UNIVERSIDADE ESTADUAL PAULISTA - UNESP

Faculdade de Engenharia e Ciências - campus de Guaratinguetá

LUCAS FURTADO RODRIGUES

ESTIMAÇÃO DE CURVAS DE CARGA DE UNIDADES CONSUMIDORAS RESIDENCIAIS:

uma abordagem utilizando sistemas de inferência *fuzzy* tipo-1, *fuzzy* tipo-2 intervalar e neuro-*fuzzy*

Guaratinguetá

2025

LUCAS FURTADO RODRIGUES

ESTIMAÇÃO DE CURVAS DE CARGA DE UNIDADES CONSUMIDORAS RESIDENCIAIS:

uma abordagem utilizando sistemas de inferência *fuzzy* tipo-1, *fuzzy* tipo-2 intervalar e neuro-*fuzzy*

Dissertação, apresentada à Universidade Estadual Paulista (UNESP), Faculdade de Engenharia e Ciências , Guaratinguetá, para obtenção do título de Mestre em Engenharia.

Área de Concentração: Produção

Orientador: Profª Dra. Paloma Maria Silva Rocha Rizol

Guaratinguetá

2025

Rodrigues, Lucas Furtado
R696e Estimação de curvas de carga de unidades consumidoras residenciais: uma abordagem utilizando sistemas de inferência fuzzy tipo-1, fuzzy tipo-2 intervalar e Neuro-fuzzy / Lucas Furtado Rodrigues - Guaratinguetá, 2025.
77 f : il.
Bibliografia: f. 71-75

Dissertação (Mestrado) – Universidade Estadual Paulista, Faculdade de Engenharia e Ciências de Guaratinguetá, 2025.

Orientadora: Profª. Drª. Paloma Maria Silva Rocha Rizol

1. Energia elétrica - Consumo. 2. Lógica fuzzy.
3. Redes inteligentes de energia. 4. Medidores elétricos
I. Título.

CDU 620.92(043)

Luciana Máximo
Bibliotecária/CRB-8 3595

IMPACTO POTENCIAL DESTA PESQUISA

Esta pesquisa traz um impacto ao contribuir com o avanço dos modelos de estimativa de consumo de energia elétrica residencial, podendo, favorecer o planejamento do sistema elétrico, subsidiar programas de eficiência energética e contribuir na formação de cidadãos mais conscientes com a sustentabilidade e responsabilidade socioambiental.

POTENTIAL IMPACT OF THIS RESEARCH

This research has an impact by contributing to the advancement of residential electricity consumption estimation models, which can facilitate electrical system planning, support energy efficiency programs, and contribute to the development of citizens who are more aware of sustainability and social and environmental responsibility.

LUCAS FURTADO RODRIGUES

Estimação de curvas de carga de unidades consumidoras residenciais: Uma abordagem com sistemas de inferência fuzzy tipo-1, fuzzy tipo-2 intervalar e Neuro-Fuzzy.

Dissertação apresentada à Universidade Estadual Paulista (UNESP), Faculdade de Engenharia e Ciências de Guaratinguetá, para obtenção do título de Mestre em Engenharia

Data da defesa: 08/12/2025

Banca Examinadora:

gov.br
Documento assinado digitalmente
PALOMA MARIA SILVA ROCHA RIZOL
Data: 09/12/2025 12:04:03-0300
Verifique em https://validar.iti.gov.br

Profa. Dra. PALOMA MARIA SILVA ROCHA RIZOL

Orientador - UNESP

gov.br
Documento assinado digitalmente
RUBENS ALVES DIAS
Data: 09/12/2025 13:53:03-0300
Verifique em https://validar.iti.gov.br

Prof. Dr. RUBENS ALVES DIAS

UNESP

gov.br
Documento assinado digitalmente
JOSE ARNALDO FRUTUOSO ROVEDA
Data: 09/12/2025 16:47:50-0300
Verifique em https://validar.iti.gov.br

Prof. Dr. JOSE ARNALDO FRUTUOSO ROVEDA

UNESP

Dedico este trabalho à minha família.

AGRADECIMENTOS

Agradeço primeiramente à Deus, que me deu saúde e a oportunidade de realizar este trabalho, colocando pessoas maravilhoas durante todo o caminho percorrido.

À minha filha e minha esposa, cujo amor e compreensão foram fundamentais para a realização deste trabalho, as quais estiveram presentes desde o início dessa jornada. O apoio nos momentos difíceis foi uma fonte de motivação e equilíbrio durante todo o percurso.

Aos meus pais, que sempre foram minha base e meu porto seguro. Este trabalho é, em grande parte, fruto do exemplo de valores e determinação que recebi de vocês. A orientação, os valores e os exemplos de integridade transmitidos ao longo de minha vida foram determinantes para que esta etapa fosse alcançada.

À orientadora, profª Dra. Paloma Maria Silva Rocha Rizol, cuja orientação, conhecimento e dedicação foram fundamentais para o desenvolvimento deste trabalho. Orientação esta que não foi apenas acadêmica, mas também valiosos aprendizados de vida. Sou grato pela confiança em mim depositada e pelo tempo dedicado ao acompanhamento e aprimoramento de cada etapa deste processo.

Aos meus avós, por me incentivarem, muitas vezes sem nem mesmo saber, a seguir o caminho da engenharia, pelos exemplos de honestidade e trabalho. Agradeço por me ensinarem muita coisa, algumas das quais só consigo compreender nos dias de hoje.

Agradeço aos amigos e professores que fizeram parte da minha trajetória ao longo de toda a vida e aos que ainda estão presentes. A cada um, deixo meu reconhecimento pelo incentivo, pelas trocas de conhecimento, pelas conversas informais e pelos momentos de distração que contribuíram para a construção deste percurso.

“Intelligence is the ability to adapt to change.”
(Stephen Hawking)

RESUMO

Durante as últimas décadas, o consumo de energia elétrica no setor residencial vem aumentando e diferentes tipos de cargas vem sendo utilizadas, aliando isso com o avanço das tecnologias, o comportamento do consumidor tem se alterado, ficando evidenciado que cada vez mais a importância do aperfeiçoamento dos modelos de consumo de energia elétrica de unidades consumidoras residenciais, visando incorporar as mudanças de hábito e as incertezas do consumidor. O presente trabalho propõe a utilização de sistemas de inferência *fuzzy* tipo-1, *fuzzy* tipo-2 intervalar e *fuzzy* baseado em redes adaptativas para a estimativa do consumo de energia elétrica de unidades residenciais, considerando fatores comportamentais do consumidor, climáticos e socioeconômicos. O conjunto de dados utilizado para modelagem e validação possui 2073 amostras de consumo horário coletados da Pesquisa de Posse e Hábitos de Uso de equipamentos elétricos na classe residencial 2019, elaborada por meio do Programa Nacional de Conservação de Energia Elétrica – Procel. Os modelos foram implementados utilizando a linguagem de programação *Python*, sendo uma alternativa gratuita ao *software* MatLab. Os resultados foram avaliados pelo erro absoluto médio, erro percentual absoluto médio, erro quadrático médio e pela raiz do erro quadrático médio. Os modelos desenvolvidos apresentaram bons resultados e conseguiram correlacionar os aspectos climáticos, econômicos-sociais e comportamentais humano para a estimação do consumo de energia elétrica em unidades consumidoras residenciais, sendo que o modelo utilizando sistema de inferência *fuzzy* baseado em redes adaptativas obteve o melhor resultado.

Palavras-Chave: consumo de energia residencial; lógica *fuzzy*; sistema de inferência *fuzzy* tipo-1; sistema de inferência *fuzzy* tipo-2 intervalar; sistema *fuzzy* baseado em redes adaptativas.

ABSTRACT

Over the last few decades, electricity consumption in the residential sector has been increasing and different types of loads have been used. Combined with advances in technology, consumer behavior has changed, making it increasingly important to improve models of electricity consumption in residential consumer units, in order to incorporate changes in habits and consumer uncertainties. This work proposes the use of type-1 fuzzy inference systems, interval type-2 fuzzy inference systems and adaptive-networks-based fuzzy inference systems to estimate the electricity consumption of residential units, taking into account consumer behavior, climate and socioeconomic factors. The data set used for modeling and validation has 2073 hourly consumption samples that were collected from the 2019 survey of ownership and habits of use of electrical equipment in the residential class, prepared through the National Electric Energy Conservation Program - Procel. The models were implemented using the Python programming language, which is a free alternative to the software MatLab. The results were evaluated by mean absolute error, mean absolute percentage error, mean square error and root mean square error. The developed models showed good results and were able to correlate climatic, socioeconomic, and behavioral aspects to estimate electricity consumption in residential units. The adaptive-networks-based fuzzy inference system model obtained the best results.

Keywords: residential energy consumption; fuzzy logic; type-1 fuzzy inference system; interval type-2 fuzzy inference system; Adaptive-Networks-Based Fuzzy Inference Systems.

LISTA DE ILUSTRAÇÕES

Figura 1 Histórico do consumo mensal de energia elétrica 15
Figura 2 Parcela de consumo dos setores 16
Figura 3 Taxa de crescimento do consumo de energia elétrica para o ano de 2024, em relação ao ano de 2023 17
Figura 4 Taxa de crescimento anual do consumo de energia elétrica do setor residencial 17
Figura 5 Interações com relação ao consumo de energia elétrica do setor residencial 18
Figura 6 Métodos *top-down* e *bottom-up* para a estimativa de consumo de energia . 21
Figura 7 Publicações por ano 22
Figura 8 Publicações por país 22
Figura 9 Publicações por ano incluindo o termo *fuzzy* 25
Figura 10 Co-ocorrências de palavras chaves entre as publicações 26
Figura 11 Diagrama de blocos de um T1FIS 29
Figura 12 Função de pertinência triangular com adição de uma FOU 30
Figura 13 Diagrama de blocos de um IT2FIS 30
Figura 14 Arquitetura ANFIS 32
Figura 15 Classificação da Pesquisa 39
Figura 16 Fluxograma das etapas da pesquisa 41
Figura 17 Tela do PPH 2019 WEB 43
Figura 18 Tela da curva de carga para a região sudeste 43
Figura 19 Tela da curva de carga para a região sudeste em formato de tabela 44
Figura 20 Consumo de energia elétrica por hora no ano de 2019, por classe social e por mês 44
Figura 21 Dados de temperatura com possíveis *outliers* 46
Figura 22 Dados de temperatura com a exclusão dos *outliers* 46
Figura 23 Funções de pertinência triangular e trapezoidal 49
Figura 24 Funções de pertinência do modelo T1FIS para a entrada “renda familiar” . 50
Figura 25 Funções de pertinência do modelo T1FIS para a entrada “temperatura” . . 51
Figura 26 Funções de pertinência do modelo T1FIS para a entrada “horário” 52
Figura 27 Funções de pertinência do modelo T1FIS para a saída “consumo de energia” 53
Figura 28 Funções de pertinência do modelo IT2FIS para a entrada “renda familiar” 57
Figura 29 Funções de pertinência do modelo IT2FIS para a entrada “temperatura” . 58
Figura 30 Funções de pertinência do modelo IT2FIS para a entrada “horário” 59
Figura 31 Funções de pertinência do modelo IT2FIS para a saída “consumo de energia” 61
Figura 32 Valores esperados *vs* valores estimados para modelo T1FIS-1 63
Figura 33 Valores esperados *vs* valores estimados para modelo IT2FIS 65

Figura 34 Valores esperados *vs* valores estimados para modelo ANFIS (dados de treinamento) 68
Figura 35 Valores esperados *vs* valores estimados para modelo ANFIS (dados de validação) 68
Figura 36 Valores esperados *vs* valores estimados para modelo IT2FIS 69

LISTA DE TABELAS

Tabela 1 – Principais funções do módulo *fuzz.membership* 35
Tabela 2 – Métodos de defuzificação do módulo *skfuzzy.defuzz* 36
Tabela 3 – Funções do módulo de controle *skfuzzy.control* 36
Tabela 4 – Principais classes da biblioteca *pyit2fls* 36
Tabela 5 – Principais métodos da classe IT2Mamdani 37
Tabela 6 – Principais funções e métodos da biblioteca *lazuardy_anfis* 38
Tabela 7 – Parâmetros de classificação do modelo T1FIS para a entrada “classe social” 50
Tabela 8 – Parâmetros de classificação do modelo T1FIS para a entrada “temperatura” . 51
Tabela 9 – Parâmetros de classificação do modelo T1FIS para a entrada “horário” . . . 52
Tabela 10 – Parâmetros de classificação do modelo T1FIS para a saída “consumo de energia” 53
Tabela 11 – Base de Regras 54
Tabela 12 – Parâmetros de classificação do modelo IT2FIS para a entrada “renda familiar” 57
Tabela 13 – Parâmetros de classificação do modelo IT2FIS para a entrada “temperatura” 58
Tabela 14 – Parâmetros de classificação do modelo IT2FIS para a entrada “horário” . . . 59
Tabela 15 – Parâmetros de classificação do modelo IT2FIS para a saída “consumo de energia” 60
Tabela 16 – Detalhes dos modelos T1FIS testados 64
Tabela 17 – Resultados das métricas de avaliação dos modelos T1FIS 64
Tabela 18 – Detalhes dos modelos IT2FIS testados 66
Tabela 19 – Resultados das métricas de avaliação dos modelos IT2FIS 66
Tabela 20 – Resultados das métricas de avaliação do modelo ANFIS 67
Tabela 21 – Resultados das métricas de avaliação do modelo ANFIS 69

LISTA DE ABREVIATURAS E SIGLAS

ANFIS	Sistema de Inferência Neuro-*Fuzzy* Adaptativo, do inglês *Adaptive Neuro-Fuzzy Inference System*
FOU	Mancha de Incerteza, do inglês *Footprint Of Uncertainty*
GLD	Gerenciamento pelo Lado da Demanda
GA-ANFIS	Sistema de Inferência Fuzzy baseado em Redes Adaptativas utilizando Algoritmos Genético, do inglês *Genetic Algorithm - Adaptive Neuro-Fuzzy Inference System*
INMET	Instituto Nacional de Metereologia
IT2FIS	Sistema de Inferência *Fuzzy* Tipo-2 Intervalar, do inglês *Interval Type-2 Fuzzy Inference System*
KM	Karnick-Mendel
LMF	Função de Pertinência Inferior, do inglês *Lower Membership Function*
MAE	Erro Absoluto Médio, do inglês *Mean Absolute Error*
MAPE	Erro Absoluto Médio Percentual, do inglês *Mean Absolute Percentage Error*
MSE	Erro Quadrático Médio, do inglês *Mean Squared Error*
PIB	Produto Interno Bruto
Procel	Programa Nacional de Conservação de Energia Elétrica
RMSE	Raíz Quadrada do Erro Quadrático Médio, do inglês *Root Mean Squared Error*
RNAs	Redes Neurais Artificiais
SAE	*Statistically Adjusted Engineering*
T1FIS	Sistema de Inferência *Fuzzy* Tipo-1, do inglês *Type-1 Fuzzy Inference System*
TUS	Pesquisa de Uso do Tempo, do inglês *Time Use Survey*
UMF	Função de Pertinência Superior, do inglês *Upper Membership Function*

SUMÁRIO

1 INTRODUÇÃO 15
1.1 CONTEXTUALIZAÇÃO DA PESQUISA 15
1.2 OBJETIVOS 19
1.3 JUSTIFICATIVA E RELEVÂNCIA 19
1.4 DELIMITAÇÃO DA PESQUISA 27
1.5 ORGANIZAÇÃO DO TRABALHO 27

2 REFERENCIAL TEÓRICO 28
2.1 SISTEMA DE INFERÊNCIA *FUZZY* TIPO-1 28
2.2 SISTEMA DE INFERÊNCIA *FUZZY* TIPO-2 INTERVALAR 29
2.3 SISTEMA DE INFERÊNCIA NEURO-*FUZZY* ADAPTATIVO 31
2.4 MÉTRICAS DE AVALIAÇÃO 33
2.4.1 Erro Médio Absoluto (MAE) 33
2.4.2 Erro Médio Quadrático (MSE) 33
2.4.3 Raíz Quadrada do Erro Quadrático Médio (RMSE) 34
2.4.4 Erro Absoluto Médio Percentual (MAPE) 34
2.5 SISTEMAS DE INFERÊNCIA *FUZZY* UTILIZANDO *PYTHON* 34
2.5.1 Biblioteca *skfuzzy* 35
2.5.2 Biblioteca *pyit2fls* 36
2.6 Biblioteca *lazuardy_anfis* 37

3 MATERIAL E MÉTODO 39
3.1 CLASSIFICAÇÃO DA PESQUISA 39
3.2 LOCAL DE ESTUDO 40
3.3 ETAPAS DA PESQUISA 40
3.3.1 Aquisição de dados 40
3.3.1.1 Dados de consumo e curva de carga 42
3.3.1.2 Dados de temperatura 44
3.3.2 Pré-processamento dos dados 45
3.3.3 Modelagem 47
3.3.3.1 Modelo T1FIS 47
3.3.3.1.1 Renda Familiar 49
3.3.3.1.2 Temperatura 50
3.3.3.1.3 Horário 51
3.3.3.1.4 Consumo de Energia 52
3.3.3.1.5 Base de regras e validação 53

3.3.3.2 Modelo IT2FIS 56
3.3.3.2.1 Renda Familiar *56*
3.3.3.2.2 Temperatura *57*
3.3.3.2.3 Horário *58*
3.3.3.2.4 Consumo de energia *59*
3.3.3.2.5 Base de regras e simulação *61*
3.3.4 Modelo ANFIS **61**

