desagregação de Energia de Referência (REDD - *Data Set for Energy Disaggregation Research*), contendo informações detalhadas sobre o uso de energia em seis residências dos EUA. Ele visa promover novas pesquisas sobre desagregação de energia.

A coleção usa um medidor de energia inteligente para coletar os dados, e contém leituras de energia de alta e baixa frequência de 6 residências nos EUA registradas por um período entre algumas semanas e alguns meses. Este conjunto de dados é amplamente utilizado para avaliação de algoritmos NILM. Com base no conjunto de dados apresentado, ele propõem um método para realizar a desagregação de energia utilizando a abordagem do FHMM. Na solução proposta, ele busca determinar o consumo individual de cada aparelho elétrico na residência com base na sequência total de energia consumida coletada pelos medidores inteligentes.

O FHMM é muito utilizado para trabalhar com series temporais e, pode ser considerado como um método de desagregação de energia. No FHMM, cada dispositivo ou circuito na residência é descrito por meio de um HMM. Cada dispositivo tem um estado oculto discreto, um estado de tempo e um estado interno do dispositivo (desligado ou ligado). A cada instante de tempo, dado o estado interno, o dispositivo emite uma potência distribuída gaussiana com parâmetros de média e variância específicos do estado. No entanto, observamos apenas a soma de todas as saídas de potência em cada momento.

A tarefa de desagregação foi enquadrada como um problema onde dada uma sequência observada de energia agregada, pretende-se calcular a probabilidade posterior dos consumos individuais do dispositivo. No FHMM proposto neste trabalho, a arquitetura foi construída conforme mostrado na Figura 2.9. Cada dispositivo tem um estado oculto discreto, denotado por  $x(i)$  que corresponde aproximadamente ao estado interno do dispositivo “desligado” ou “ligado”. E a cada período de tempo, dado o estado interno, o dispositivo emite uma potência distribuída gaussiana, denotada por  $y(i)$ , com parâmetros de média e variância específicos do estado.

No entanto, com os dados disponíveis no conjunto REDD apenas a soma de todas as saídas de potência em cada momento é observada. A tarefa de desagregação pode então ser enquadrada como um problema de inferência, dada uma sequência observada de energia agregada, pretendemos calcular a probabilidade posterior dos consumos individuais dos dispositivos.

Para construir o modelo a partir dos dados, é usado como entrada o consumo total de energia da rede medida na residência em um determinado período de tempo e é definido como alvo o consumo real dos dispositivos em um período de um mês com amostragem de 3s. Para




Figura 2.9 – Arquitetura do Modelo Fatorial de Markov Oculto.

Fonte: (KOLTER; JOHNSON, 2011).

treinar o modelo é usado o algoritmo Baum-Welch (EM) padrão, que encontra um modelo que melhor explica a sequência de observações. Utilizando a amostragem de Gibbs para gerar uma sequência de amostras com distribuição de probabilidades aleatórias, os estados ocultos de todas as cadeias menos uma são utilizados para prever a cadeia restante. Neste ponto, as amostras anteriores são retidas e o processo se repete até finalizar a combinação de estados ocultos.

Para avaliar o método, foi usado o tempo de duas semanas de dados e de cinco das casas em REDD. Nos experimentos apresentados, o método FHMM é capaz de desagregar razoavelmente bem. No entanto, há uma queda significativa na precisão ao passar de 71.5% na previsão de treinamento para 46.6% na previsão de teste, mas o método FHMM ainda funciona substancialmente melhor do que a previsão da média simples.

#### 2.2.4 Non-intrusive load monitoring algorithm based on household electricity use habits

De acordo com (YIN et al., 2021), a construção de redes inteligentes é uma tarefa importante para melhorar a taxa de utilização de energia elétrica em residências e, os métodos de decomposição de carga não intrusiva têm sido amplamente estudados para auxiliar nessa construção.

No entanto, os métodos de decomposição de carga não intrusiva são limitados pelo custo de transmissão e largura de banda da rede, onde os dados de baixa frequência têm sido amplamente utilizados em aplicações práticas. Ele ressalta neste trabalho que a precisão na identificação dos dispositivos neste caso enfrenta alguns desafios, como as características dos

dados de baixa frequência são relativamente únicas é difícil expressar o status operacional de aparelhos complexos, resultando em baixo desempenho na decomposição.

Nesse artigo, a decomposição de carga não intrusiva foi proposta utilizando uma combinação da abordagem do Modelo Fatorial de Markov Oculto (FHMM) com o Modelo de Hábitos de Eletricidade Doméstico, estudando a relação entre os hábitos de consumo de eletricidade e o método de decomposição do status da carga.

Ele utilizou o Modelo de Mistura Gaussiana (GMM - *Gaussian Mixture Model*) e informações de tempo para modelar a distribuição de probabilidade do estado do aparelho elétrico e, as distribuições de probabilidade obtidas são usadas como observações de entrada no modelo Markov. Dessa forma, ele propõe o Modelo Humano-Fatorial Markov Oculto (BH-FHMM - *Hidden Markov Human-Factor Model*) com uma melhoria significativa na precisão da decomposição de cargas elétricas dos equipamentos.

O BH-FHMM utiliza como base os hábitos de consumo de eletricidade dos usuários para melhorar a precisão da identificação dos métodos de decomposição de carga. Os hábitos de consumo doméstico de eletricidade são introduzidos como recursos adicionais para estender o conjunto de recursos de baixa frequência tradicional. Em seguida, o conjunto de dados resultante é fundido com as informações da série temporal e um GMM é usado para modelar a distribuição de probabilidade das informações da série temporal para aparelhos elétricos. Os valores médios de diferentes distribuições Gaussianas são usados como os valores de distribuição de carga para diferentes períodos de tempo para reduzir o erro entre a potência prevista e a potência real.

Para avaliar o método, foi utilizado a base de dados REDD e em cada família foram selecionados os cinco principais aparelhos elétricos do conjunto de treinamento e a média dos resultados dos índices para representar o índice de decomposição da família. Nos experimentos apresentados, o método BH-FHMM foi capaz de desagregar o consumo de energia muito bem com acurácia acima de 90% e, apresentou um desempenho de 1-3% maior do que o modelo FHMM tradicional.

### **2.2.5 A practical solution based on convolutional neural network for non-intrusive load monitoring**

Como exposto por (MORADZADEH et al., 2021), nos últimos anos a introdução de soluções práticas e úteis para resolver o problema de monitoramento de carga não intrusiva na gestão de energia tem colocado muitos desafios.

Neste trabalho, a decomposição de carga não intrusiva foi proposta utilizando uma abordagem baseada em aprendizado profundo denominada Rede Neural Convolutiva (CNN - *Convolutional Neural Network*). O método CNN é construído com uma estrutura camada a camada, extraindo as características de cada dispositivo nas curvas de consumo total de energia e, sendo capaz de detectar e distinguir os diferentes tipos de aparelhos elétricos na residência.

O CNN usado neste artigo consiste em uma camada de entrada, três camadas de convolução, três camadas máximas de pooling, uma camada totalmente conectada e uma camada classificadora. Desta forma, a desagregação de carga para o consumo de energia doméstico total é baseado na identificação dos padrões de consumo de cada dispositivo.

Ele utiliza o conjunto de dados REDD relacionado a dados do mundo real e medições em baixa frequência para realizar a avaliação experimental, já o consumo total de energia da residência é obtido por meio de um medidor inteligente e usado como entrada para cada rede a fim de desagregar a carga. O consumo de energia de um dia foi assumido como uma curva de consumo, e no total, oito curvas de consumo de energia de um dia de cada aparelho elétrico formavam a camada de entrada. As curvas de consumo de energia de cada dispositivo são usadas como dados de entrada para treinar e testar a rede e, após o treinamento inicial e os testes com os dados do consumo de energia dos dispositivos foi possível realizar a desagregação. Para avaliar o método proposto, dados da casa 1, casa 2, casa 3 e casa 4 do conjunto de dados REDD foram selecionados. As medições estão relacionadas a duas semanas com o período de amostragem de 1s e alguns eletrodomésticos com o período de amostragem de 3s. Nos experimentos apresentados, o método utilizando CNN é capaz de desagregar muito bem o consumo de energia de cada dispositivo, chegando a uma acurácia de 98,4% na previsão de treinamento e 97,06% na previsão de teste. Em comparação com o método FHMM utilizando a mesma base de dados, ele apresenta um desempenho superior.

## 3 Desenvolvimento

Neste capítulo, duas abordagens são descritas para resolver o problema NILM. Uma abordagem baseada no FHMM e outra baseada em uma rede LSTM. Para isso, foi realizado um pré processamento nos dados para a construção da etapa de treinamento e teste e posteriormente para as predições dos modelos, como descrito no decorrer das seções.

### 3.1 Ferramentas utilizadas na construção dos modelos

O desenvolvimento das abordagens propostas nesta pesquisa foram realizados utilizando a linguagem de programação Python. Também foi utilizada a ferramenta NILMTK, que fornece funções para análise do conjunto de dados REDD, e as bibliotecas Pandas, Numpy e Keras, que fornecem estruturas de dados e ferramentas de análise de alto desempenho. Para execução dos experimentos, foi utilizado um notebook Acer Aspire e5-571-56r0 com o sistema operacional Windows 10 de 64 bits e 12 gigas de RAM configurada no ambiente Anaconda.

### 3.2 Pré processamento

Na etapa de pré processamento, foram selecionados, como estudo de caso deste trabalho, apenas os dados de consumo da Casas 1 do conjunto de dados REDD, em um período de 22 dias, com amostragem de 1s. O consumo total da rede foi obtido nos dois primeiros medidores como mostrado na Figura 3.1 e o consumo real de cada dispositivo nos medidores subsequentes como mostrado na Figura 3.2. Com os dados de consumo total e real em mãos, foi realizado um tratamento nos mesmos para transformar os valores ausentes em zeros e renomear as colunas dos dispositivos para seus respectivos nomes reais. Após o tratamento dos dados, foi criado o conjunto de entrada para os modelos com as informações do consumo total da rede e o consumo real dos 16 dispositivos existentes na residência, como mostrado na Figura 3.3. Ainda como forma de ajuste dos dados, como a série temporal possui uma alta variabilidade, foi realizada uma normalização na escala de valor absoluto dos dados mantendo suas propriedades. Para isso, foi usada a função “Scaling” que de forma análoga normaliza os dados em uma escala entre 0 e 1.