4 RESULTADOS E DISCUSSÕES **63**
4.1 MODELO T1FIS 63
4.2 MODELO IT2FIS 64
4.3 MODELO ANFIS 67

5 CONCLUSÕES **70**

REFERÊNCIAS **71**

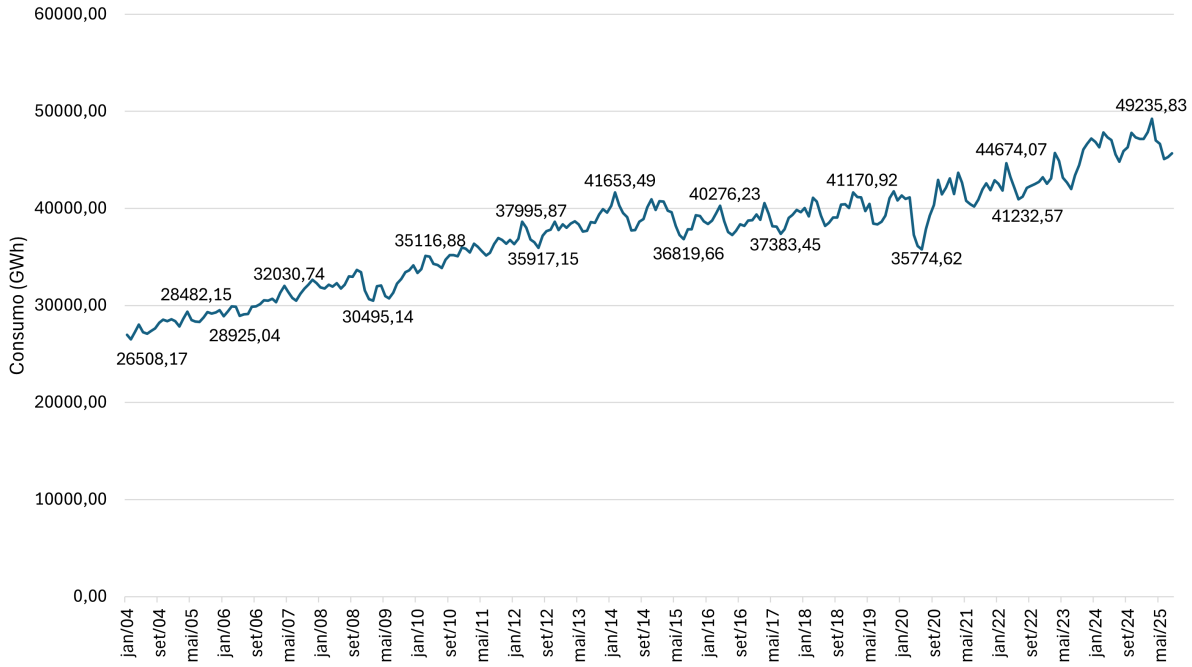
DADOS CURRICULARES **76**

1 INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO DA PESQUISA

O consumo de energia elétrica no Brasil vem crescendo ao longo do tempo e em março de 2025 chegou à marca de 49.235,83 GWh, sendo o recorde de consumo da série histórica, que é medida desde 2004 (EMPRESA DE PESQUISA ENERGÉTICA, 2025). A Figura 1 apresenta o histórico de consumo mensal de energia elétrica desde o ano de 2004 até setembro de 2025.

Figura 1 – Histórico do consumo mensal de energia elétrica

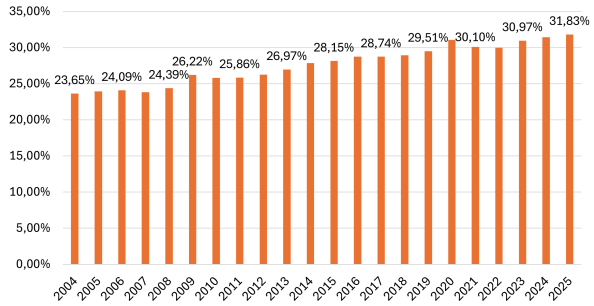


Fonte: Elaborado pelo autor.

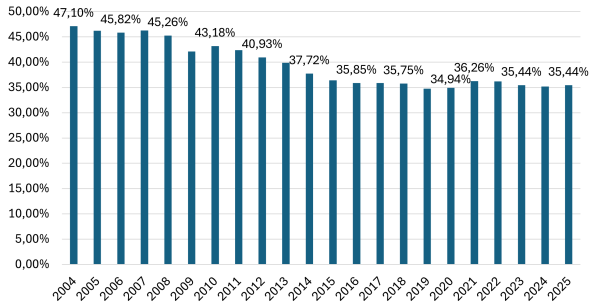
Neste cenário, pode-se destacar o setor residencial, o qual vem, ao longo dos anos, aumentando sua parcela de participação no consumo de energia brasileiro, conforme apresentado na Figura 2a. Observa-se que no ano de 2004 o consumo de tal setor era de 23,64% de toda a energia consumida no Brasil e nos últimos anos (de 2020 até 2024) ficou próximo de 31%, atingindo a marca de 31,83% em 2025[1]. Em contrapartida, o setor industrial vem reduzindo, ao longo do tempo, sua parcela de participação no consumo de energia elétrica, saindo de 47,10% em 2004 para 35,44% em 2025[1], conforme apresentado pela Figura 2b. O setor comercial teve um pequeno aumento na parcela de consumo, apresentado na Figura 2c, enquanto o consumo de outros setores apresentou uma leve subida entre os anos de 2015 e 2018, seguido de uma redução nos anos seguintes, até atingir o valor de 14,56%, conforme ilustrado na Figura 2d.

[1] considerando dados disponibilizados até set/2025

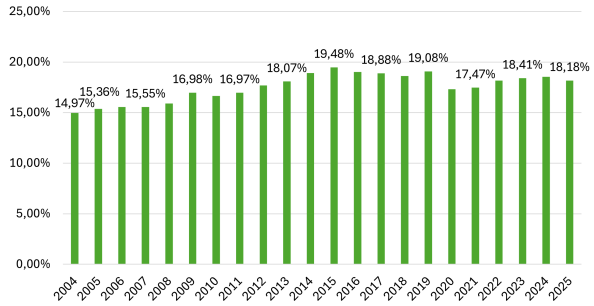
Figura 2 – Parcela de consumo dos setores



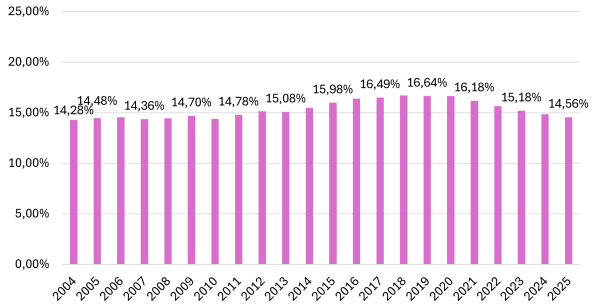
(a) Parcela de consumo do setor residencial



(b) Parcela de consumo do setor industrial



(c) Parcela de consumo do setor comercial



(d) Parcela de consumo de outros setores

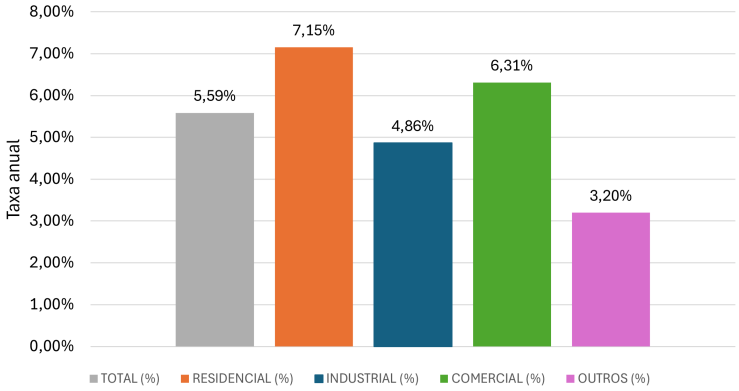
Fonte: Elaborado pelo autor.

Além do aumento da parcela de consumo, o setor residencial apresenta a maior taxa de crescimento do consumo de energia elétrica, sendo de 7,15% no ano de 2024 em relação ao ano de 2023. A Figura 3 apresenta a taxa de crescimento do consumo de energia elétrica para todos os setores.

As taxas de crescimento anual, em relação ao ano anterior, para o setor residencial são apresentadas na Figura 4. Pode-se notar que elas são positivas ao longo do tempo, com uma pequena exceção para o ano de 2015, onde obteve um valor negativo de 0,84%. Observa-se também que, no ano de 2023, foi obtida a maior taxa de crescimento desse setor. A alta taxa de crescimento nos últimos anos é reflexo do fenômeno climático *El Niño*, que causa aumento da temperatura média em algumas regiões, ondas de calor e um clima mais seco. Aliado a isso, houve um aumento no número de unidades consumidoras residenciais, redução das perdas de energia elétrica, diminuição das quedas de energia elétrica (bem como da frequência dessas ocorrências) e melhora nos indicadores macroeconômicos, tais como emprego, renda e consumo das famílias, corroborando para elevar o consumo de energia elétrica (EMPRESA DE PESQUISA ENERGÉTICA, 2023; EMPRESA DE PESQUISA ENERGÉTICA, 2024).

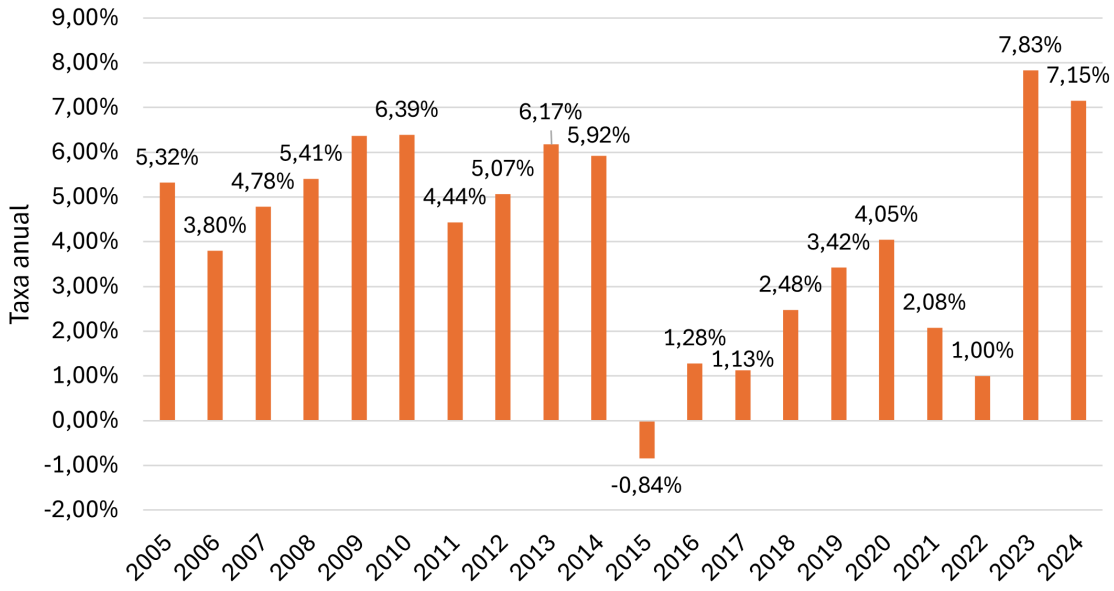
Nos últimos anos, a eletricidade tem sido a principal fonte de energia das residências, e isso deve aumentar nos próximos anos devido ao aumento da posse de alguns eletrodomésticos e ao incremento do uso destes em residências onde não há o hábito de utilização, como em famílias de baixa renda. Além disso, a necessidade de energia das residências pode mudar devido à

Figura 3 – Taxa de crescimento do consumo de energia elétrica para o ano de 2024, em relação ao ano de 2023



Fonte: Elaborado pelo autor.

Figura 4 – Taxa de crescimento anual do consumo de energia elétrica do setor residencial



Fonte: Elaborado pelo autor.

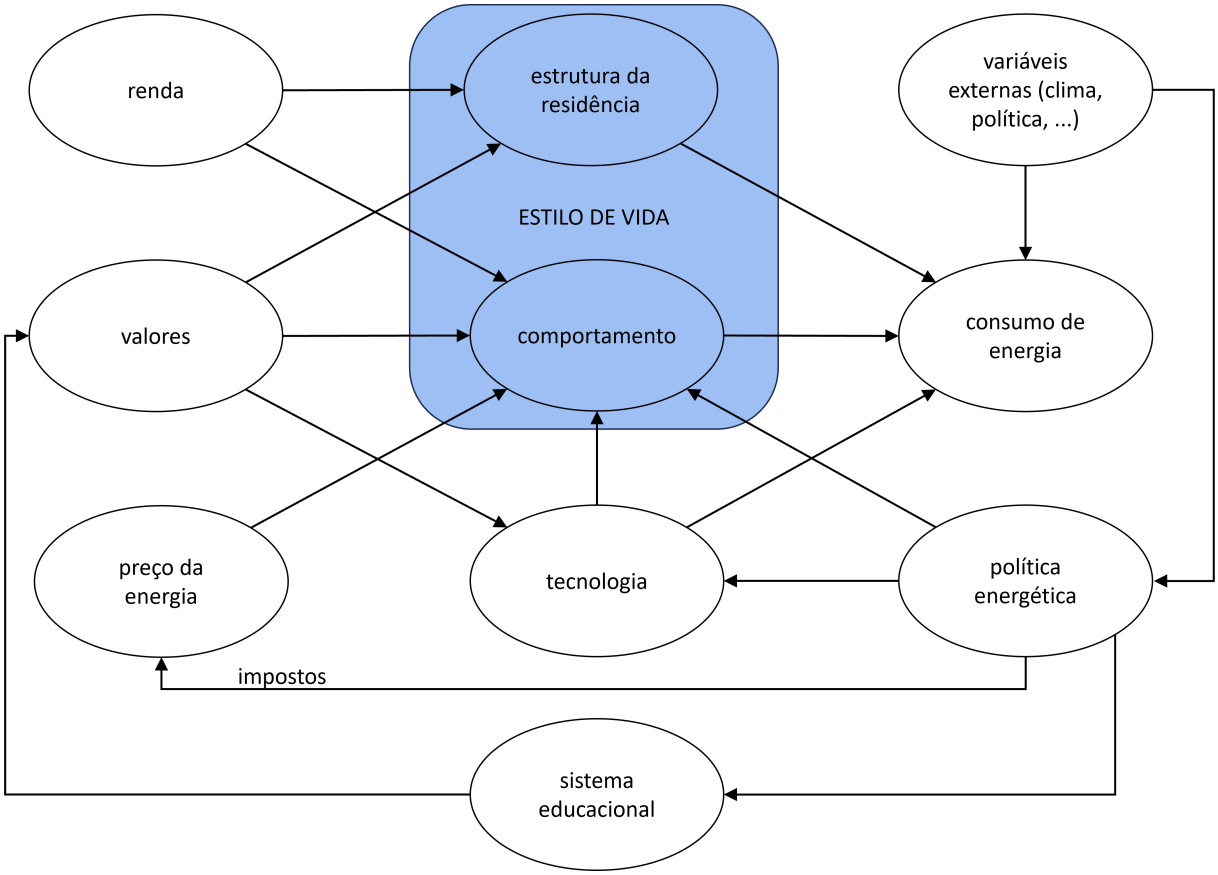
mudanças em hábitos pessoais, políticas públicas ou eventos imprevistos (BRASIL. Ministério de Minas e Energia; EMPRESA DE PESQUISA ENERGÉTICA, 2023).

Dessa forma, com o aumento do consumo de energia elétrica residencial e a projeção para a continuação da elevação, a estimativa de curvas de carga para o setor residencial torna-se uma ferramenta de grande importância para melhorar o uso dos recursos energéticos. Tais estimativas são realizadas por meio de modelos desenvolvidos para prever o consumo de energia no setor residencial.

Dias, Mattos e Balestieri (2004) propõem um esquema básico de definições e interações relacionadas ao consumo de energia elétrica no setor residencial, apresentado na Figura 5. Neste esquema, pode-se observar que existem muitas variáveis que influenciam o consumo de energia,

tais como o clima, o comportamento do consumidor, a estrutura residencial, a eficiência, as políticas energéticas e o sistema educacional. Dessa maneira, pode-se compreender a complexidade de caracterizar o consumo, bem como suas correlações com os fatores influenciadores (MORISHITA, 2011).

Figura 5 – Interações com relação ao consumo de energia elétrica do setor residencial



Fonte: Adaptado de Dias, Mattos e Balestieri (2004)

No Brasil, para melhorar o aproveitamento dos recursos energéticos, o país deve desenvolver políticas públicas que considerem não apenas o crescimento do consumo de energia, mas também o comportamento do consumidor (BRASIL. Ministério de Minas e Energia; EMPRESA DE PESQUISA ENERGÉTICA, 2020). O Plano Nacional de Energia – PNE 2050 recomenda o aperfeiçoamento dos modelos de previsão da curva de carga de energia elétrica, incorporando uma maior participação dos consumidores e as incertezas associadas.

Durante décadas, as pesquisas relacionadas à estimativa da consumo de energia elétrica ao longo de um determinado período tem focado no consumo anual e em modelos que consideram a carga da rede elétrica como uma demanda total de energia, sem a preocupação com a fonte de consumo (GRANDJEAN; ADNOT; BINET, 2012; PROEDROU, 2021). Dessa maneira, objetivando o comportamento da fonte de consumo, na presente pesquisa, optou-se por utilizar a lógica *fuzzy* para estimar a curva de carga de consumo residencial, levando em consideração os aspectos inerentes às incertezas associadas.

Como a teoria dos conjuntos *fuzzy* foi criada para tratar do aspecto vago da informação (ZADEH, 1965) e a teoria das possibilidades para tratar a incerteza da informação (ZADEH, 1999), tais teorias são intimamente ligadas e, com isso, é possível tratar tanto a imprecisão quanto a incerteza de um conjunto de informações, sendo muito utilizadas em sistemas que utilizam as informações fornecidas por seres humanos (SANDRI, S. ; CORREA, C., 1999).