### 3.3 Ajustes e configuração dos modelos

No ajuste dos modelos, foi definida uma função para criar um novo conjunto de dados que recebe três argumentos como referência. O “dataset de entrada”, que é uma matriz com o consumo total da residência em uma sequência de tempo, o “dataset de saída”, que é uma matriz com o consumo real dos dispositivos naquele instante de tempo, e a “janela”, que é o tamanho

```

consumo_total = mains.power_series_all_data()
consumo_total

Loading data for meter ElecMeterID(instance=2, building=1, dataset='REDD')
Done loading data all meters for this chunk.

2011-04-18 09:22:09-04:00    342.820007
2011-04-18 09:22:10-04:00    344.559998
2011-04-18 09:22:11-04:00    345.140015
2011-04-18 09:22:12-04:00    341.679993
2011-04-18 09:22:13-04:00    341.029999
...
2011-05-24 15:56:57-04:00    273.649994
2011-05-24 15:56:58-04:00    273.160004
2011-05-24 15:56:59-04:00    274.100006
2011-05-24 15:57:00-04:00    273.390015
2011-05-24 15:57:01-04:00    274.260010
Freq: S, Name: (power, apparent), Length: 3134093, dtype: float32
    
```

Figura 3.1 – Consumo total de energia na residência.

```

#os medidores que sinalizam os dispositivos
sub_mains = elec.submeters()
consumo_real = sub_mains.dataframe_of_meters()
consumo_real.head()

Loading data for meter ElecMeterID(instance=4, building=1, dataset='REDD')
Done loading data all meters for this chunk.
Loading data for meter ElecMeterID(instance=20, building=1, dataset='REDD')
Done loading data all meters for this chunk.
    
```

	(5, 1, REDD)	(6, 1, REDD)	(7, 1, REDD)	(8, 1, REDD)	(9, 1, REDD)	(11, 1, REDD)	(12, 1, REDD)	(13, 1, REDD)	(14, 1, REDD)	(15, 1, REDD)	(16, 1, REDD)	(17, 1, REDD)	(18, 1, REDD)	(19, 1, REDD)	((3, 1, REDD), (4, 1, REDD),)	((10, 1, REDD), (20, 1, REDD),)
2011-04-18 09:22:12-04:00	6.0	0.0	34.0	21.0	81.0	5.0	1.0	0.0	0.0	2.0	0.0	65.0	46.0	0.0	0.0	0.0
2011-04-18 09:22:15-04:00	6.0	0.0	34.0	21.0	81.0	5.0	1.0	0.0	0.0	2.0	0.0	65.0	46.0	0.0	0.0	0.0
2011-04-18 09:22:18-04:00	6.0	0.0	34.0	22.0	81.0	5.0	1.0	0.0	0.0	2.0	0.0	65.0	46.0	0.0	0.0	0.0
2011-04-18 09:22:21-04:00	6.0	1.0	35.0	21.0	81.0	5.0	1.0	0.0	0.0	1.0	0.0	65.0	46.0	0.0	0.0	0.0
2011-04-18 09:22:24-04:00	6.0	0.0	34.0	21.0	81.0	5.0	1.0	0.0	0.0	2.0	0.0	65.0	46.0	0.0	0.0	0.0

Figura 3.2 – Consumo real de energia dos dispositivos.

	fridge_1	dish washer_1	sockets_1	sockets_2	light_1	microwave_1	unknown_1	electric space heater_1	electric stove_1	sockets_3	...	sockets_3	dish washer_1	unknown_2
2011-04-20 00:00:00-04:00	6.0	0.0	20.0	22.0	81.0	4.0	1.0	0.0	0.0	1.0	...	0.0	0.0	0.0
2011-04-20 00:00:01-04:00	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.0	0.0
2011-04-20 00:00:02-04:00	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.0	0.0
2011-04-20 00:00:03-04:00	6.0	0.0	21.0	22.0	81.0	4.0	1.0	0.0	0.0	1.0	...	4.0	1.0	0.0
2011-04-20 00:00:04-04:00	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.0	0.0

Figura 3.3 – Conjunto de entrada com todas as medições.

da janela de tempo usada como entrada, nesse caso, ela foi definida como 60. Esse padrão foi usado para criar um conjunto de dados em que  $X$  contém os consumos totais até um determinado horário ( $t$ ) e  $Y$  é o consumo real de energia de cada dispositivo no horário ( $t$ ) determinado.

Com o conjunto de entrada e saída definidos para cada sequência de observação, foi realizada uma divisão nos dados em conjunto de treinamento e teste, para avaliar o desempenho dos modelos. Para isso, 70% das observações foram selecionadas para treinar o modelo e os 30% restantes para testar o modelo.

### 3.4 Arquitetura dos modelos

Na construção do modelo FHMM, alguns aspectos foram levados em consideração para definição da arquitetura conforme abordado na Subseção 2.2.3. Para a abordagem em questão, a arquitetura foi definida conforme mostrado na Figura 3.4, onde cada um dos dispositivos na casa é descrito por meio de um Modelo de Markov Oculto (HMM). Logo, seja  $\{Yt\} = \{Yt, t = 1, 2, \dots, 16\}$  a sequência de observações e  $\{Xt\} = \{Xt, t = 1, 2, \dots, 16\}$  a cadeia de Markov definida no espaço de estados  $\{e\} = \{1, 2\}$  sendo 1 “desligado” e 2 “ligado”, temos que suas histórias sejam respectivamente  $Yt^{(e)} = \{Yi^{(1)}, i = 1, 2, \dots, 16\}$  e  $\{Yi^{(2)}, i = 1, 2, \dots, 16\}$  e  $Xt^{(e)} = \{Xi^{(1)}, i = 1, 2, \dots, 16\}$  e  $\{Xi^{(2)}, i = 1, 2, \dots, 16\}$ . Com isso, a primeira camada foi definida criando um modelo de Markov oculto com emissões gaussianas para cada dispositivo, recebendo como parâmetro dois estados ocultos e uma covariância completa entre os estados. Posteriormente os modelos criados são combinados para formar o modelo fatorial de Markov oculto na segunda camada, recebendo como parâmetros o tamanho da distribuição inicial da ocupação do estado, uma covariância completa entre os estados, a distribuição inicial da ocupação do estado e a matriz de probabilidades de transição entre estados. A camada de saída corresponde a representação dos valores preditos como o consumo de eletricidade para cada um dos dispositivos no período de tempo informado.