1.2 OBJETIVOS

O objetivo geral deste trabalho é a construção de modelos de previsão para estimar o consumo de energia elétrica para unidades consumidoras residenciais, utilizando uma ferramenta de desenvolvimento de software gratuita que possibilite a construção e a simulação desses modelos. Tais modelos devem levar em consideração os aspectos climáticos, os aspectos econômicos-sociais e os aspectos comportamentais humanos. Tais modelos serão feitos utilizando o Sistema de Inferência *Fuzzy* Tipo-1 (T1FIS, do inglês *Type-1 Fuzzy Inference System*), o Sistema de Inferência *Fuzzy* Tipo-2 Intervalar (IT2FIS, do inglês *Interval Type-2 Fuzzy Inference System*) e o Sistema *Fuzzy* Baseado em Redes Adaptativas (ANFIS, do inglês *Adaptive-Networks-Based Fuzzy Inference Systems*).

Para que o objetivo geral seja atingido, deve-se cumprir os objetivos específicos, conforme apresentados a seguir:

- Utilizar uma ferramenta gratuita para a construção e simulação dos modelos, bem como para a análise e tratamento dos dados;
- Avaliar o impacto de fatores climáticos, socioeconômicos e comportamentais humanos nos modelos de previsão do consumo de energia residencial.

1.3 JUSTIFICATIVA E RELEVÂNCIA

Modelos de estimativa de curva de carga são sistemas que reproduzem, de forma agregada, o consumo de eletricidade de todos os dispositivos elétricos em uma residência ao longo de um determinado período de tempo (PROEDROU, 2021). De acordo com EMPRESA DE PESQUISA ENERGÉTICA (2021), há a necessidade de delimitar bem a aplicação do modelo de acordo com o objeto de estudo, podendo ser em termos de fontes energéticas, horizontes de tempo, classes de renda, perfis sociais e outros aspectos.

Os modelos para a estimativa de curva de carga podem ser classificados de acordo com dois métodos: *top-down* e *bottom-up* (SWAN; UGURSAL, 2009; GRANDJEAN; ADNOT; BINET, 2012; PROEDROU, 2021; EMPRESA DE PESQUISA ENERGÉTICA, 2021).

Os métodos *top-down*, em geral, utilizam como entrada um conjunto de dados menor e de maneira agregada, não necessitando de separação de acordo com as características do setor residencial. Tais métodos buscam a correlação entre o consumo de energia e aspectos gerais (macrovariáveis), tais como o Produto Interno Bruto (PIB), a taxa de desemprego, estatísticas

sobre a população e o número de domicílios (ABREU *et al.*, 2015; TEIXEIRA, 2020; EMPRESA DE PESQUISA ENERGÉTICA, 2021; GRANDJEAN; ADNOT; BINET, 2012; PROEDROU, 2021). Neste tipo de modelo, geralmente não consegue-se distinguir o consumo para residências individuais (PAATERO; LUND, 2006).

Modelos que utilizam o método *top-down*, por utilizarem dados mais agregados, são mais fáceis de serem construídos, porém, podem ser inadequados em alguns períodos, pois acredita-se que as interações energéticas e econômicas do passado poderão persistir no futuro (MATSUDO, 2001). Desta maneira, tais modelos não conseguem captar variações bruscas, tais como momentos de crise ou instabilidades, gerando distorções estatísticas ou quebras de séries (EMPRESA DE PESQUISA ENERGÉTICA, 2021). Além disso, as relações entre o consumo de energia e o uso final da energia elétrica não são explícitas, o que torna mais difícil a identificação das melhores áreas para reduzir o consumo de energia de um determinado setor (SWAN; UGURSAL, 2009).

O método *bottom-up*, em geral, utiliza como entrada um conjunto de dados mais extensos e de maneira desagregada, explicitando melhor as relações entre o consumo de energia e o uso final (STREICHER *et al.*, 2019; EMPRESA DE PESQUISA ENERGÉTICA, 2021). Os dados de entrada são microvariáveis, tais como o consumo individual de cada equipamento, o comportamento dos ocupantes da residência, informações meteorológicas ou outras microvariáveis pertinentes (ABREU *et al.*, 2015; GRANDJEAN; ADNOT; BINET, 2012; PAATERO; LUND, 2006; PROEDROU, 2021; ZÚÑIGA; CASTILLA; AGUILAR, 2014). Com este tipo de modelo, pode-se conseguir um alto nível de detalhes, podendo ajustar rapidamente a curva estimada com a inclusão ou retirada de equipamentos, por exemplo (ABREU *et al.*, 2015; PROEDROU, 2021).

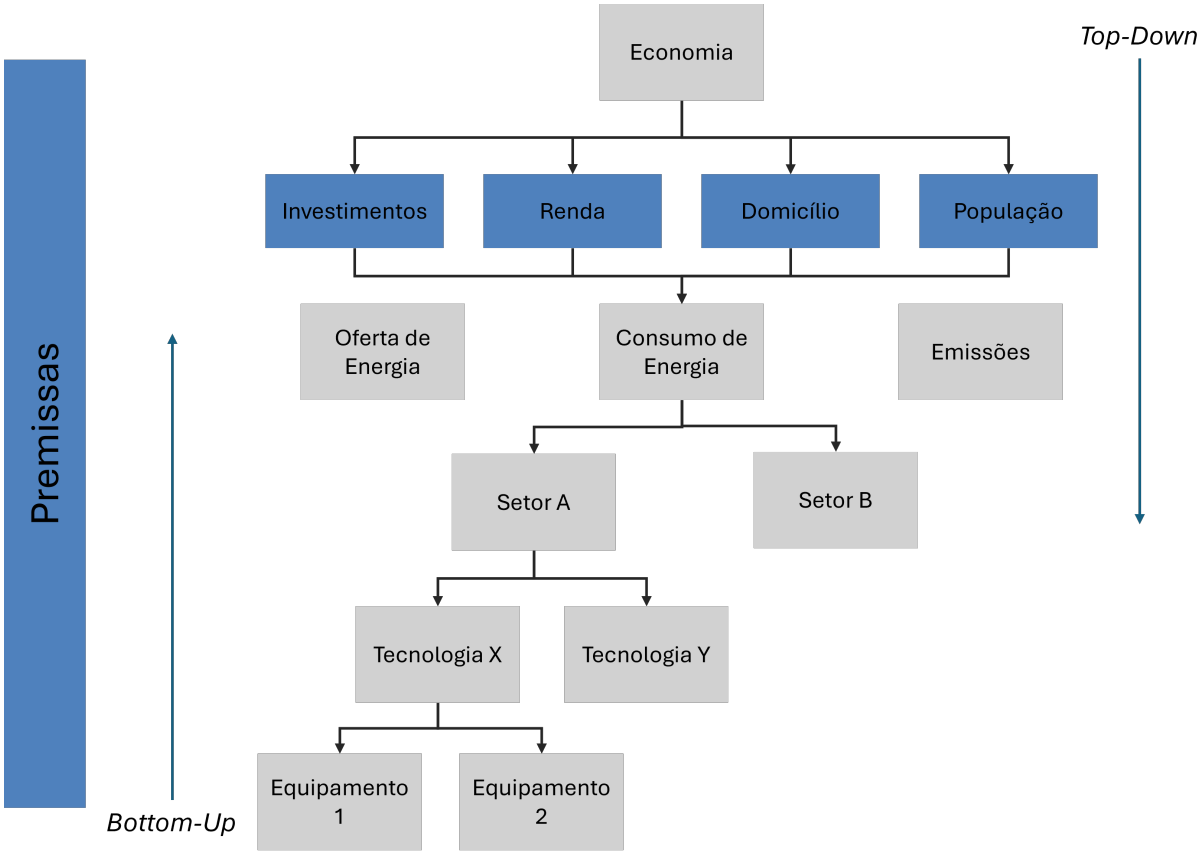
As principais desvantagens do método *bottom-up* são o esforço computacional devido ao nível de detalhes do conjunto de entrada e a obtenção dos dados de entrada devido às diferentes informações e ao seu detalhamento (LI *et al.*, 2019; PROEDROU, 2021).

A Figura 6 exemplifica as diferenças entre os dois métodos de estimativa de curvas de carga. Pode-se observar que o método *top-down* parte de dados agregados, como, por exemplo, dados econômicos, e desce o nível de análise para elementos um pouco mais desagregados. Em contrapartida, no método *bottom-up*, observa-se que parte dos setores desagregados, como os equipamentos residenciais, e sobe o nível de análise para elementos mais agregados. Em ambos os métodos, o alvo pode ser a estimativa do consumo de energia elétrica, a oferta de energia ou a emissão de poluentes.

Além de ambos os métodos, podem existir modelos híbridos, os quais combinam componentes *top-down* e *bottom-up*, permitindo a análise de cenários mais complexos (EMPRESA DE PESQUISA ENERGÉTICA, 2021). Porém, para evitar problemas de interpretação dos resultados dos modelos, a distinção entre os dois métodos torna-se de grande importância (MATSUDO, 2001).

Para destacar os impactos e a relevância do tema, foi realizado um estudo bibliométrico a partir do banco de dados da plataforma *SCOPUS* e também foi utilizado o *software VOSviewer* para apresentar as interações entre as publicações.

Figura 6 – Métodos *top-down* e *bottom-up* para a estimativa de consumo de energia



Fonte: Adaptado de EMPRESA DE PESQUISA ENERGÉTICA (2021).

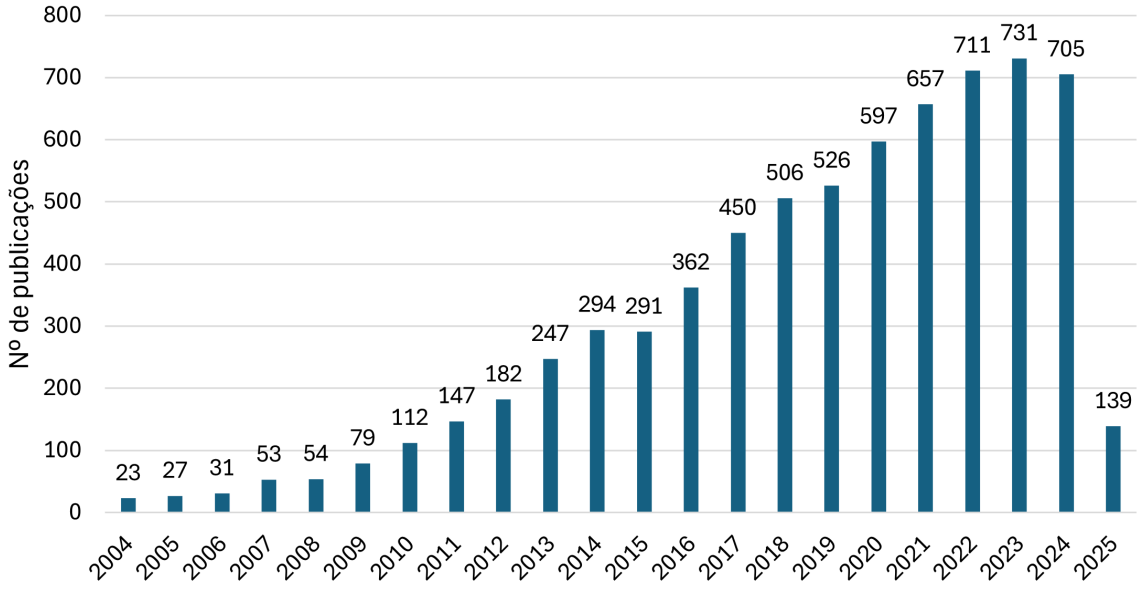
Utilizando a plataforma *SCOPUS* para realizar a busca de trabalhos que se aderem à linha desta pesquisa, foram definidas palavras-chave com termos relacionados à curvas de carga residencial, sendo eles: *load curve*, *load profile*, *load modeling*, *load shape modeling*, *energy demand model*, *electricity consumption*, *residential*, *household* e *domestic*. Inicialmente, a busca foi realizada elencando os termos da seguinte forma: (“*load curve*” OR “*load profile*” OR “*load modeling*” OR “*load shape modeling*” OR “*energy demand model*” OR “*electricity consumption*”) AND (*residential* OR *household* OR *domestic*).

Na busca inicial, foram encontradas 9950 publicações relacionadas ao tema. A Figura 7 apresenta o número de publicações por ano nos últimos 20 anos. Pode-se observar que o tema apresenta uma forte tendência de estudo. Em 2025, apresenta uma queda devido a busca ter sido realizada no mês de junho deste ano.

A Figura 8 apresenta os países com mais publicações no tema, sendo apresentados somente os países que contém 100 ou mais publicações. Pode-se observar que a China lidera com 1289 publicações, seguida pelos Estados Unidos e a Índia, com 1176 e 550 publicações, respectivamente. O Brasil ocupa a décima sexta posição com 154 publicações.

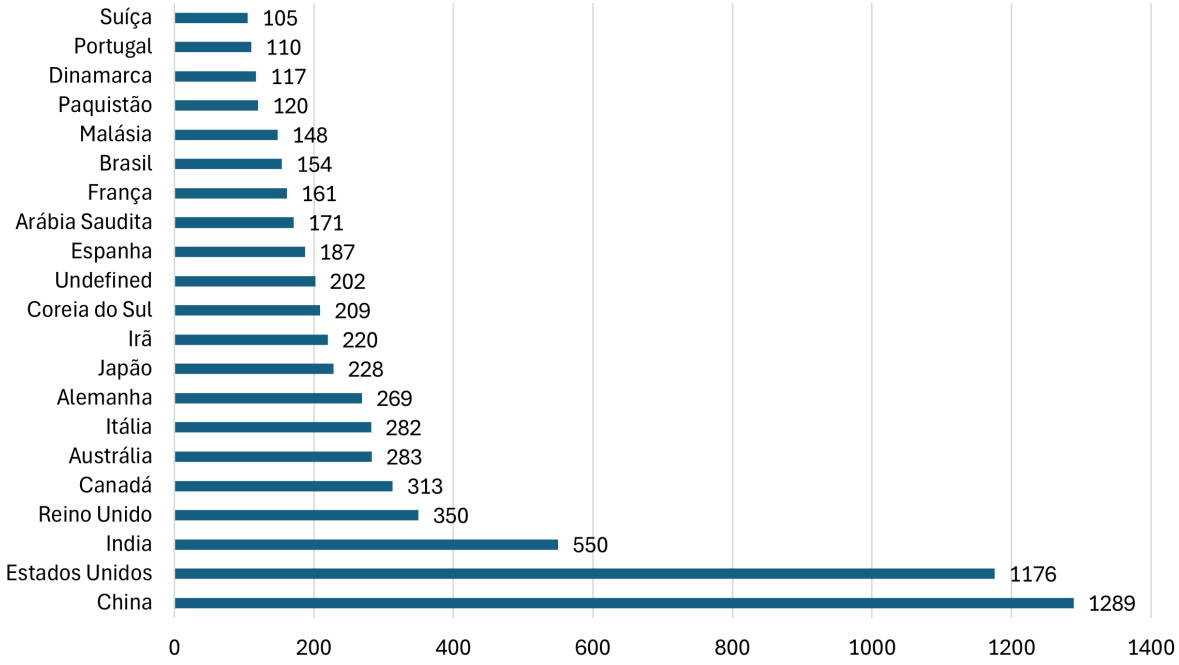
Para esta busca inicial, foram verificados, através das palavras-chave e dos resumos, os trabalhos que realmente se aderem ao tema da presente pesquisa e, a seguir, serão brevemente

Figura 7 – Publicações por ano



Fonte: Elaborado pelo autor.

Figura 8 – Publicações por país



Fonte: Elaborado pelo autor.

apresentadas as publicações que apresentaram maior relevância.

No trabalho de Train, Herriges e Windle (1985), foi desenvolvido um modelo denominado *Statistically Adjusted Engineering* (SAE), o qual estima a curva de carga de uso final de energia elétrica, integrando informações dos modelos de engenharia (utilizados até então) e dados reais de

consumo de energia. As curvas de carga estimadas dependem de dados meteorológicos, diferentes cenários de presença de habitantes, operação dos aparelhos, informações socioeconômicas e particularidades das habitações. Tal modelo requer uma grande quantidade de dados para incorporar as características dos ocupantes da residência.

O modelo desenvolvido por Walker e Pokoski (1985) foi o primeiro a considerar o comportamento do consumidor para estimar as curvas de carga, utilizando a "disponibilidade" e a "propensão" dos ocupantes da habitação. O modelo utiliza funções de probabilidade obtidas pelo método de Monte-Carlo, sendo uma função de distribuição de disponibilidade, que estima estatisticamente o número de pessoas em uma residência disponíveis para usar um eletrodoméstico, e uma função de distribuição de propensão, que indica a probabilidade de um indivíduo usar um determinado eletrodoméstico em um momento do dia. Os autores observam que a complexidade de obter os dados os levou a considerar apenas um cenário em que um único habitante vive na residência.

Capasso *et al.* (1994) baseou-se no modelo mencionado anteriormente e desenvolveu um modelo *bottom-up* que utilizou conjuntos de funções "comportamentais" e de "engenharia", melhorando o modelo desenvolvido por Walker e Pokoski (1985) e tornando-se uma referência para trabalhos posteriores, principalmente para aqueles que utilizam uma modelagem do comportamento humano. Histogramas de disponibilidade dos ocupantes, distribuições percentuais de uso dos eletrodomésticos, número de recursos humanos disponíveis e a propriedade dos eletrodomésticos foram utilizados nas funções comportamentais. As funções de engenharia utilizavam informações sobre o tempo de ciclo do aparelho e do consumo de energia.