Figura 3.4 – Arquitetura do modelo FHMM.

Fonte: (KOLTER; JOHNSON, 2011).

Na construção do modelo LSTM, foram levados em consideração alguns aspectos para definição da arquitetura conforme abordado na Subseção 2.1.7. Para a abordagem em questão, a arquitetura foi definida com seguindo uma estrutura em camadas conforme mostrado na Figura 3.5. A entrada corresponde as sequências de observações em uma janela de tempo de 60s, a primeira camada LSTM recebe como parâmetros 32 unidades como tamanho da saída desta camada, definindo à dimensão do vetor de estado oculto, uma função de ativação tangente hiperbólica para solucionar o nosso problema dos valores sendo todos do mesmo sinal, uma variável “input\_shape” que informa o tamanho da sequência observada igual a 60 observações, um “dropout” de 0.2 usado para prevenir o sobre-ajustamento na etapa de treino e a variável “return\_sequences”, que informa que a camada será usada como entrada para a próxima iteração. A segunda camada uma LSTM que recebe como parâmetros 16 unidades para o tamanho de saída, definindo à dimensão do vetor de estado oculto, uma função de ativação tangente hiperbólica para solucionar o nosso problema dos valores sendo todos do mesmo sinal e um “dropout” de 0.2 usado para prevenir o sobre-ajustamento. Uma camada Dense que informa a dimensionalidade da saída e foi definida com 16 unidades, definindo a dimensão da saída, que no caso é a quantidade de dispositivos existentes na casa, uma função de ativação Softmax para converter a saída em um vetor de probabilidades e, por fim, a camada de saída representado todos os dispositivos presentes na residência.



Figura 3.5 – Arquitetura do modelo LSTM.

### 3.5 Conjunto de dados de treinamento e teste

Na etapa de treinamento, os modelos foram ajustados para receber como entrada uma janela de tamanho 60 da sequência de observações do “consumo total” de energia da Casa 1 do conjunto de dados REDD, referente ao período de 18 de abril de 2011 a 03 de maio de 2011 totalizando 367973 observações, e como saída a sequência de observações no mesmo período do “consumo real” de energia para cada um dos 16 dispositivos presentes na Casa 1 conforme mostrado na Figura 3.6.

```
# definindo a janela de tempo e criando o conjunto de dados
janela = 60
entrada_original, saida_original = create_dataset(entrada, saida, janela)

#dividindo os dados em treino e teste
train_size = int(len(entrada_original) * 0.70)
test_size = len(entrada_original) - train_size
entrada_trainX, entrada_testX = entrada_original[0:train_size:], entrada_original[train_size:len(entrada_original),]
saida_trainY, saida_testY = saida_original[0:train_size:], saida_original[train_size:len(saida_original),]
```

```
entrada_trainX[0]
array([[341.68 , 342.21 , 341.81 , 341.28 , 341.86 , 341.53998,
        341.66 , 341.84 , 343.57 , 344.69 , 345.25 , 342.71 ,
        341.96 , 346.46 , 340.33002, 344.33002, 344.47 , 345.3 ,
        343.77 , 344.69 , 344.11 , 345.77 , 345.64 , 344.33002,
        346.47 , 344.72998, 346.39 , 344.46 , 346.85 , 345.37 ,
        345.97998, 347. , 345.46002, 346.15002, 346.65 , 346.79 ,
        349.16998, 348.99 , 344.06 , 348.22 , 345.51 , 344.12 ,
        346.36002, 344.41998, 344.6 , 344.78 , 344.23 , 344.99 ,
        345.18 , 345.88 , 343.38 , 344.13 , 345.12 , 342.61 ,
        343.55 , 343.27 , 342.05 , 342.97 , 343.16998, 342.99 ],
      dtype=float32)
```

```
saida_trainY[0]
array([[0.01749322, 0. , 0.10495933, 0.06997289, 0.23615849,
        0.01457768, 0.00291554, 0. , 0. , 0.00583107,
        0. , 0.1895099 , 0.1341147 , 0. , 0. ,
        0. , ], dtype=float32)
```

Figura 3.6 – Entrada e saída da etapa de treinamento.

Já para a etapa de teste, os modelos foram ajustados para receber como entrada uma janela de tamanho 60 da sequência de observações do “consumo total” de energia da Casa 1, referente ao período de 03 de maio de 2011 a 24 de maio de 2011 totalizando 157703 observações, e como saída a sequência de observações no mesmo período de tempo do “consumo real” de energia para cada um dos 16 dispositivos presentes na Casa 1 conforme mostrado na Figura 3.7.

Na abordagem FHMM, para treinar e testar o modelo, foram selecionados como entrada apenas cinco dos dispositivos descritos no início da seção. Em um primeiro momento para cada um dos dispositivos foi criado uma rede de Markov oculto e realizado um treinamento passando apenas o consumo total para estimar os parâmetros. Logo em seguida, os modelos foram combinados para gerar o modelo fatorial de markov oculto onde são informadas as probabilidades de transição de estado. Durante o processo foi possível observar o tempo gasto durante a etapa de treino e o dispositivo que está sendo treinado conforme mostrado na Figura 3.8.