Balachandra e Chandru (1999) apresentaram um método que utiliza curvas de carga representativas para explicar o comportamento da carga de um sistema. As curvas de cargas representativas são construídas agrupando e normalizando as curvas de carga diária do sistema que apresentam padrões de consumo semelhantes. Pode-se estimar o papel de alguns grupos de consumo no comportamento anual da curva a partir dos resultados agregados. Os grupos de maior e menor consumo podem ser observados ao longo do ano e podem ser identificadas as diferenças significativas no consumo médio e nas variações ao longo de um dia. Isso permite explicar o comportamento dos setores ao longo do ano, comparando-os com elementos como as estações do ano. Assim, é possível ver como cada um desses elementos pode influenciar o consumo do grupo ao longo do ano e como os grupos respondem a diferentes situações de consumo.

Paatero e Lund (2006) propõem um modelo de estimativa que não necessita de muitos dados para chegar em um panorama geral do consumo de energia. Dessa forma, pode-se construir curvas de carga para um grande número de residências a partir de valores médios estatísticos da consumo de energia de aparelhos individuais e distribuições estatísticas gerais dos consumidores. A perda de precisão dos resultados pode ser compensada pela redução do volume de dados que é requerido. Além disso, também foi observado que o consumo de energia elétrica é sazonal, variando de acordo com a estação do ano, a temperatura média do dia e a hora.

O modelo proposto por Richardson *et al.* (2010) utiliza dados de um estudo no Reino Unido que registrou, para cerca de 21.000 habitações, informações detalhadas sobre como as pessoas passam seu tempo. Tais registros foram utilizados para a criação de padrões de ocupação ativa e perfis de atividades diárias que descrevem como as pessoas passam o tempo realizando certas atividades. Dessa maneira, por meio da simulação do uso dos aparelhos eletrodomésticos, são criados dados sintéticos em alta resolução (um minuto de intervalo), os quais são utilizados para calcular a curva de carga da habitação, com base no número de ocupantes, no dia da semana e no mês. Os dados gerados foram validados comparando-os com os dados reais medidos ao longo de um ano em 22 residências. Para incorporar as características dos ocupantes da residência, há a necessidade de uma grande quantidade de dados.

Lopez-Rodroguez *et al.* (2013) utilizam dados da Pesquisa de Uso do Tempo (TUS, do inglês *Time Use Survey*) 2009-2010, realizada pelo Instituto Nacional de Estatística da Espanha, para determinar os padrões de ocupação em propriedades espanholas e correlacionar com o consumo de energia elétrica. Dessa maneira, propõe-se um modelo estocástico baseado na cadeia de Markov e em técnicas de Monte Carlo para simular o perfil de consumo doméstico de energia, com base no número de membros de uma família e no dia da semana. O estudo aponta três momentos de ocupação ativa: manhã, meio-dia e noite, além de levar em consideração as atividades relacionadas ao uso de eletrodomésticos que poderiam ser utilizadas em soluções de Gerenciamento pelo Lado da Demanda (GLD).

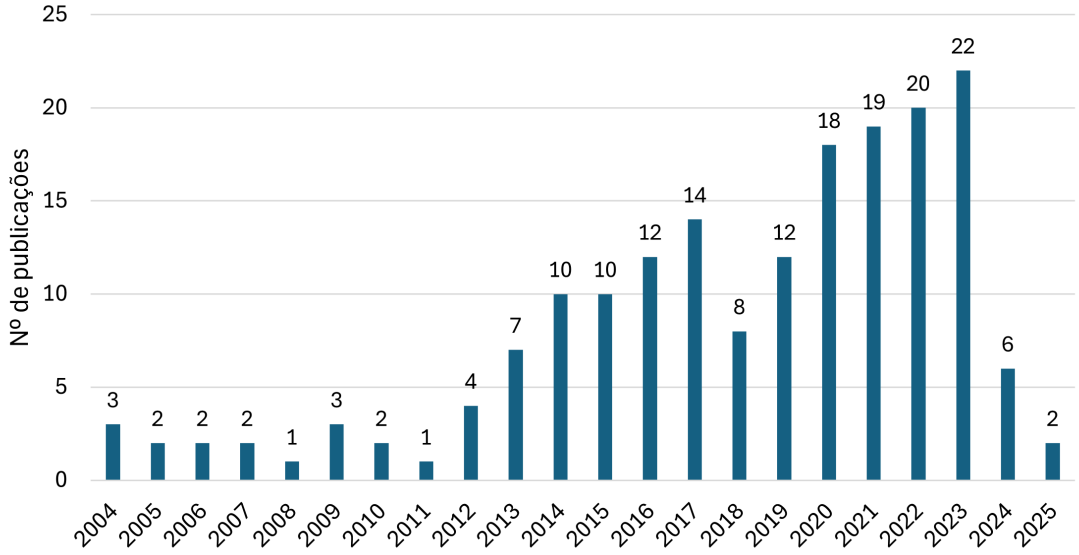
Para aderir a pesquisa bibliométrica ao objetivo principal deste trabalho, foi inserido na busca da plataforma *SCOPUS* o termo *fuzzy*, sendo os termos da busca elencados da seguinte maneira: (“*load curve*” OR “*load profile*” OR “*load modeling*” OR “*load shape modeling*” OR “*energy demand model*” OR “*electricity consumption*”) AND (*residential* OR *household* OR *domestic*) AND (*fuzzy* OR ANFIS). O número de resultados diminuiu para 207 publicações. Na Figura 9 pode-se observar que a aderência de sistemas *fuzzy* ao tema geral iniciou-se com maior ênfase a partir do ano de 2014, com uma leve diminuição nos anos de 2018 e 2019. No ano de 2023, obteve-se o maior número de publicações, com um total de 22 no ano.

A seguir, serão apresentados, de maneira breve, os trabalhos mais relevantes que se aderem ao tema do trabalho proposto.

Li, Su e Chu (2011) apresentam um estudo comparativo sobre a previsão do consumo de energia em edifícios usando dois modelos: Redes Neurais Artificiais (RNAs) e um Sistema de Inferência *Fuzzy* baseado em Redes Adaptativas utilizando Algoritmos Genéticos (GA-ANFIS). O modelo GA-ANFIS otimiza a base de regras por meio de algoritmos genéticos e ajusta os parâmetros usando o ANFIS para melhorar o desempenho da previsão. Os resultados indicam que o modelo GA-ANFIS supera a RNA em precisão de previsão, mantendo um tempo de modelagem semelhante, o que o torna uma alternativa viável para a previsão de energia em edifícios.

Zúñiga, Castilla e Aguilar (2014) propõe a utilização de um sistema de lógica *fuzzy* para modelar o comportamento humano relacionado à utilização de eletrodomésticos e à iluminação

Figura 9 – Publicações por ano incluindo o termo *fuzzy*



Fonte: Elaborado pelo autor.

residencial. Dessa forma, os autores obtém um perfil de ativação por hora para cada dispositivo, representando a probabilidade do aparelho ser utilizado em determinados momentos do dia. Tais perfis de ativação são utilizados para calcular a energia consumida por cada aparelho e, consequentemente, a curva de consumo de energia elétrica da residência.

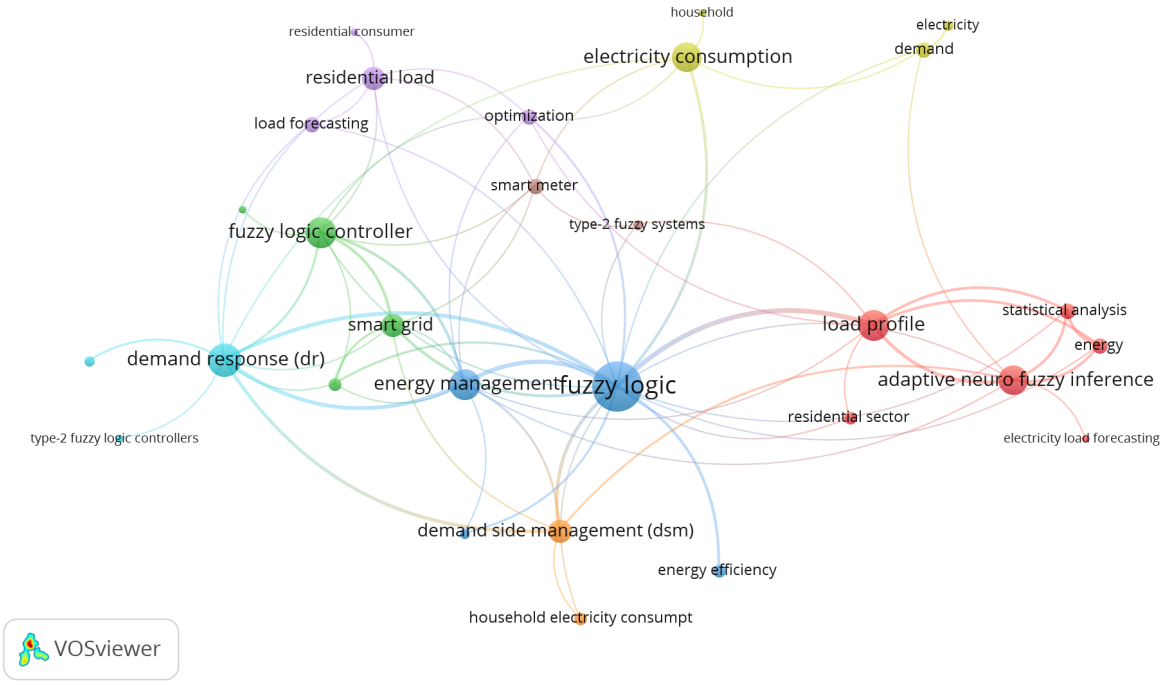
Popoola, Munda e Mpanda (2015) apresentam o desenvolvimento e avaliação do ANFIS para modelar perfis de carga de iluminação residencial, incorporando variáveis como iluminação natural, ocupação ativa e nível de renda dos moradores. Os resultados demonstraram que tal modelo apresentou uma correlação mais forte e um erro quadrático médio menor em comparação com modelos de regressão linear tradicionais. Alguns anos depois, os autores apresentam outro estudo utilizando o modelo ANFIS, porém, desta vez, utilizam abordagens com dados ponderados e não ponderados (POPOOLA; MUNDA; MPANDA, 2018).

Os trabalhos de Abreu *et al.* (2015) e Abreu *et al.* (2020) também propõem a utilização de sistemas *fuzzy* para a obtenção do perfil de carga residencial. Os autores utilizam como entradas do sistema *fuzzy* os horários do dia e a ocupação da residência. Dessa forma, estima-se o consumo por hora da residência e, consequentemente, a curva de carga residencial. Os autores comparam os resultados obtidos pelo sistema *fuzzy* com os dados medidos de um conjunto de residências nas cidades de Ilha Solteira e São Paulo.

Já o trabalho de Nokar, Tashtarian e Moghaddam (2017) propõe uma abordagem para a previsão de carga de curto prazo em redes inteligentes, usando um modelo ANFIS combinado com técnicas de pré-filtragem de dados. Os autores enfatizam a importância do pré-processamento de dados de carga de eletricidade, que geralmente contêm ruído e valores ausentes. Sendo assim, utilizam um método de filtragem com um filtro de média móvel e a imputação dos k-vizinhos mais próximos para preparar o conjunto de dados de treinamento da carga horária para análise.

Com a utilização do *software VOSviewer*, foi realizada uma análise dos estudos, relacionando as palavras chave das publicações com o número de ocorrências e a ligação entre elas. Para que esta análise reflita à pesquisa aqui exposta, foi realizada uma filtragem dos termos, de forma a eliminar aqueles que não são relacionados e também para agrupar termos muito semelhantes. Dessa maneira, foi gerada uma rede contendo 8 *clusters* e 29 itens, conforme apresentado na Figura 10. Nesta análise, quanto mais espessa for a linha que une dois nós, mais forte será a ligação entre os termos. Além disso, quanto mais o termo está situado na região central da rede, maior é a concentração das ligações com outros termos. Por fim, quanto maior a frequência do termo, maior é o seu ícone. Portanto, a partir da figura a seguir, pode-se concluir que o termo *fuzzy logic* tem muita ligação com vários outros termos e apresenta maior frequência entre os termos buscados e, além disso, ele possui uma boa força de ligação com o termo *load profile*.

Figura 10 – Co-ocorrências de palavras chaves entre as publicações



Fonte: Elaborado pelo autor.

Por fim, na pesquisa da base *SCOPUS*, foram adicionados os termos *type-2* e *type 2*, a fim de encontrar as publicações que utilizaram algum sistema de inferência *fuzzy* tipo-2. Nesta pesquisa, foram encontradas quatro publicações, sendo que apenas em duas delas essa técnica é utilizada na estimativa da curva de carga de consumo de energia elétrica em unidades residenciais.

Kapler (2022) propuseram a utilização de um sistema de inferência *fuzzy* tipo-2 para fazer a previsão do perfil de consumo de energia elétrica residencial. Dessa maneira, foram utilizados dois perfis de carga de duas residências diferentes, ambas com resolução de um minuto. O modelo tem como saída a previsão de consumo do minuto posterior ($x(t+1)$), utilizando três

entradas deslocadas no tempo, sendo $x(t)$, $x(t-1)$ e $x(t-2)$. Além disso, foi realizada a sintonia das funções de pertinência de cada uma das entradas utilizando algoritmos genéticos e otimização por enxame de partículas.

Li *et al.* (2025) propõe a utilização de um modelo que utiliza a lógica *fuzzy* tipo-2 intervalar para representar as incertezas associadas e, logo após, um perceptron multicamadas para estimar os valores ausentes do conjunto de dados. Depois que os dados faltantes são estimados, realiza-se a previsão do consumo de energia residencial por meio de uma rede que combina aprendizado por transferência e aprendizado em conjunto.

Com base nos trabalhos analisados anteriormente, verifica-se a existência de uma lacuna no que diz respeito à aplicação do IT2FIS na estimativa do consumo de energia residencial, como é proposto pela presente pesquisa. Observa-se que a utilização desta abordagem necessita de pesquisas adicionais que contribuam para o avanço do conhecimento e o desenvolvimento de novas perspectivas metodológicas relacionadas ao contexto em questão.

1.4 DELIMITAÇÃO DA PESQUISA

A pesquisa será desenvolvida considerando os dados referentes ao consumo de energia de unidades consumidoras residenciais da região sudeste do Brasil, obtidos por meio da Pesquisa de Posse de Equipamentos e Hábitos de Uso - 2019 (PPH-2019), que foi elaborada por meio do Programa Nacional de Conservação de Energia Elétrica – Procel.

1.5 ORGANIZAÇÃO DO TRABALHO

Dando sequência ao trabalho, no capítulo 2 é feita uma revisão da literatura sobre o problema em questão, destacando os métodos para estimativa do consumo de energia elétrica e os modelos já desenvolvidos. A fundamentação teórica dos conceitos envolvidos no trabalho será abordada, tais como os T1FIS, IT2FIS e ANFIS, além das métricas de avaliação dos modelos propostos.

No capítulo 3, são apresentados os materiais e métodos utilizados, classificando a pesquisa, apresentando o local de estudo, a coleta dos dados utilizados no trabalho e a construção de cada um dos modelos utilizados, detalhando cada variável de entrada e saída, bem como suas funções de pertinência e a base de regras utilizada.

No capítulo 4, são apresentados os resultados obtidos e realizadas as discussões pertinentes a cada um deles.

Por fim, no capítulo 5, apresenta-se a conclusão do trabalho, de acordo com os objetivos e os resultados encontrados. Também é feita uma breve discussão e sugestão para trabalhos futuros.

2 REFERENCIAL TEÓRICO

2.1 SISTEMA DE INFERÊNCIA *FUZZY* TIPO-1

A teoria dos conjuntos *fuzzy* e a teoria das possibilidades foram criadas para lidar com o aspecto vago da informação com a incerteza da informação (ZADEH, 1965; ZADEH, 1999). O uso da lógica fuzzy permite, em várias situações, representar de maneira apropriada as fronteiras de decisão complexas, tornando-se de grande utilização em sistemas nos quais o conhecimento é incompleto ou impreciso (MEZA *et al.*, 2006).

Tais teorias são intimamente ligadas e com isso, é possível tratar tanto a imprecisão quanto a incerteza de um conjunto de informações, sendo muito utilizadas em sistemas que utilizam a informações fornecidas por seres humanos (SANDRI, S. ; CORREA, C., 1999).

Na teoria clássica, a pertinência de um elemento é muito bem definida, podendo ser classificado como pertencente ou não pertencente ao conjunto. A função de pertinência $\mu_A(x)$ expressa que, dado um universo X, os elementos deste universo pertencem ou não pertencem ao conjunto (KLIR; YUAN, 1996; RIZOL; DIAS, 2014), sendo matematicamente representada pela equação 1.

$$\mu_A(x) = \begin{cases} 1 & \text{se e somente se } x \in A \\ 0 & \text{se e somente se } x \notin A \end{cases} \tag{1}$$

ou seja, o elemento possui apenas dois graus de pertinência em relação ao conjunto [0 ou 1].

Já na lógica *fuzzy*, um objeto pode pertencer parcialmente a um determinado conjunto, pois os conjuntos *fuzzy* possuem valores reais definidos no intervalo [0, 1] (ZADEH, 1965). Um conjunto *fuzzy* A, definido em um universo de discurso I, pode ser representado pela equação 2.

$$A = \{(x, \mu_A(x)) | x \in I\} \tag{2}$$

onde $\mu_A(x)$ indica o quanto x é compatível com o conjunto A.

O T1FIS possui quatro blocos, os quais são: fuzificador, base de regras, inferência e defuzificador (MENDEL, 1995), ilustrados na Figura 11.