Na abordagem LSTM, para treinar e testar o modelo, foram definidos os seguintes parâmetros: a camada de “entrada” e “saída” conforme descrito no início da seção, a quantidade

```
# definindo a janela de tempo e criando o conjunto de dados
janela = 60
entrada_original, saida_original = create_dataset(entrada, saida, janela)

#dividindo os dados em treino e teste
train_size = int(len(entrada_original) * 0.70)
test_size = len(entrada_original) - train_size
entrada_trainX, entrada_testX = entrada_original[0:train_size:], entrada_original[train_size:len(entrada_original),]
saida_trainY, saida_testY = saida_original[0:train_size:], saida_original[train_size:len(saida_original),]

entrada_testX[0]
array([[364.84 , 365.11002, 364.71002, 364.56 , 363.83002, 364.17 ,
        364.11 , 363.68 , 362.97 , 363.56 , 363.13 , 363.08002,
        363.58002, 363.34003, 362.46002, 363.11 , 362.7 , 362.65997,
        362.51 , 362.83 , 362.59 , 362.52 , 362.63998, 362.75 ,
        362.46 , 363.05002, 362.26 , 362.41 , 362.41 , 362.84 ,
        361.08 , 361.34 , 361.7 , 361.84998, 361.88998, 361.76 ,
        361.86002, 361.88 , 361.52 , 361.82 , 361.59003, 361.21997,
        362.37 , 360.45 , 361.19 , 361.58002, 361.34998, 360.86 ,
        362.12 , 361.25 , 362.3 , 363.41 , 360.92 , 362.36 ,
        360.3 , 361.05 , 361.35 , 360.25 , 362.43 , 362.38998],
      dtype=float32)

saida_testY[0]
array([[0.5353349 , 0. , 0.066227 , 0.05518916, 0.2235161 ,
        0.01103783, 0.00275946, 0. , 0.00275946,
        0. , 0.00275946, 0. , 0. ,
        0. ], dtype=float32)
```

Figura 3.7 – Entrada e saída da etapa de teste.

```
classifiers = {'FHMM':FHMM()}
predictions = {}
sample_period = 30
for clf_name, clf in classifiers.items():
    print(clf_name)
    start = time.time()
    clf.train(top_5_train_elec, sample_period=sample_period)
    end = time.time()
    print("Runtime =", end-start, "seconds.")

FHMM
Training model for submeter 'ElecMeter(instance=5, building=1, dataset='REDD', appliances=[Appliance(type='fridge', instance=1)])' with 3 states
Loading data for meter ElecMeterID(instance=20, building=1, dataset='REDD')
Done loading data all meters for this chunk.
Training model for submeter 'MeterGroup(meters=
  ElecMeter(instance=10, building=1, dataset='REDD', appliances=[Appliance(type='washer dryer', instance=1)])
  ElecMeter(instance=20, building=1, dataset='REDD', appliances=[Appliance(type='washer dryer', instance=1)])
)' with 3 states
Training model for submeter 'ElecMeter(instance=9, building=1, dataset='REDD', appliances=[Appliance(type='light', instance=1)])' with 3 states
Training model for submeter 'ElecMeter(instance=8, building=1, dataset='REDD', appliances=[Appliance(type='sockets', instance=2)])' with 3 states
Training model for submeter 'ElecMeter(instance=6, building=1, dataset='REDD', appliances=[Appliance(type='dish washer', instance=1)])' with 3 states
Runtime = 19.867944955825806 seconds.
```

Figura 3.8 – Treinamento do modelo FHMM.

de “épocas” que foi ajustada para 50 épocas de treino definida por meio da observação dos valores obtidos na variável “validation\_data”, que informa a perda obtida durante o treinamento e o teste indicando se houve um sobre ajuste nos dados e, o otimizador “Adam” usado para acelerar o algoritmo de descida do gradiente, devido a sua eficiência ao trabalhar com problemas envolvendo muitos parâmetros. Como mostrado na Figura 3.9, durante o processo de treinamento e teste foi possível acompanhar o tempo gasto e a perda obtidos a cada época.

```
history = model.fit(trainX_reshape, trainY_norm, epochs=50, validation_data=(testX_reshape, testY_norm),
                    verbose=2, shuffle=False)
11500/11500 - 56s - loss: 0.0067 - val_loss: 0.0068 - 56s/epoch - 5ms/step
Epoch 42/50
11500/11500 - 56s - loss: 0.0067 - val_loss: 0.0067 - 56s/epoch - 5ms/step
Epoch 43/50
11500/11500 - 57s - loss: 0.0067 - val_loss: 0.0067 - 57s/epoch - 5ms/step
Epoch 44/50
11500/11500 - 56s - loss: 0.0067 - val_loss: 0.0067 - 56s/epoch - 5ms/step
Epoch 45/50
11500/11500 - 56s - loss: 0.0067 - val_loss: 0.0067 - 56s/epoch - 5ms/step
Epoch 46/50
11500/11500 - 56s - loss: 0.0067 - val_loss: 0.0067 - 56s/epoch - 5ms/step
Epoch 47/50
11500/11500 - 59s - loss: 0.0067 - val_loss: 0.0067 - 59s/epoch - 5ms/step
Epoch 48/50
11500/11500 - 62s - loss: 0.0067 - val_loss: 0.0067 - 62s/epoch - 5ms/step
Epoch 49/50
11500/11500 - 63s - loss: 0.0067 - val_loss: 0.0067 - 63s/epoch - 6ms/step
Epoch 50/50
11500/11500 - 59s - loss: 0.0067 - val_loss: 0.0067 - 59s/epoch - 5ms/step
```

Figura 3.9 – Treinamento do modelo LSTM.

## 4 Resultados

Neste capítulo, são descritas as avaliações dos modelos e a análise dos resultados obtidos.