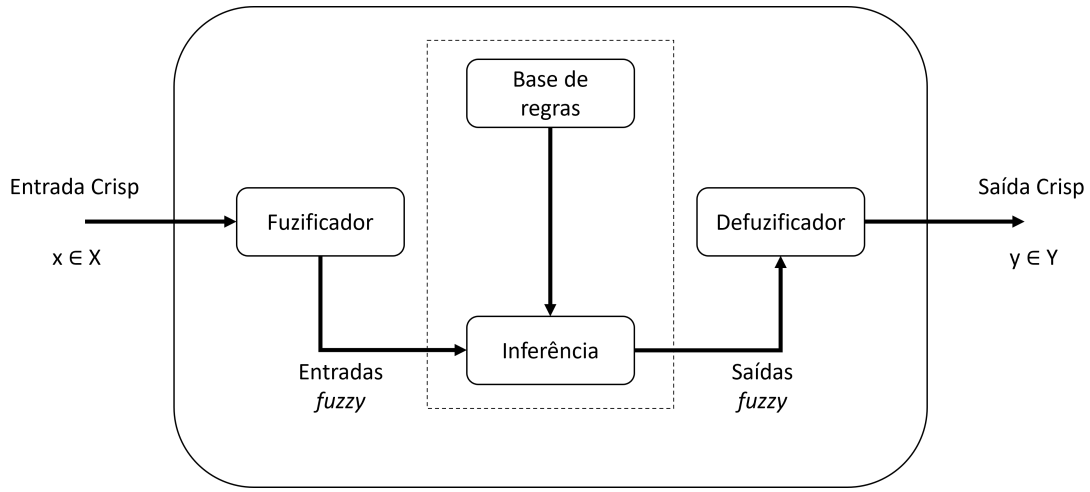
Normalmente, utilizam-se como entrada do T1FIS valores reais, resultantes de alguma medição ou observação, assim diz-se que tais valores são *crisps*. O fuzificador é responsável pela transformação dos valores *crisps* de entrada em um valor *fuzzy* correspondente. Nesta etapa, os valores de entrada são mapeados e atribuídos à valores linguísticos com um determinado grau de pertinência (RIZOL; DIAS, 2014).

As regras possuem um aspecto fundamental para um bom desempenho de um T1FIS e podem ser fornecidas por especialistas. Assim, a base de regras contém o conjunto de regras que é responsável por todo o raciocínio *fuzzy*, por meio das variáveis linguísticas (RIZOL; DIAS,

2014). Sendo composta por regras do tipo:

SE <antecedente> ENTÃO <consequente>

Figura 11 – Diagrama de blocos de um T1FIS



Fonte: Adaptado de Rizol e Dias (2014)

O bloco de inferência realiza as operações do sistema *fuzzy* de acordo com o que foi estabelecido na base de regras, a qual executa a lógica *fuzzy* por meio das variáveis linguísticas (RIZOL; DIAS, 2014). Os sistemas de inferência *fuzzy* mais utilizados são o Mamdani e o Takagi-Sugeno (PALIT; POPOVICĆ, 2005).

Por fim, no bloco defuzificador, a informação no domínio *fuzzy* é convertida em saída real (*crisp*) por meio dos métodos de defuzificação (RIZOL; DIAS, 2014), sendo destacados os métodos: critério de máximo, média do máximo e o centro da área (MENDEL, 1995).

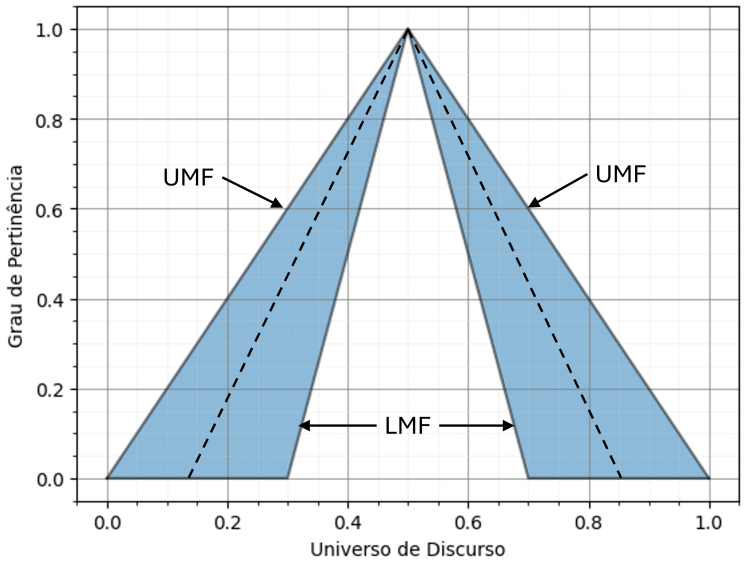
2.2 SISTEMA DE INFERÊNCIA *FUZZY* TIPO-2 INTERVALAR

Quando não é possível determinar a pertinência de um elemento a um conjunto como pertencente ou não pertencente (0 ou 1), utiliza-se o T1FIS. Da mesma maneira, quando se tem dificuldade em determinar o grau de pertinência, mesmo que seja um número *crisp* entre [0,1], pode-se utilizar o IT2FIS (CASTILLO; MELIN, 2008). As funções de um T1FIS possuem grau de pertinência com um valor *crisp*, enquanto o grau de pertinência para IT2FIS é um valor *fuzzy*, ou seja, os conjuntos do IT2FIS podem ser chamados de conjuntos *fuzzy-fuzzy* (MENDEL, 2007).

Se as incertezas do IT2FIS desaparecerem, tal sistema é reduzido a um T1FIS. Para representar as incertezas associadas, as funções de pertinência do IT2FIS são obtidas criando-se uma Mancha de Incerteza (FOU, do inglês *Footprint Of Uncertainty*) na vizinhança da função de pertinência do T1FIS (MENDEL, 2007). A Figura 12 apresenta um exemplo de uma função de pertinência trapezoidal, a qual foi adicionada uma FOU.

Ao adicionar uma Função de Pertinência Superior (UMF, do inglês *Upper Membership Function*) e uma Função de Pertinência Inferior (LMF, do inglês *Lower Membership Function*) a FOU é criada. Dessa forma, um conjunto *fuzzy* tipo-2 pode ser obtido pela união de todas as funções de pertinência possíveis entre UMF e LMF (MENDEL, 2007).

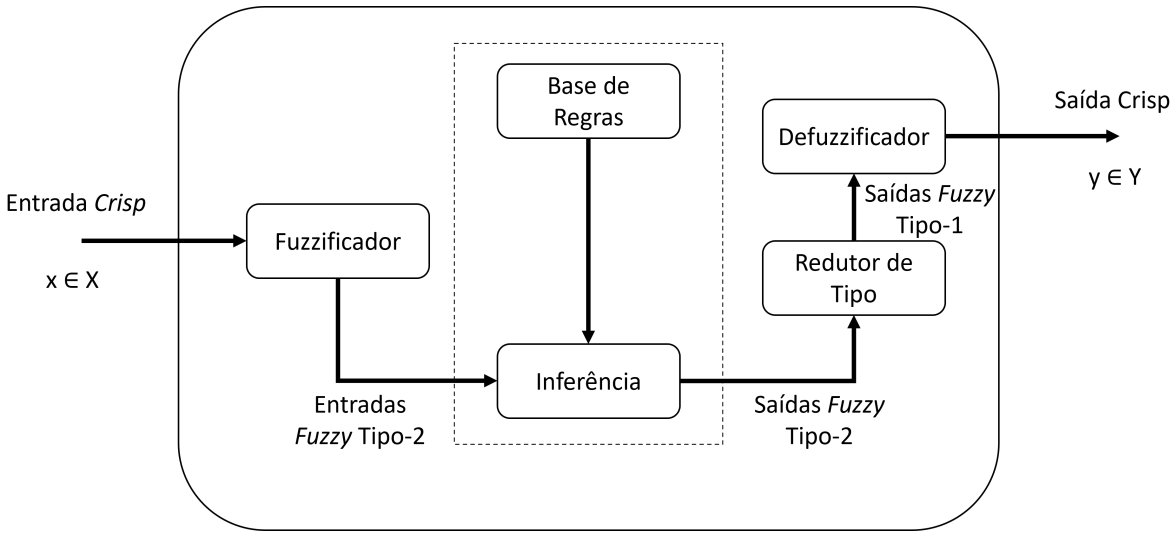
Figura 12 – Função de pertinência triangular com adição de uma FOU



Fonte: Adaptado de Mendel (2007)

Um IT2FIS possui um bloco a mais que o T1FIS, sendo eles: fuzificador, base de regras, inferência, redutor de tipo e defuzificador (RIZOL; MESQUITA; SAOTOME, 2011). A Figura 13 apresenta o diagrama de blocos de um IT2FIS.

Figura 13 – Diagrama de blocos de um IT2FIS



Fonte: Adaptado de Rizol, Mesquita e Saotome (2011)

O fuzificador é responsável pela transformação dos valores *crisps* de entrada em conjunto *fuzzy* tipo-2, da mesma maneira que um T1FIS (RIZOL; MESQUITA; SAOTOME, 2011).

A base de regras permanece a mesma que no T1FIS e, da mesma forma, o bloco de inferência faz as operações do sistema *fuzzy* tipo-2 de acordo com a base de regras (RIZOL; MESQUITA; SAOTOME, 2011).

O bloco redutor de tipo é um novo bloco, o qual transforma o conjunto *fuzzy* tipo-2 em um conjunto *fuzzy* tipo-1. Equivalente ao bloco defuzificador, existe um método de tipo-redutor (RIZOL; MESQUITA; SAOTOME, 2011).

Nesta pesquisa, será utilizado o método do centroide, o qual é definido pela coleção de todos os centroides dos conjuntos *fuzzy* tipo-1 que compõem a FOU. O resultado é uma coleção de números finitos tendo um valor mínimo à esquerda (y_l) e um valor máximo à direita (y_r) e, para encontrar estes valores, pode-se utilizar vários métodos (RIZOL; MESQUITA; SAOTOME, 2011). Porém, nessa dissertação será utilizado o método proposto por Karnick-Mendel (KM), por ser o algoritmo mais utilizado na redução de tipo de sistemas *fuzzy* tipo-2 intervalar (WU; MENDEL, 2009; DODURKA *et al.*, 2014).

Por fim, no bloco defuzificador a informação já está no domínio *fuzzy* tipo-1, sendo convertida em saída real (*crisp*), através dos métodos de defuzificação (RIZOL; MESQUITA; SAOTOME, 2011).

2.3 SISTEMA DE INFERÊNCIA NEURO-*FUZZY* ADAPTATIVO

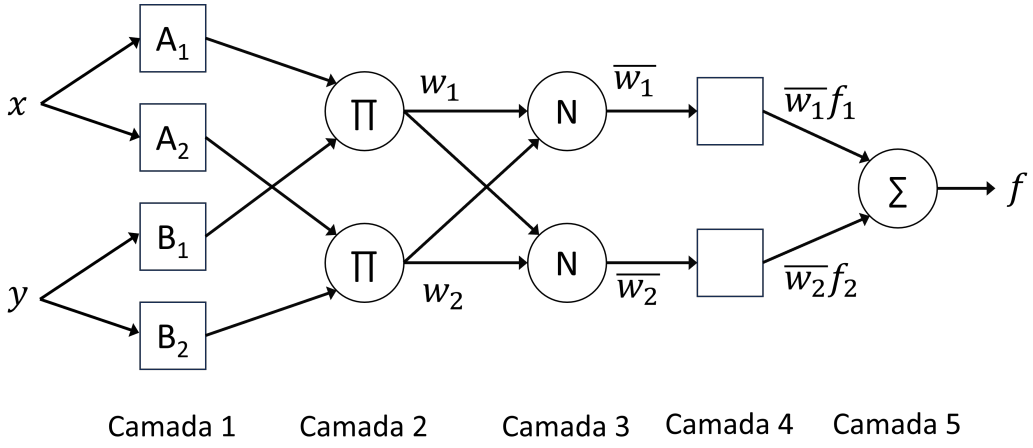
O principal problema com a lógica *fuzzy* é que não há um processo organizado para transformar o conhecimento ou experiência humana em uma base de regras, e, para minimizar o erro de saída, faz-se necessário um ajuste das funções de pertinência, no qual torna-se difícil a validação pois é necessário o auxílio de um especialista. Por outro lado, uma rede neural pode aprender com seu ambiente e adaptar-se interativamente a ele (JANG, 1993).

O ANFIS é uma rede *feedforward* multicamadas que mapeia um espaço de entrada para um espaço de saída usando algoritmos de aprendizagem de redes neurais e raciocínio difuso, podendo combinar a força de abstração das palavras de um sistema *fuzzy* com a força numérica de uma rede adaptativa de uma rede neural. Tal sistema é capaz de aprender, construir, contabilizar e classificar, tendo como vantagem permitir a extração de regras *fuzzy* a partir de dados numéricos ou conhecimento especializado e construir uma base de regras de acordo com os dados de treinamento (CHANG; CHANG, 2006).

A Figura 14 apresenta um ANFIS simplificado para duas entradas e uma saída. Para representar as diferentes capacidades de adaptação, utilizou-se quadrados para os nós que possuem parâmetros (nós adaptativos) e círculos para os nós sem parâmetros (nós fixos) (JANG, 1993).

De acordo com (JANG, 1993), cada uma das camadas tem as seguintes características:

Figura 14 – Arquitetura ANFIS



Fonte: Adaptado de Jang (1993)

- **Camada 1:** Sua saída são os graus de pertinência da respectiva entrada, baseado nas premissas das regras. Onde x é a entrada do nó i e A_i é a variável linguística associada ao seu respectivo, representado pela equação 3.

$$O_i^1 = \mu_{A_i}(x) \tag{3}$$

- **Camada 2:** É calculado o grau de pertinência para o consequente de cada regra. A saída de cada nó representa o grau de ativação de uma regra, dado pela equação 4.

$$\omega_i = \mu_{A_i}(x) \times \mu_{B_i}(y) \tag{4}$$

- **Camada 3:** É realizado a normalização do grau de ativação das regras, de acordo com a equação 5.

$$\overline{\omega_i} = \frac{\omega_i}{\omega_1 + \omega_2}, i = 1, 2, ... \tag{5}$$

- **Camada 4:** A saída desta camada é calculada pelo produto entre a saída normalizada da camada anterior pelo grau de ativação do consequente, representado pela equação 6.

$$O_i^4 = \overline{\omega_i} f_i \tag{6}$$

- **Camada 5:** Fornece como resultado a saída *crisp* do sistema, de acordo com a equação 7.

$$O_i^5 = \sum_i \overline{\omega_i} f_i \tag{7}$$

Dessa maneira é construído um sistema neuroadaptativo que é equivalente a um T1FIS do tipo *Takagi-Sugeno* (JANG, 1993). O processo de aprendizagem do ANFIS é feito de maneira

iterativa até que seja atingido o critério de parada.

2.4 MÉTRICAS DE AVALIAÇÃO

Erros de previsão são a diferença entre um valor observado e um valor previsto (HYNDMAN; ATHANASOPOULOS, 2018). Para Faceli *et al.* (2011), as métricas de avaliação mais utilizadas são o Erro Absoluto Médio, do inglês *Mean Absolute Error* (MAE) e o Erro Quadrático Médio, do inglês *Mean Squared Error* (MSE). Porém, outras métricas como o Erro Absoluto Médio Percentual, do inglês *Mean Absolute Percentage Error* (MAPE) e Raíz Quadrada do Erro Quadrático Médio, do inglês *Root Mean Squared Error* (RMSE) são utilizadas (HYNDMAN; ATHANASOPOULOS, 2018; IZBICKI; SANTOS, 2020; ALOORRAVI, 2024). A seguir, é apresentado o conceito de cada uma dessas métricas.

2.4.1 Erro Médio Absoluto (MAE)

É utilizada para verificar a diferença média absoluta entre o valor observado e o valor previsto (ALOORRAVI, 2024). Segundo Hyndman e Athanasopoulos (2018) é um erro que é dependente da escala, ou seja, os erros de previsão estão na mesma escala dos dados (HYNDMAN; ATHANASOPOULOS, 2018). A equação 8 apresenta seu cálculo.

$$MAE = \frac{1}{n}\sum_{n}^{i=1} |Y_i - \hat{Y}_i| \tag{8}$$

na qual n é o número de amostras de validação, Y_i é o valor real da amostra e $\hat{Y}_i$ é o valor estimado da amostra.

2.4.2 Erro Médio Quadrático (MSE)

O MSE se difere do MAE apenas na métrica de avaliação, a qual é quadrática (CHICCO; WARRENS; JURMAN, 2021). Este erro é apresentado pela equação 9.

$$MSE = \frac{1}{n}\sum_{n}^{i=1} \left(Y_i - \hat{Y}_i\right)^2 \tag{9}$$

na qual n é o número de amostras de validação, Y_i é o valor real da amostra e $\hat{Y}_i$ é o valor estimado da amostra.

O MSE é mais sensível aos valores extremos de erro do que o MAE (CHICCO; WARRENS; JURMAN, 2021). Dessa forma, pequenos erros têm uma ênfase maior (PALIT; POPOVICĆ, 2005).

2.4.3 Raíz Quadrada do Erro Quadrático Médio (RMSE)

O RMSE é uma derivação do MSE, com o intuito de padronizar as unidades de medida do MSE (CHICCO; WARRENS; JURMAN, 2021). Da mesma forma que o MAE, é dependente da escala (HYNDMAN; ATHANASOPOULOS, 2018), conforme a equação 10

$$RMSE = \sqrt{\frac{1}{n}\sum_{n}^{i=1}\left(Y_i - \hat{Y}_i\right)^2} \tag{10}$$

na qual n é o número de amostras de validação, Y_i é o valor real da amostra e $\hat{Y}_i$ é o valor estimado da amostra.

Modelos de que minimizam o MAE resultam em previsões mais próximas da mediana, enquanto modelos que minimizam o RMSE resultam em previsões mais próximas da média (HYNDMAN; ATHANASOPOULOS, 2018).