### 4.1 Métricas para avaliação das abordagens propostas

Para avaliar a eficácia dos modelos na previsão do consumo de eletricidade individual dos dispositivos na residência, foi usada a métrica da Raiz do Erro Quadrático Médio (RMSE - *Root Mean Squared Error*), que calcula a média de diferença entre o valor predito com o real e, para lidar com o problema da diferença entre unidades, é aplicada a raiz quadrática. Assim, a unidade fica na mesma escala que o dado original, resultando em uma melhor interpretabilidade do resultado da métrica. Desta maneira penalizando valores que sejam muito diferentes entre o previsto e o real. Portanto, quanto maior é o valor de RMSE, significa que o modelo não performou bem em relação as previsões. E a métrica do Coeficiente de determinação ( $R^2$ ), que representa o percentual da variância dos dados que é explicado pelo modelo, os resultados variam de 0 a 1 e geralmente também são expressos em termos percentuais, ou seja, variando entre 0% e 100%. Quanto maior é o valor de  $R^2$ , mais explicativo é o modelo em relação aos dados previstos. Foi usado também para avaliar os modelos a média, com o intuito de comparar os resultados obtidos na desagregação.

### 4.2 Resultados obtidos

Nesta seção são apresentados os resultados obtidos nos experimentos realizados após avaliar os modelos com a média e as métricas RMSE e  $R^2$ .

#### 4.2.1 Experimento usando o modelo FHMM

No experimento com a abordagem baseada no modelo FHMM, a métrica do RMSE foi usada para avaliar se o consumo predito pelo nosso modelo está próximos aos consumos reais de cada dispositivo. Com o intuito de tornar os experimentos possíveis para a proposta do trabalho, apenas cinco dispositivos foram selecionados para a criação dos modelos HMM e posteriormente combinados para criação do modelo FHMM, isto se deve ao elevado custo computacional envolvido na criação individual desses modelos. Conforme mostrado na Figura 4.1, observa-se que a abordagem proposta consegue desagregar o consumo individual dos dispositivos selecionados na residência com base apenas no consumo total informado. Entretanto, os valores obtidos com a métrica RMSE nos informa que os consumos preditos ainda possuem um erro alto em comparação ao consumo real da mesma sequência de tempo observada.

Erro RMSE	
Fridge	96.104636
Washer dryer	245.678844
Light	100.239687
Sockets	27.622803
Dish washer	216.839779

Figura 4.1 – RMSE obtido na desagregação do modelo FHMM.

### 4.2.2 Experimento usando o modelo LSTM

Para os experimentos realizados com a abordagem baseada na rede LSTM, a métrica do RMSE foi usada para avaliar se o consumo predito com o nosso modelo está próximo aos consumos reais de cada dispositivo presentes na residências. Com o intuito de melhorar os resultados obtidos a partir dos conhecimentos adquiridos na construção dos experimentos com a abordagem FHMM, no modelo LSTM foi realizada a análise de todos os dispositivos presentes na residência. Durante a realização dos experimentos, os hiper-parâmetros do modelo proposto foram ajustados e adaptados para o problema em questão de forma empírica e, para decidir qual a melhor quantidade de épocas para treinar o modelo, foi observado o gráfico da Figura 4.2. Observa-se que quando o valor da perda nos dados de validação começa a crescer e quando a acurácia nos dados de validação começa a decrescer.

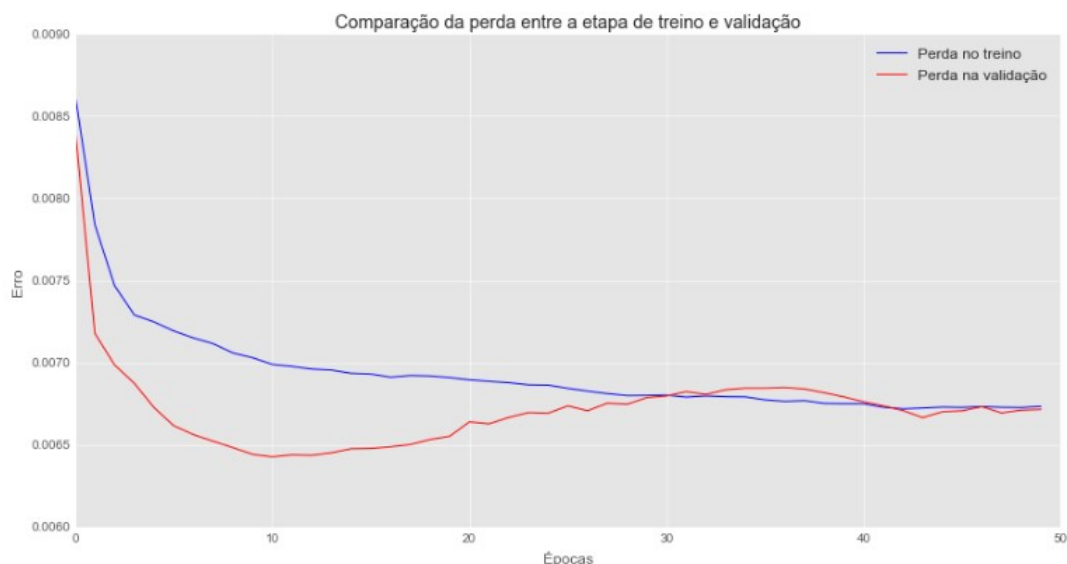


Figura 4.2 – Perda obtida na etapa de treino e validação com o modelo LSTM.

Analisando os resultados obtidos com a predição do modelo conforme mostrado no gráfico da Figura 4.3, foi possível observar que para cada um dos dispositivos na residência o modelo conseguiu prever o consumo real apresentando um erro baixo próximo de zero e,

durante a etapa de treinamento e teste o modelo consegue prever bem o consumo de alguns dispositivos como mostrado nas colunas “verde” e “vermelha”, mas ainda em alguns casos temos uma diferença nos valores preditos. Como forma de criar um *baseline* para comparar os resultados obtidos, foi criada a coluna “azul” que representa a desagregação de carga na base de teste, baseada na distribuição dos consumos de cada dispositivo, inferidas pelos consumos dos dispositivos no conjunto de treinamento e observa-se que, nos casos onde os dispositivos possuem um consumo próximo de zero, ela apresenta um melhor resultado do que o predito nas etapas de treino e teste.

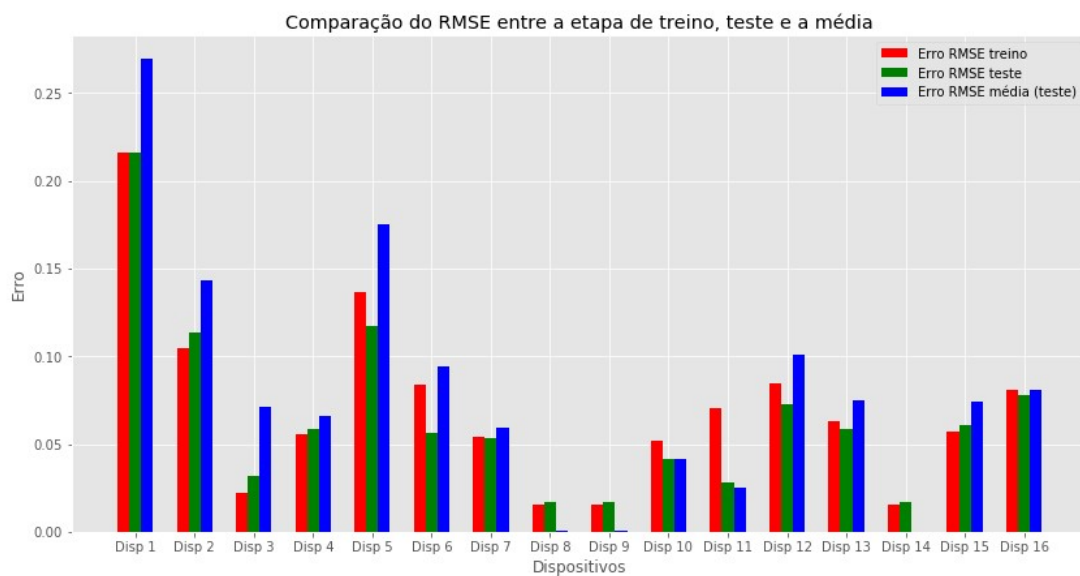


Figura 4.3 – RMSE obtido na desagregação com o modelo LSTM.

Como forma de visualizar e analisar os resultados em um período maior de tempo, foram selecionadas as medições do consumo real dos dispositivos, o consumo predito e a *baseline*, em um período de um dia. Como mostrado no gráfico da Figura 4.4, observa-se que os consumos preditos para cada um dos dispositivos está bem próximo ao seu consumo real, no entanto, ainda em alguns casos a predição apresenta um consumo diferente do real. Observa-se que a *baseline* consegue resultados mais próximos ao consumo real nos casos onde os dispositivos possuem um consumo de energia próximo de zero.




Figura 4.4 – Comparação entre o consumo real, consumo predito e a média do consumo em um dia.



# 5 Considerações Finais

Com os estudos realizados neste trabalho, foi possível ter uma melhor compreensão do problema de monitoramento e desagregação de cargas elétrica, bem como, visualizar duas diferentes abordagens que podem ser aplicadas para solucioná-lo.

## 5.1 Conclusão

Nesta pesquisa, duas técnicas de mineração de dados foram aplicadas para tentar resolver o problema de desagregação de cargas elétricas NILM. A primeira técnica segue uma abordagem baseada no Modelo Fatorial de Markov Oculto (FHMM), que faz o uso das observações dos estados ocultos para realizar a predição do consumo individual dos dispositivos e a segunda técnica segue uma abordagem baseada na rede Long Short Term Memory (LSTM), que faz o uso de uma janela de observações de tempo para realizar a predição do consumo individual dos dispositivos no tempo observado.

Com os resultados obtidos nos experimentos usando as métricas RMSE, foi possível observar que o problema de desagregação do consumo de energia individual dos dispositivos, tratado neste trabalho, pode ser realizado por meio dos modelos propostos, apresentando um erro baixo próximo de zero entre os valores preditos e os valores reais. Foi possível concluir com este trabalho, que as sequências de entrada medidas em um sinal agregado impactam diretamente na predição e comparação do resultados das abordagens e, a utilização de ferramentas e bases de dados públicas facilitam o pré-processamento e uso dos dados para realizar a desagregação do consumo de energia dos dispositivos. A aplicação das técnicas propostas nesta pesquisa para resolver o problema de desagregação de cargas não intrusivas busca fomentar e auxiliar novas pesquisas na área.

## 5.2 Trabalhos Futuros

Em trabalhos futuros, pretende-se realizar experimentos com todas as casas do conjunto REED, mostrando o desempenho das abordagens treinadas e avaliadas em cada casa separadamente, e avaliar também o desempenho do modelo quando treinado com dados de algumas casas e testado em uma casa diferente. Também pretende-se explorar novas abordagens e conjuntos de dados visando identificar técnicas que possam ser empregadas a diferentes conjunto de dados públicos.