2.4.4 Erro Absoluto Médio Percentual (MAPE)

O MAPE é utilizado para quantificar a diferença percentual entre os valores previstos e os valores reais (ALOORRAVI, 2024). Como é um erro percentual, possui a vantagem de ser livre de unidade, podendo ser utilizado para comparar diferentes previsões (HYNDMAN; ATHANASOPOULOS, 2018). A equação 11 apresenta seu cálculo.

$$MAPE = \frac{1}{n}\sum_{n}^{i=1}\left|\frac{Y_i - \hat{Y}_i}{Y_i}\right| \cdot 100 \tag{11}$$

na qual n é o número de amostras de validação, Y_i é o valor real da amostra e $\hat{Y}_i$ é o valor estimado da amostra.

Como desvantagem, o MAPE tende a ser problemático quando os valores reais se aproximam de zero, pois sua fórmula envolve a divisão do erro absoluto pelo valor real, assim, quando esse valor é muito pequeno ou igual a zero, o erro percentual pode se tornar extremamente grande ou indefinido, levando a interpretações incorretas (HYNDMAN; ATHANASOPOULOS, 2018; CHICCO; WARRENS; JURMAN, 2021).

2.5 SISTEMAS DE INFERÊNCIA *FUZZY* UTILIZANDO *PYTHON*

A linguagem de programação *Python* tem se destacado como uma ferramenta essencial no contexto educacional e de pesquisa acadêmica atual, sendo desenvolvida por Guido Van Rossum e lançada em 1991. Essa linguagem de programação de alto nível tem ganhado cada vez mais popularidade nas universidades e centros de pesquisa ao redor do mundo (LI, 2021). Tal linguagem de programação tem sido amplamente adotada em cursos de programação, disciplinas de ciência de dados, engenharia e várias outras áreas (ZHU *et al.*, 2023).

A usabilidade do *Python* tem como pilar sua ampla biblioteca e em um sistema robusto de pacotes de terceiros. A linguagem já vem acompanhada de módulos úteis para diversas tarefas, e ainda é enriquecida por bibliotecas populares que permitem a realização de diversas tarefas, tais como desenvolvimento *web* e até aprendizado de máquina (ALI *et al.*, 2023).

Nesta seção, serão apresentadas as bibliotecas para *Python* que foram utilizadas para o desenvolvimento dos modelos T1FIS, IT2FIS e ANFIS.

2.5.1 Biblioteca *skfuzzy*

A biblioteca *skfuzzy* (também conhecida como *scikit-fuzzy*) traz a implementação de uma gama de ferramentas e algoritmos para computação e projetos envolvendo lógica *fuzzy*, tendo como objetivo principal fornecer à comunidade científica uma alternativa robusta e de código aberto às soluções para lógica *fuzzy*. Tal biblioteca é estruturada em módulos, organizados logicamente, facilitando tanto o uso geral quanto a exploração de funcionalidades específicas (SCIKIT-FUZZY DEVELOPERS, 2025).

A biblioteca organiza suas funções em três módulos principais:

- *membership*: funções de pertinência;
- *defuzzify*: métodos de defuzificação;
- *control*: sistema de controle fuzzy (variáveis, regras, inferência).

Para a criação das funções de pertinência, é utilizado o módulo *skfuzzy.membership*. Existem vários tipos de funções de pertinência que podem ser utilizados, porém, na Tabela 1, serão apresentados os três tipos mais utilizados.

Tabela 1 – Principais funções do módulo *fuzz.membership*

Função	**Descrição**
skfuzzy.trimf(x, [a, b, c])	Função de pertinência triangular
skfuzzy.trapmf(x, [a, b, c, d])	Função de pertinência trapezoidal
skfuzzy.gaussmf(x, mean, sigma)	Função de pertinência gaussiana

Fonte: Elaborado pelo autor.

Na Tabela 1, a variável x representa o universo de discurso da variável, a, b, c, e d representam os vértices da função, seja ela triangular ou trapezoidal, e $mean$ e $sigma$ representam a média e a variância da função gaussiana, respectivamente.

O módulo de defuzificação (*skfuzzy.defuzz*) é responsável por calcular um valor "crisp" a partir de um conjunto fuzzy agregado. Tal módulo contém vários algoritmos de defuzificação, conforme apresentado na Tabela 2

Tabela 2 – Métodos de defuzificação do módulo *skfuzzy.defuzz*

Função	**Descrição**
skfuzzy.defuzz(x, mfx, 'centroid')	Defuzificação pelo método "centroide"
skfuzzy.defuzz(x, mfx, 'bisector')	Defuzificação pelo método "bisetriz"
skfuzzy.defuzz(x, mfx, 'mom')	Defuzificação pelo método "média dos máximos"
skfuzzy.defuzz(x, mfx, 'som')	Defuzificação pelo método "mínimo dos máximos"
skfuzzy.defuzz(x, mfx, 'lom')	Defuzificação pelo método "máximo dos máximos"

Fonte: Elaborado pelo autor.

Por fim, tem-se o módulo de controle, no qual é realizado todo o design do modelo *fuzzy*. Neste módulo são definidos os antecedentes, consequentes, regras, o sistema fuzzy e a simulação. A Tabela 3 apresenta as funções deste módulo.

Tabela 3 – Funções do módulo de controle *skfuzzy.control*

Função	**Descrição**
skfuzzy.control.Antecedent	Define variável de entrada fuzzy
skfuzzy.control.Consequent	Define variável de saída fuzzy
skfuzzy.control.Rule	Criação da base de regras
skfuzzy.control.ControlSystem	Estrutura o sistema fuzzy a partir de regras
skfuzzy.control.ControlSystemSimulation	Simulação do sistema fuzzy

Fonte: Elaborado pelo autor.

2.5.2 Biblioteca *pyit2fls*

A biblioteca PyIT2FLS (*Python Interval Type-2 Fuzzy Logic Systems*) foi desenvolvida para facilitar a criação e implementação de IT2FIS em Python. Trata-se de uma ferramenta para a modelagem e simulação de sistemas *fuzzy* com incerteza associada, utilizando conjuntos *fuzzy* intervalar (HAGHRAH; GHAEMI; BADAMCHIZADEH, 2025).

Para modelos IT2FIS, a biblioteca apresenta várias classes, porém serão apresentadas as duas principais, conforme apresentado na Tabela 4.

Tabela 4 – Principais classes da biblioteca *pyit2fls*

Classe	**Descrição**
IT2FS	Conjunto Fuzzy Tipo-2 Intervalar
IT2Mamdani	Sistema Fuzzy Mamdani Tipo-2 Intervalar

Fonte: Elaborado pelo autor.

A classe IT2FS tem a função de representar conjuntos *fuzzy* tipo-2 intervalar, sendo definido por uma por uma UMF e uma LMF, delimitando assim a FOU associada ao grau de pertinência. Tal classe é definida, principalmente, por cinco parâmetros:

- Universo de discurso: Valores discretizados do domínio da variável linguística;
- UMF: Função de pertinência superior;
- Parâmetros da UMF: Parâmetros específicos da função de pertinência superior escolhida
- LMF: Função de pertinência inferior;
- Parâmetros da LMF: Parâmetros específicos da função de pertinência inferior escolhida

Assim como na biblioteca *skfuzzy*, existem várias funções de pertinência que podem ser utilizadas, tais como triangular, trapezoidal e gaussiana.

Já a classe IT2Mamdani é responsável pela implementação do sistema *fuzzy* Mamdani tipo-2 intervalar, permitindo a modelagem e inferência de regras fuzzy a partir dos conjuntos definidos pela classe IT2FS. Tal classe tem os principais métodos apresentados na Tabela 5.

Tabela 5 – Principais métodos da classe IT2Mamdani

Método	**Descrição**
add_input_variable	Adiciona uma variável de entrada ao sistema
add_output_variable	Adiciona uma variável de saída ao sistema
add_rule	Adiciona uma regra do tipo "Se-Então" à base de regras do sistema
evaluate	Avalia (simula) o sistema para um determinado conjunto de entradas

Fonte: Elaborado pelo autor.

Cada um dos métodos possui os seus parâmetros definidos de acordo com a sua função. No método "*evaluate*" são escolhidos o algoritmo de redução de tipo e de defuzificação.

2.6 BIBLIOTECA *LAZUARDY_ANFIS*

A biblioteca *lazuardy_anfis* representa uma implementação em Python do ANFIS, sendo uma versão melhorada da biblioteca original *anfis*. Esta biblioteca combina as capacidades de redes neurais com sistemas de inferência *fuzzy*, sendo uma ferramenta para modelagem de sistemas complexos e não lineares (LAZUARDY, 2024).

A biblioteca oferece suporte a três tipos de funções de pertinência, seguindo a nomenclatura da biblioteca *skfuzzy*, sendo elas:

- gaussmf: Função de pertinência gaussiana;
- gbellmf: Função de pertinência sino generalizado;
- sigmf: Função de pertinência sigmoide

Tabela 6 – Principais funções e métodos da biblioteca *lazuardy_anfis*

Função /Método	**Descrição**	**Parâmetros**
membershipfunction.MemFuncs	Cria o conjunto de funções de pertinência das entradas e saídas	Funções de pertinência de cada uma das variáveis de entrada e saída
anfis.ANFIS()	Cria o modelo ANFIS	X, Y, conjunto de funções de pertinência
trainHybridJangOffLine()	Executa o treinamento do modelo	número de épocas
predict()	Realiza predições com o modelo treinado	Conjunto de dados

Fonte: Elaborado pelo autor.

A Tabela 6 apresenta as principais funções e métodos desta biblioteca.

A biblioteca *lazuardy_anfis* representa uma implementação do sistema ANFIS em Python, tendo uma arquitetura flexível e com suporte a múltiplas funções de pertinência. Dessa maneira, ela pode ser adequada para uma ampla gama de aplicações em modelagem de sistemas.

3 MATERIAL E MÉTODO

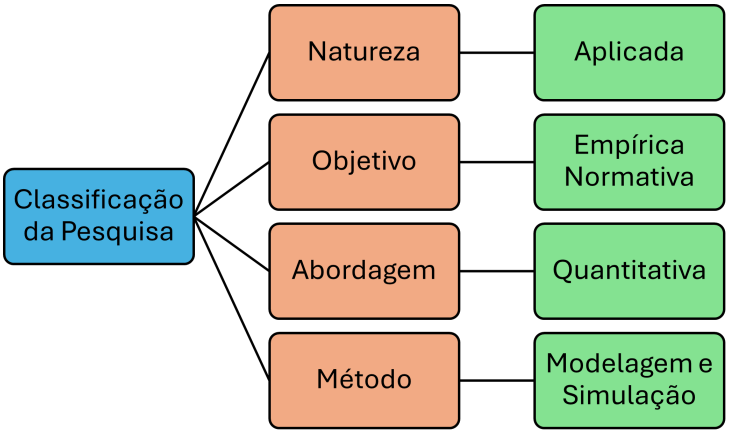
Neste capítulo, são apresentados os métodos que foram utilizados para o desenvolvimento dos modelos de estimativa de curva de carga em unidades consumidoras residenciais, com base na aplicação das lógicas *fuzzy* (T1FIS, IT2FIS e ANFIS). Dessa forma, é apresentada a estruturação de cada um dos modelos *fuzzy*, definindo as variáveis de entrada e saída, funções de pertinência e base de regras, bem como do modelo ANFIS.

3.1 CLASSIFICAÇÃO DA PESQUISA

A pesquisa pode ser caracterizada como um conjunto de ações que são propostas para encontrar a solução de um problema, sendo uma atividade que faz a combinação entre teoria e dados, por meio de procedimentos científicos sistemáticos e racionais (SILVA; MENEZES, 2005; GIL, 2008). A metodologia da pesquisa científica em engenharia de produção normalmente se utiliza a classificação com relação ao escopo da pesquisa, levando também em consideração outros tipos de desenvolvimentos, tais como trabalhos teórico-conceituais, de modelagem e simulação, dentre outros (FILIPPINI, 1997).

A pesquisa desenvolvida neste trabalho pode ser classificada como pesquisa aplicada com objetivo empírico normativo, abordagem quantitativa e método de modelagem e simulação. A Figura 15 apresenta a classificação da pesquisa.

Figura 15 – Classificação da Pesquisa



Fonte: Adaptado de Turrioni e Mello (2012)

Quanto à natureza, é classificada como pesquisa aplicada, pois os resultados podem ser aplicados ou utilizados para a solução de problemas reais (TURRIONI; MELLO, 2012), quanto ao objetivo, caracteriza-se como empírico normativo, pois busca estratégias para aperfeiçoar os resultados disponíveis na literatura do tema, bem como comparar as estratégias utilizadas (BERTRAND; FRANSOO, 2002), descrevendo os modelos utilizados para a obtenção dos

resultados. Quanto à abordagem, caracteriza-se como quantitativa, pois se trata da aplicação de modelos matemáticos e estatísticos para realizar as análises dos resultados (CASARIN; CASARIN, 2012). Ou seja, a pesquisa traduz os números em informações para realizar suas análises (TURRIONI; MELLO, 2012) e quanto ao método, caracteriza-se por ser de modelagem e simulação, pelo motivo de que se faz o experimento de um sistema real, utilizando-se de um modelo e analisando-se como este irá responder às modificações que lhe forem propostas (TURRIONI; MELLO, 2012).

3.2 LOCAL DE ESTUDO

A região sudeste do Brasil é formada pelos estados de Minas Gerais, Espírito Santo, Rio de Janeiro e São Paulo e de acordo com INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (2023) é a região mais populosa do país, com 41,8% da população brasileira e possui uma área territorial de 924.558,34 km^2. Além de ser a região mais desenvolvida do país, é responsável por 52,3% do PIB do Brasil.

Na PPH-2019 os estados de São Paulo, Rio de Janeiro e Minas Gerais tiveram 1100 amostras para cada um dos estados e 625 amostras para o estado do Espírito Santo. A região sudeste foi responsável por cerca de 20,9% dos domicílios entrevistados em todo o país. Por sua ampla participação na PPH-2019 e pelo seu impacto nacional, a seleção da região sudeste torna-se ideal para as análises quantitativas e qualitativas no escopo da presente pesquisa.

3.3 ETAPAS DA PESQUISA

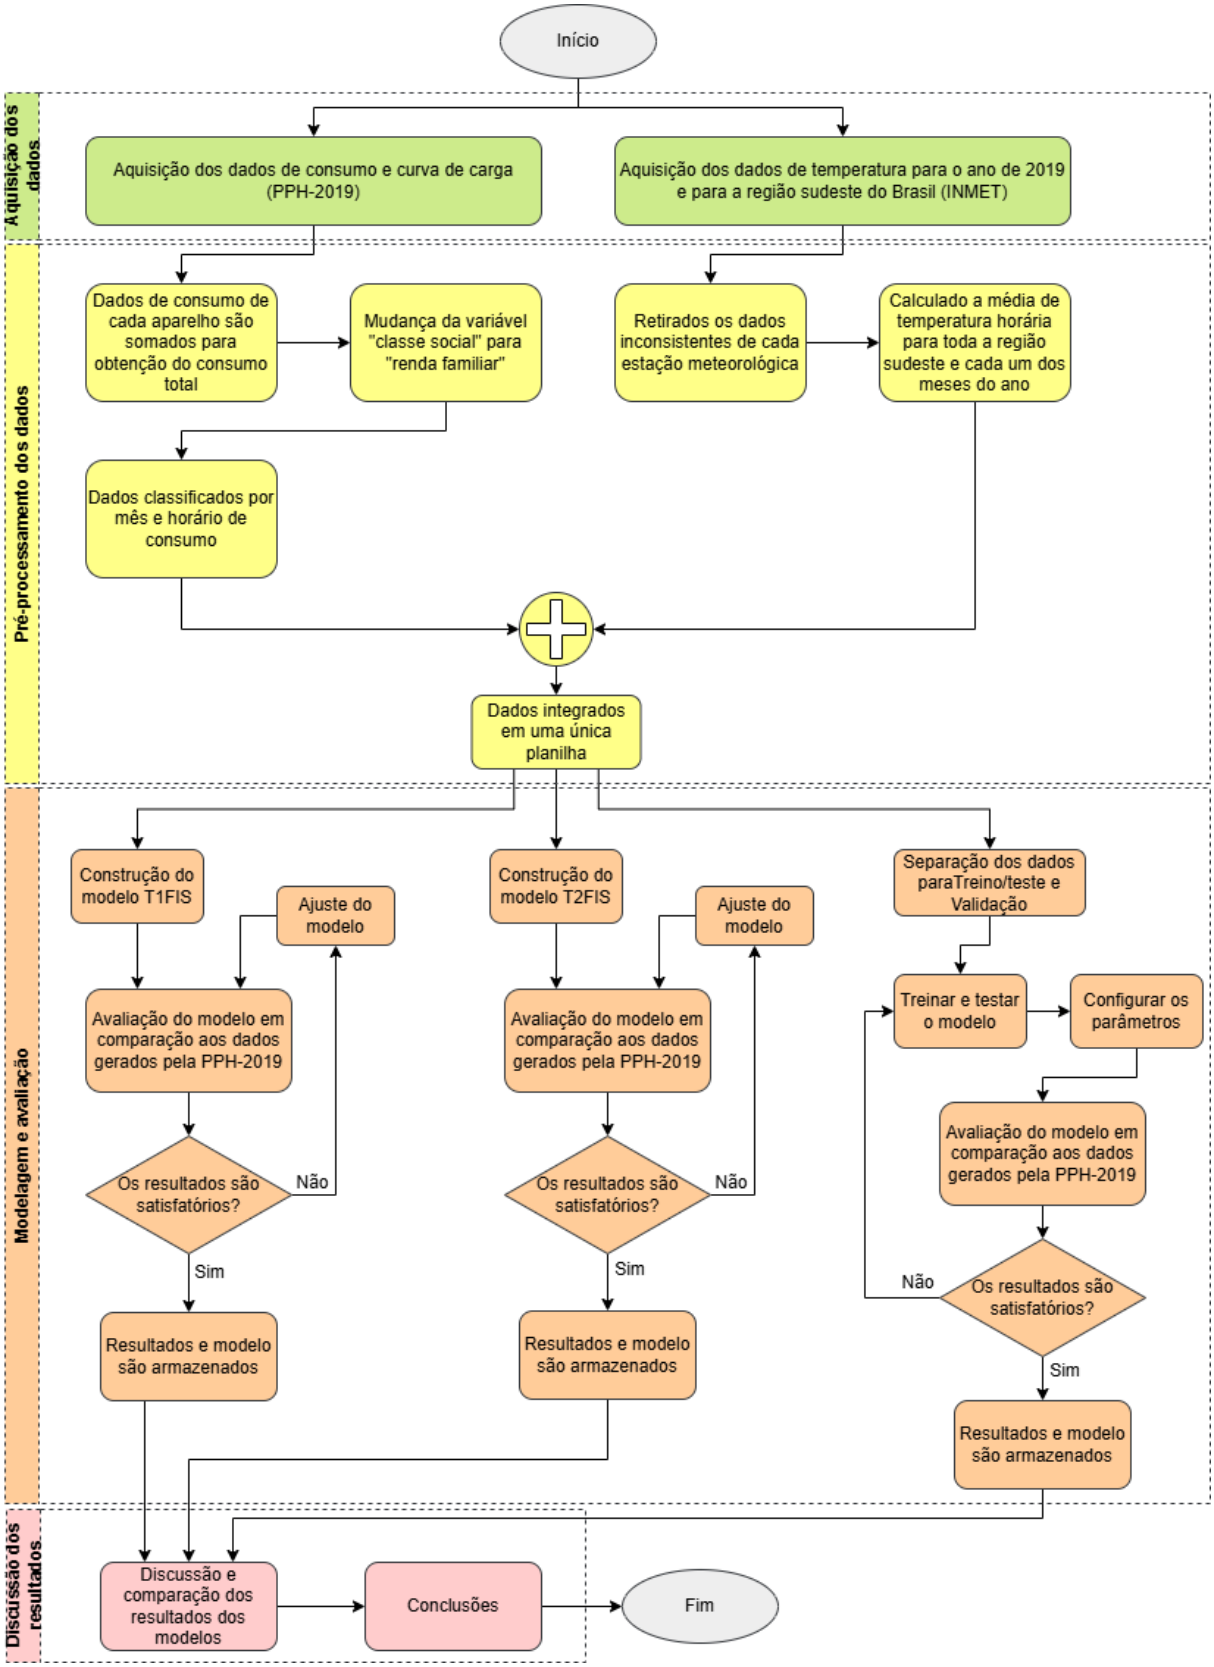
A fim de garantir a clareza e a organização do desenvolvimento desta pesquisa, esta seção apresenta as etapas da pesquisa que foram adotadas ao longo do estudo. Cada uma delas foi planejada para permitir a construção, implementação e validação dos modelos baseados em lógica *fuzzy*, para a estimativa de curva de carga em unidades consumidoras residenciais, contemplando desde a aquisição e o pré-processamento dos dados até a construção dos sistemas de inferência *fuzzy*, passando pela modelagem, avaliação e análise dos resultados. A Figura 16 ilustra um fluxograma com as etapas principais que estruturam esta pesquisa, permitindo uma visão geral do caminho percorrido para alcançar os objetivos propostos.

A seguir será detalhado cada uma das etapas que são representadas na Figura 16, com exceção da etapa de discussão dos resultados, a qual será apresentada nos capítulos seguintes.

3.3.1 Aquisição de dados

Nesta etapa do trabalho, é realizada a aquisição dos dados que serão utilizados para teste e validação dos modelos T1FIS e IT2FIS. No modelo ANFIS, tais dados serão utilizados para treinamento, teste e validação.

Figura 16 – Fluxograma das etapas da pesquisa



Fonte: Elaborado pelo autor.

3.3.1.1 Dados de consumo e curva de carga

Os dados de consumo de energia para o setor residencial foram obtidos através da PPH-2019, elaborada pelo Programa Nacional de Conservação de Energia Elétrica – Procel em parceria com a Eletrobras.

As PPHs têm como intuito "conhecer o comportamento, os hábitos, as características de consumo, além do nível de conhecimento sobre eficiência energética da população brasileira" (ELETROBRAS, 2019a), sendo realizadas pela Eletrobras, por meio do Programa Nacional de Conservação de Energia Elétrica (Procel). Tais pesquisas são uma importante ferramenta de gestão, sendo que seus dados podem contribuir para o gerenciamento das ações do Procel e no planejamento energético nacional (ELETROBRAS, 2019a).

A primeira pesquisa foi realizada em 1988 em âmbito nacional, sendo denominada de "Pesquisa de Posse de Eletrodomésticos e Hábitos de Consumo" na classe residencial. Nesta oportunidade, foram entrevistados 10.818 consumidores em 291 municípios, abrangendo todas as regiões do país (PROCEL, 2006; ELETROBRAS, 2019a).

Em 1997/98 foi realizada a segunda pesquisa, ainda no segmento residencial. Ao todo foram pesquisados 15.870 consumidores em 15 estados e o Distrito Federal (PROCEL, 2006; ELETROBRAS, 2019a).

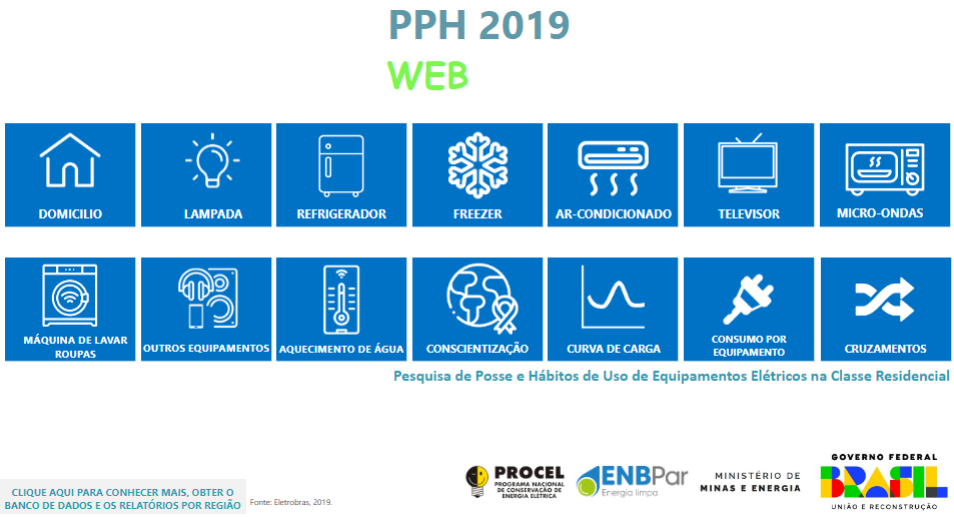
De 2004 a 2006 foi realizada a terceira pesquisa, porém ela foi mais ampla e acabou abrangendo mais setores de consumo, além do residencial, sendo eles comercial/industrial e poderes públicos. Nesta pesquisa foram aplicadas 14.442 entrevistas, sendo 9.847 no segmento residencial (PROCEL, 2006; ELETROBRAS, 2019a).

A mais recente pesquisa foi realizada em 2019, voltando a ser apenas para o setor residencial. Esta pesquisa foi a maior realizada no setor, contando com 18.875 amostras, distribuídas em todos os estados e o Distrito Federal. Nos estados de São Paulo, Rio de Janeiro, Minas Gerais e Bahia, foram coletados 1.100 amostras em cada um deles, pois são os estados com maior número de domicílios. Para os demais estados e o Distrito Federal, foram coletadas 625 amostras para cada um deles. A escolha dos municípios onde foram coletadas as informações seguiu o seguinte critério: todas as capitais deveriam ser cobertas, assim como as cidades com número de domicílios maior ou igual a 100 mil. Caso um estado não tivesse cidades que atendessem a esse critério, seria considerada a cidade com maior número de domicílios (ELETROBRAS, 2019a).

Como resultado da PPH 2019, tem-se o PPH 2019 WEB, um painel interativo de informações com a apresentação dos resultados. A Figura 17 apresenta uma captura da tela do PPH WEB. Neste painel pode-se encontrar diversas informações dos domicílios amostrados e, ao acessar uma categoria de dados, pode-se obter as análises referentes ao conteúdo acessado, podendo filtrar os dados por região (Centro-Oeste, Nordeste, Norte, Sudeste e Sul), por classe social (A, B1, B2, C1, C2, D-E) e por mês do ano (Janeiro a Dezembro).

Para a utilização dos dados no presente trabalho, foi acessada a categoria de curva de carga e acessada a análise da curva por classe social, obtendo-se os dados de acordo com a região

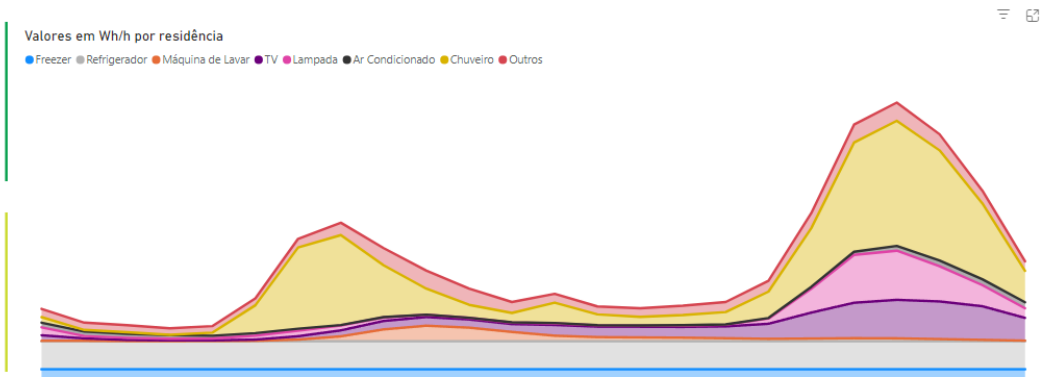
Figura 17 – Tela do PPH 2019 WEB



Fonte: ELETROBRAS (2019b)

selecionada, a classe social e o mês. A Figura 18 apresenta a curva de carga para a região sudeste do Brasil, sem a utilização dos filtros para categoria social ou mês do ano. É possível também fazer a obtenção dos dados em forma de tabela, conforme apresentado na Figura 19.

Figura 18 – Tela da curva de carga para a região sudeste

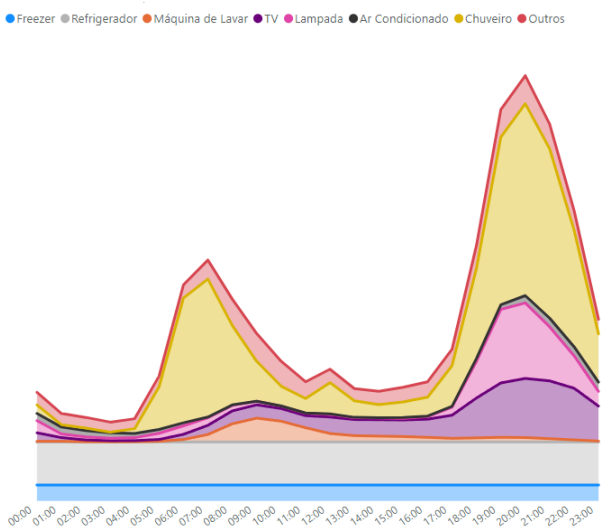


Fonte: ELETROBRAS (2019b)

A partir das tabelas, os dados foram coletados mantendo fixa a região sudeste e alterando os filtros de classe social e mês do ano. Dessa forma, foram obtidas 72 curvas de carga, compiladas em uma planilha para utilização neste trabalho.

Os dados do consumo residencial são apresentados na Figura 20, com um total de 1728 amostras, sendo: 6 classes sociais, 12 meses e 24 horas por dia. Os dados têm uma tendência de diminuição, pois estão separados por classe social e em ordem decrescente, assim as primeiras amostras se referem à classe social mais alta e as últimas amostras se referem à classe social mais baixa, refletindo assim o consumo para cada uma delas.

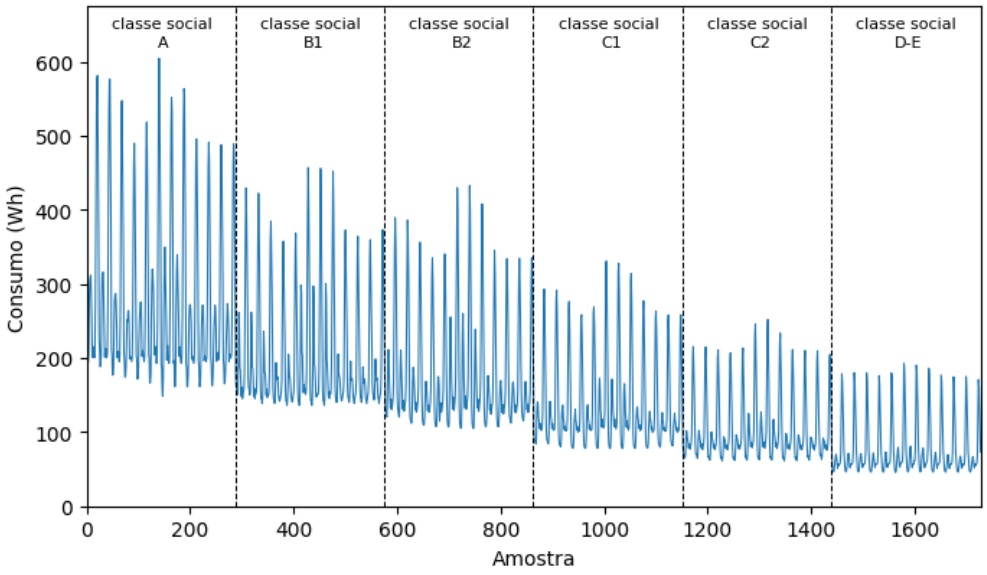
Figura 19 – Tela da curva de carga para a região sudeste em formato de tabela



Horario	Freezer	Refrigerador	Máquina de Lavar	TV	Lampada	Ar Condicionado	Chuveiro	Outros
00:00	15,49	41,94	0,63	8,26	11,86	7,00	8,30	12,29
01:00	15,49	41,94	0,68	3,56	3,56	6,71	2,35	10,91
02:00	15,49	41,94	0,23	1,71	3,09	6,09	2,40	10,42
03:00	15,49	41,94	0,23	1,01	2,39	5,33	0,56	9,82
04:00	15,49	41,94	0,27	1,04	2,87	4,03	4,75	9,70
05:00	15,49	41,94	0,68	1,72	6,05	3,69	41,61	10,45
06:00	15,49	41,94	2,40	5,05	8,25	2,97	121,54	12,96
07:00	15,49	41,94	7,30	8,91	7,46	0,57	134,52	18,47
08:00	15,49	41,94	17,67	12,61	5,34	0,45	77,39	25,69
09:00	15,49	41,94	23,20	12,97	3,53	0,03	38,85	27,06
10:00	15,49	41,94	20,25	12,31	2,40	0,13	19,28	24,32
11:00	15,49	41,94	13,86	11,77	2,34	0,25	14,07	16,33
12:00	15,49	41,94	8,25	16,06	2,50	0,50	30,48	13,09
13:00	15,49	41,94	6,16	15,67	1,89	0,24	16,20	11,86
14:00	15,49	41,94	5,71	15,95	1,68	0,35	12,74	12,97
15:00	15,49	41,94	5,30	16,13	1,63	0,85	15,14	14,23
16:00	15,49	41,94	4,49	17,69	2,45	0,59	18,40	15,02
17:00	15,49	41,94	3,53	22,55	7,75	0,92	39,52	16,13
18:00	15,49	41,94	3,99	38,82	35,63	2,86	87,78	22,37
19:00	15,49	41,94	4,53	52,99	71,60	4,62	163,34	26,89
20:00	15,49	41,94	4,31	57,57	73,56	7,16	187,01	27,29
21:00	15,49	41,94	3,17	56,33	52,57	8,52	164,88	24,14
22:00	15,49	41,94	2,04	50,29	31,59	8,78	113,59	19,10
23:00	15,49	41,94	0,91	33,99	14,37	9,05	47,01	14,17

Fonte: ELETROBRAS (2019b)

Figura 20 – Consumo de energia elétrica por hora no ano de 2019, por classe social e por mês



Fonte: Elaborado pelo autor.

3.3.1.2 Dados de temperatura

Na Figura 5, existem vários fatores que podem influenciar no consumo de energia elétrica residencial, tais como política energética, eficiência técnica, comportamento humano, estrutura da residência e variáveis externas (por exemplo, clima) (HAAS, 1997).

A temperatura do ar é afetada pela localização geográfica, pelos fatores ambientais e pela variabilidade climática, que, por sua vez, afetam o consumo de eletricidade. Assim, a variação da temperatura do ar faz com que os dispositivos de resfriamento e aquecimento funcionem mais e, portanto, tenham um impacto maior no consumo de energia (IMANI, 2021).

Foram coletados os dados sobre a temperatura no Banco de Dados Meteorológicos do Instituto Nacional de Meteorologia (INMET). Para realizar a coleta, foi acessado o site do INMET (portal.inmet.gov.br) e selecionada a opção "Dados Meteorológicos", em seguida "Banco de Dados Meteorológicos". Ao acessar o Banco de Dados, é exigido um e-mail para o envio das informações pertinentes.