# Referências

- ABRAHÃO, K. C. d. F. J.; SOUZA, R. G. V. d. Estimativa da evolução do uso final de energia elétrica no setor residencial do Brasil por região geográfica. *Ambiente Construído*, SciELO Brasil, v. 21, p. 383–408, 2021.
- ALI, U.; BUCCELLA, C.; CECATI, C. Households electricity consumption analysis with data mining techniques. In: IEEE. *IECON 2016-42nd Annual Conference of the IEEE Industrial Electronics Society*. [S.l.], 2016. p. 3966–3971.
- BATRA, N.; KELLY, J.; PARSON, O.; DUTTA, H.; KNOTTENBELT, W.; ROGERS, A.; SINGH, A.; SRIVASTAVA, M. Nilmtk: An open source toolkit for non-intrusive load monitoring. In: *Proceedings of the 5th international conference on Future energy systems*. [S.l.: s.n.], 2014. p. 265–276.
- CAMILO, C. O.; SILVA, J. C. d. Mineração de dados: Conceitos, tarefas, métodos e ferramentas. *Universidade Federal de Goiás (UFG)*, v. 1, n. 1, p. 1–29, 2009.
- CAMPAGNANI, M. C. *ANÁLISE DA EXPANSÃO DO MERCADO LIVRE DE ENERGIA NO BRASIL INCLUINDO MERCADO VAREJISTA*. Tese (Doutorado) — Universidade Federal do Rio de Janeiro, 2021.
- CCEE. *Redução Voluntária de Demanda*. 2021. Disponível em: <[https://www.ccee.org.br/portal/faces/pages\\_publico/o-que-fazemos/resposta\\_demanda?\\_afzLoop=770731537785078&\\_adf.ctrl-state=uj707ztk\\_1#!%40%40%3F\\_afzLoop%3D770731537785078%26\\_adf.ctrl-state%3Duj707ztk\\_5](https://www.ccee.org.br/portal/faces/pages_publico/o-que-fazemos/resposta_demanda?_afzLoop=770731537785078&_adf.ctrl-state=uj707ztk_1#!%40%40%3F_afzLoop%3D770731537785078%26_adf.ctrl-state%3Duj707ztk_5)>. Acesso em: 30 setembro 2021.
- Deep Learning Book. *O Que São Redes Neurais Artificiais Profundas ou Deep Learning*. 2021. Disponível em: <<https://www.deeplearningbook.com.br/o-que-sao-redes-neurais-artificiais-profundas/#:~:text=Aprendizagem%20Profunda%20ou%20Deep%20Learning,processamento%20feito%20pelo%20c%3%A9rebro%20humano>>. Acesso em: 20 novembro 2022.
- Deep Learning Book. *Arquitetura de Redes Neurais Long Short Term Memory LSTM*. 2022. Disponível em: <<https://www.deeplearningbook.com.br/arquitetura-de-redes-neurais-long-short-term-memory/>>. Acesso em: 20 novembro 2022.
- DENT, I.; AICKELIN, U.; RODDEN, T. The application of a data mining framework to energy usage profiling in domestic residences using UK data. *Available at SSRN 2829282*, 2011.
- DUTRA, J.; FIGER, V. Emergência hídrica e restrições de oferta. *Revista Conjuntura Econômica*, v. 75, n. 07, p. 44–46, 2021.
- FAYYAD, U.; PIATETSKY-SHAPIRO, G.; SMYTH, P. From data mining to knowledge discovery in databases. *AI magazine*, v. 17, n. 3, p. 37–37, 1996.
- HART, G. Nonintrusive appliance load monitoring. *Proceedings of the IEEE*, v. 80, n. 12, p. 1870–1891, 1992.

- KOLTER, J. Z.; JOHNSON, M. J. Redd: A public data set for energy disaggregation research. In: *Workshop on data mining applications in sustainability (SIGKDD)*, San Diego, CA. [S.l.: s.n.], 2011. v. 25, n. Citeseer, p. 59–62.
- MEDEIROS, A. P. et al. Classificação de eventos em monitoramento nilm de cargas elétricas residenciais utilizando rede neural convolucional. Universidade Federal de Santa Maria, 2019.
- MORADZADEH, A.; MOHAMMADI-IVATLOO, B.; ABAPOUR, M.; ANVARI-MOGHADDAM, A.; FARKOUSH, S. G.; RHEE, S.-B. A practical solution based on convolutional neural network for non-intrusive load monitoring. *Journal of Ambient Intelligence and Humanized Computing*, Springer, p. 1–15, 2021.
- PANZERA, A.; GOMES, A.; MOURA, D. Impactos ambientais da produção de energia elétrica. *Minas Gerais, Brasil: Centro de Referência Virtual do Professor, SEE*, 2010.
- QUEIROZ, R. de; GRASSI, P.; LAZZARE, K.; KOPPE, E.; TARTAS, B. R.; KEMERICH, P. D. da C. Geração de energia elétrica através da energia hidráulica e seus impactos ambientais. In: *Revista eletrônica em gestão, educação e tecnologia ambiental*. [S.l.]: Universidad federal de santa maria, 2013. v. 13, n. 13, p. 2774–2784.
- VERMA, A.; ANWAR, A.; MAHMUD, M.; AHMED, M.; KOUZANI, A. A comprehensive review on the nilm algorithms for energy disaggregation. *arXiv preprint arXiv:2102.12578*, 2021.
- YIN, B.; LI, Z.; XU, J.; LI, L.; YANG, X.; DU, Z. Non-intrusive load monitoring algorithm based on household electricity use habits. *Neural Computing and Applications*, Springer, p. 1–19, 2021.