Para fazer a geração dos dados, é possível selecionar diversas opções no Banco de Dados, tais como: tipos de dados, tipos de estação, abrangência, período (data inicial e data final), regiões, variáveis de interesse e estações meteorológicas.

Para o presente trabalho, como a PPH foi realizada no ano de 2019 e os dados das curvas de carga foram delimitados para a região Sudeste, foram selecionados os dados horários das estações meteorológicas automáticas para o período de 01/01/2019 a 31/12/2019, abrangendo todas as estações meteorológicas da região sudeste. Apenas a variável "temperatura do ar - bulbo seco"foi selecionada. As Figuras 19 e 20 apresentam todas as opções selecionadas no Banco de Dados Meteorológicos.

O Banco de Dados Meteorológicos envia e-mails para confirmar a requisição solicitada, avisar que a requisição está em andamento e informar que a requisição foi finalizada, disponibilizando, assim, os dados para o usuário.

3.3.2 Pré-processamento dos dados

Conjuntos de dados podem conter uma variedade de formas, características, dimensões e formatos, além de poderem ser provenientes de várias fontes distintas. Os valores dos atributos podem ser numéricos ou simbólicos, podem conter erros, ruídos ou valores incorretos e também podem incluir valores inconsistentes ou duplicados (FACELI *et al.*, 2011; GARCíA; LUENGO; HERRERA, 2015).

Para melhorar a qualidade dos dados, faz-se necessária a utilização de técnicas de pré-processamento de dados, podendo assim levar à construção de modelos que refletem mais fielmente a realidade dos dados (FACELI *et al.*, 2011).

Os dados de temperatura obtidos a partir do Banco de Dados Meteorológicos são retornados em um arquivo para cada estação meteorológica, e cada arquivo contém os dados da estação, a data da medição, o horário da medição e a temperatura medida. Foram coletadas as informações de temperatura de todas as estações meteorológicas do sudeste brasileiro, considerando apenas o ano de 2019 (mesmo ano base da PPH).

De posse dos dados de temperatura, foram excluídos os dados nos quais faltavam os valores de temperatura e, logo após, foi dado início ao tratamento dos *outliers*. Para isso, foi utilizada a regra do intervalo interquartil (IQR) das amostras, onde tal intervalo é calculado como a diferença entre o terceiro quartil (Q_3) e o primeiro quartil (Q_1), conforme a equação 12.

$$IQR = Q_3 - Q_1 \tag{12}$$

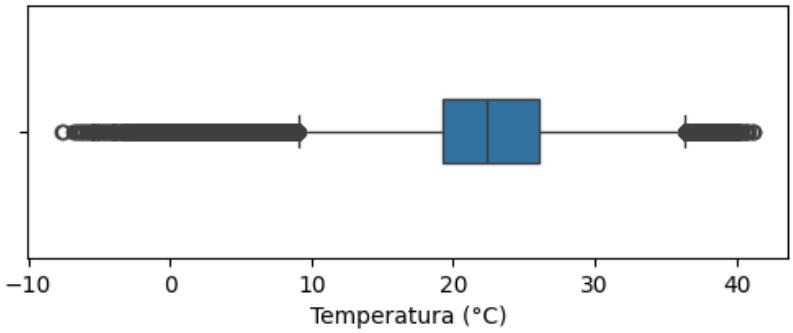
A Figura 21 apresenta um gráfico do tipo *boxplot* para os dados de temperatura. Pode-se observar que tais dados apresentam possíveis *outliers*. De acordo com (IGLEWICZ; HOAGLIN, 1993) e (DUNN, 2021), observações até 1,5 vezes o IQR são consideradas potenciais *outliers*. Para isso, foram calculados o limite superior (LS) e o limite inferior (LI), com base no IQR, conforme a as equações 13 e 14.

$$LI = Q_1 - 1,5 \cdot IQR \tag{13}$$

$$LS = Q_3 + 1,5 \cdot IQR \tag{14}$$

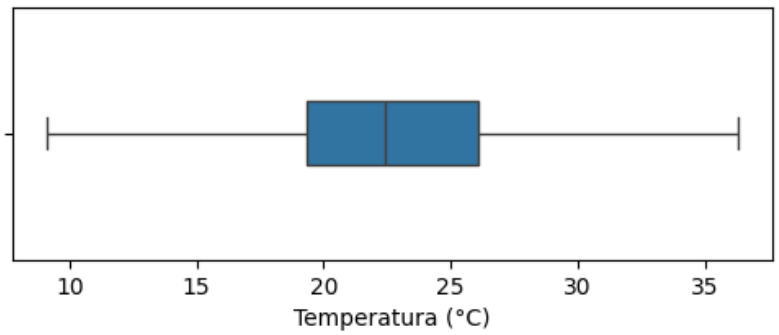
Os valores de temperatura fora do intervalo [LI, LS] foram considerados *outliers* e excluídos da base de dados. Tal exclusão representa uma pequena parcela dos dados, cerca de 1%, e não causa prejuízos. A Figura 22 apresenta os dados de temperatura após a exclusão dos *outliers*.

Figura 21 – Dados de temperatura com possíveis *outliers*



Fonte: Elaborado pelo autor.

Figura 22 – Dados de temperatura com a exclusão dos *outliers*



Fonte: Elaborado pelo autor.

Os dados extraídos da PPH foram inseridos em uma planilha. Como tais dados são por equipamentos, foi somado a energia consumida de cada aparelho e adicionado à uma coluna. Dessa maneira, obteve-se uma planilha com as classes sociais, hora, consumo horário de cada classe e mês do ano.

Como as classes sociais são classificadas em códigos, como: A, B1, B2, C1, C2 e D-E, tais valores foram convertidos para valores de renda familiar, de acordo com a classificação de renda, para o ano de 2019, da Associação Brasileira de Empresas de Pesquisa (ASSOCIAÇÃO BRASILEIRA DE EMPRESAS DE PESQUISA, 2019).

Os meses podem ser classificados em números, de 1 a 12, porém para a utilização neste trabalho essa variável foi substituída pelos dados médios horários de temperatura, adquiridos anteriormente. Assim, os dados finais utilizados são compostos pelas seguintes variáveis:

- Renda familiar: representadas pela renda familiar, de acordo com a classe social;
- Temperatura: representada pela temperatura horária média de toda a região sudeste para o referido mês;
- Horário: representado pelo intervalo horário de consumo;
- Consumo total: Consumo horário residencial para o referido horário e mês.

Os dados foram adquiridos das fontes disponíveis, passaram por um pré-processamento e foram integrados em uma única planilha. Assim, a próxima etapa do trabalho é a construção dos modelos, uma vez que os dados já se encontram prontos para serem utilizados.

3.3.3 Modelagem

A seguir serão apresentadas as modelagens adotadas para o desenvolvimento deste trabalho. Inicialmente, será exposto o modelo T1FIS, o qual é amplamente utilizado por sua simplicidade e facilidade de implementação. Em seguida, será apresentada a extensão desse modelo, o IT2FIS, que incorpora um grau adicional de incerteza e permite um tratamento mais robusto de incertezas. Por fim, será detalhado o modelo ANFIS, que combina a capacidade de aprendizado de redes neurais com a flexibilidade da lógica *fuzzy*, permitindo a construção de sistemas adaptativos baseados em dados históricos.

A modelagem proposta neste trabalho visa comparar o desempenho dessas abordagens, destacando suas vantagens, limitações e aplicabilidade ao contexto do consumo de energia do setor residencial.

Para manter a consistência com as convenções adotadas na linguagem de programação Python, os valores numéricos empregados na construção dos modelos ou obtidos como resultados das simulações, foram utilizados e apresentados no padrão americano de numeração, no qual o ponto é empregado como separador decimal, diferindo do padrão brasileiro, que utiliza a vírgula como delimitador decimal.

3.3.3.1 Modelo T1FIS

Para a estimativa do consumo horário utilizando modelos T1FIS, tem-se como base as pesquisas de (ABREU *et al.*, 2015; ABREU *et al.*, 2020; ZÚÑIGA; CASTILLA; AGUILAR,

2014). No trabalho de (ABREU *et al.*, 2015; ABREU *et al.*, 2020), os autores utilizaram como entrada do T1FIS os períodos do dia e a ocupação da residência e validaram o sistema utilizando como referência a medição de consumo de energia de dois conjuntos de residências, porém os autores não deixam claro como esses dados foram coletados nem qual a quantidade de amostras que foram utilizadas.

No trabalho de (ZÚÑIGA; CASTILLA; AGUILAR, 2014) foi utilizado um T1FIS tendo como entrada "períodos do dia" para estimar a curva de consumo referente ao uso do fogão elétrico e da máquina de lavar. Foi utilizado outro T1FIS tendo como entradas "períodos do dia" e "dia-noite", sendo que este sistema foi utilizado para estimar a curva de consumo referente ao uso da iluminação.

Um dos modelos proposto pela presente pesquisa é de um modelo T1FIS *Mamdani*, para estimativa de consumo horário de uma residência do sudeste brasileiro. O modelo foi implementado na linguagem de programação *Python* utilizando a biblioteca apresentada na seção 2.5.

As variáveis de entrada e saída foram escolhidas de acordo com os dados coletados da PPH-2019 e do Banco de Dados Meteorológicos. Dessa forma, como entrada foram selecionadas as variáveis "renda familiar", "temperatura" e "horário". Com base nessas entradas o modelo estima a sua saída, sendo o consumo de energia elétrica. A seguir, será detalhado cada uma das entradas e saída do modelo.

As funções de pertinência mais simples de se implementar são as triangulares e trapezoidais, sendo que as triangulares são as mais utilizadas na maioria dos trabalhos. Além disso, a escolha da quantidade de funções bem como do seu intervalo tem um grande impacto no resultado dos sistemas *fuzzy* (SADOLLAH, 2018). Para este trabalho, inicialmente, nas entradas e saídas foram utilizadas funções de pertinência com formato triangulares e trapezoidais, porém foram feitos outros modelos com funções de pertinência gaussianas, a fim de verificar o impacto nos resultados.

A função de pertinência triangular é definida por três parâmetros (a, b e c), onde a é o início da subida da função, b é o pico da função (onde a pertinência é igual a 1) e c é o fim da descida da função. A Figura 23a apresenta a forma gráfica de tal função de pertinência e a seguir é apresentada sua fórmula matemática.

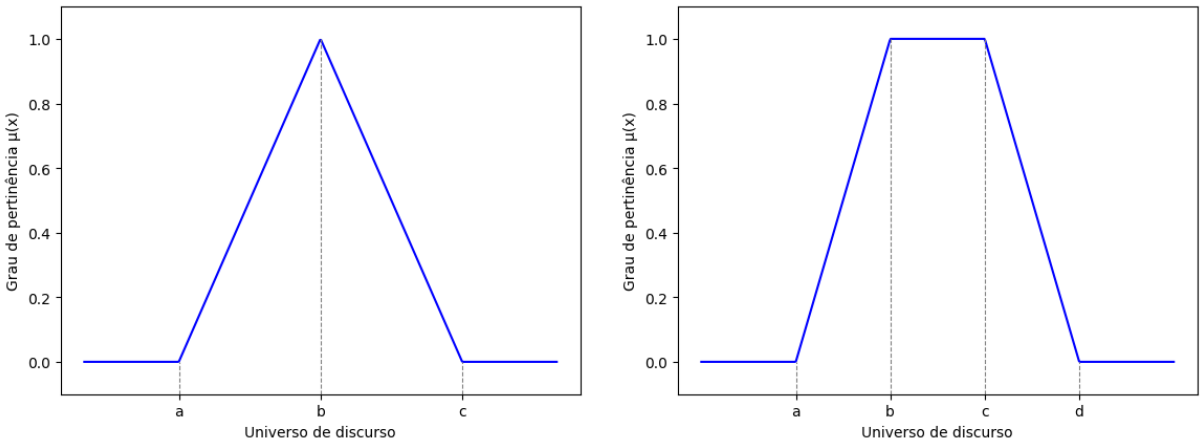
$$\mu_{\text{tri}}(x; a, b, c) = \begin{cases} 0, & x \leq a, \\ \dfrac{x-a}{b-a}, & a < x \leq b, \\ \dfrac{c-x}{c-b}, & b < x < c, \\ 0, & x \geq c. \end{cases} \tag{12}$$

Já a função de pertinência trapezoidal é definida por quatro parâmetros (a, b, c e d), onde a é o ponto onde a pertinência começa a aumentar seu valor, b é o início da região com pertinência igual a 1, c é o fim da região com pertinência igual a 1 e d é o ponto onde a pertinência volta a 0. A Figura 23b apresenta a forma gráfica de tal função de pertinência e a seguir é apresentada sua

fórmula matemática.

$$\mu_{\text{trap}}(x; a, b, c, d) = \begin{cases} 0, & x \leq a, \\ \dfrac{x-a}{b-a}, & a < x \leq b, \\ 1, & b < x \leq c, \\ \dfrac{d-x}{d-c}, & c < x < d, \\ 0, & x \geq d. \end{cases} \tag{13}$$

Figura 23 – Funções de pertinência triangular e trapezoidal



(a) Função de pertinência triangular

(b) Função de pertinência trapezoidal

Fonte: Elaborado pelo autor.

A seguir será detalhado cada uma das entradas e saídas do sistema, porém foram realizados outros testes com diferentes formatos e números de funções de pertinência, os quais serão discutidos com maior profundidade no Capítulo 4.

3.3.3.1.1 Renda Familiar

A entrada "renda familiar" é classificada de acordo com a renda familiar de cada uma das classes sociais. Conforme mencionado anteriormente, no pré-processamento dos dados, estes valores foram estabelecidos de acordo com a Associação Brasileira de Empresas de Pesquisa, dessa forma, para esta variável o universo de discurso vai de R$0,00 até R$25000,00.

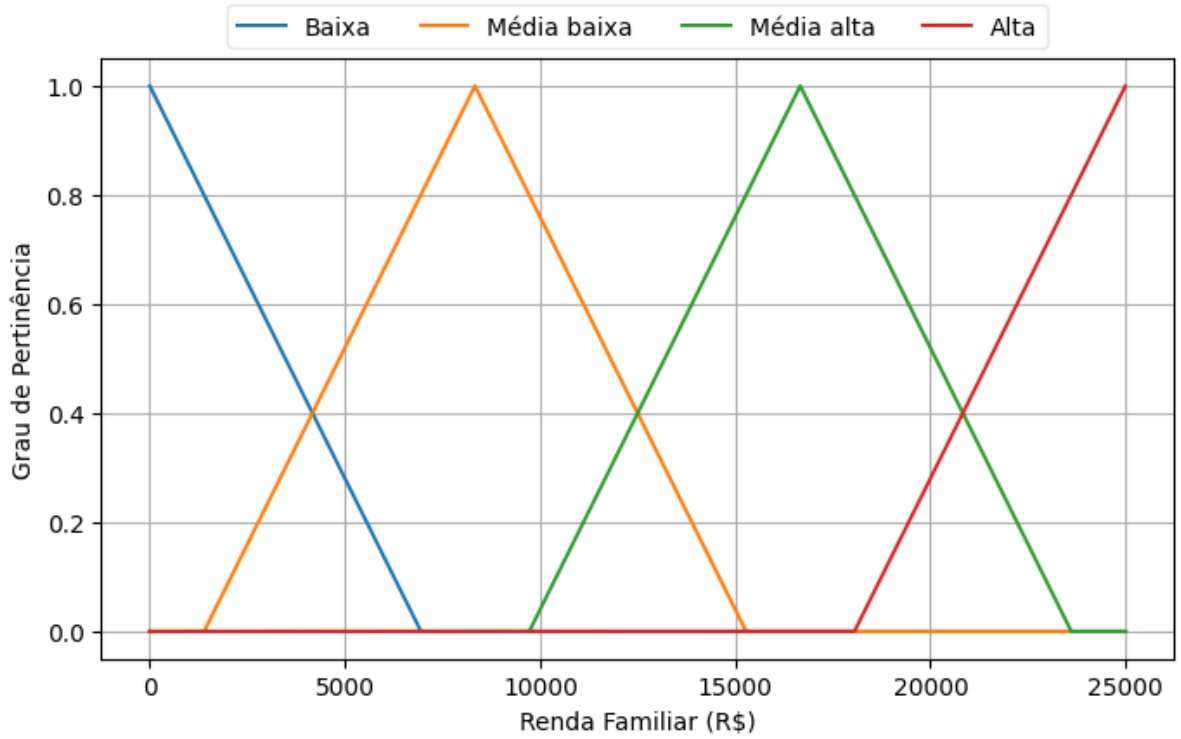
Para o modelo T1FIS, tal entrada foi classificada em quatro funções de pertinência, sendo elas "baixa", "média-baixa", "média-alta" e "alta". A Tabela 7 apresenta os parâmetros utilizados para cada uma das funções de pertinência e a Figura 24 apresenta as funções de pertinência utilizadas no conjunto *fuzzy* para a variável de entrada "renda familiar".

Tabela 7 – Parâmetros de classificação do modelo T1FIS para a entrada “classe social”

Classificação	**Parâmetros**
baixa	[0, 0, 6944]
média-baixa	[1390, 8333, 15276]
média-alta	[9722, 16666, 23610]
alta	[18055, 25000, 25000]

Fonte: Elaborado pelo autor.

Figura 24 – Funções de pertinência do modelo T1FIS para a entrada “renda familiar”



Fonte: Elaborado pelo autor.

3.3.3.1.2 Temperatura

Para a entrada “temperatura”, o universo de discurso foi definido de acordo com a temperatura máxima (30,79°C) e mínima (13,38°C) dos dados. Tal entrada foi classificada em três funções de pertinência, sendo elas “baixa”, “média” e “alta”.

A Tabela 8 apresenta os parâmetros utilizados para cada uma das funções e a Figura 25 apresenta as funções de pertinência utilizadas no conjunto *fuzzy* para a variável de entrada “temperatura”.

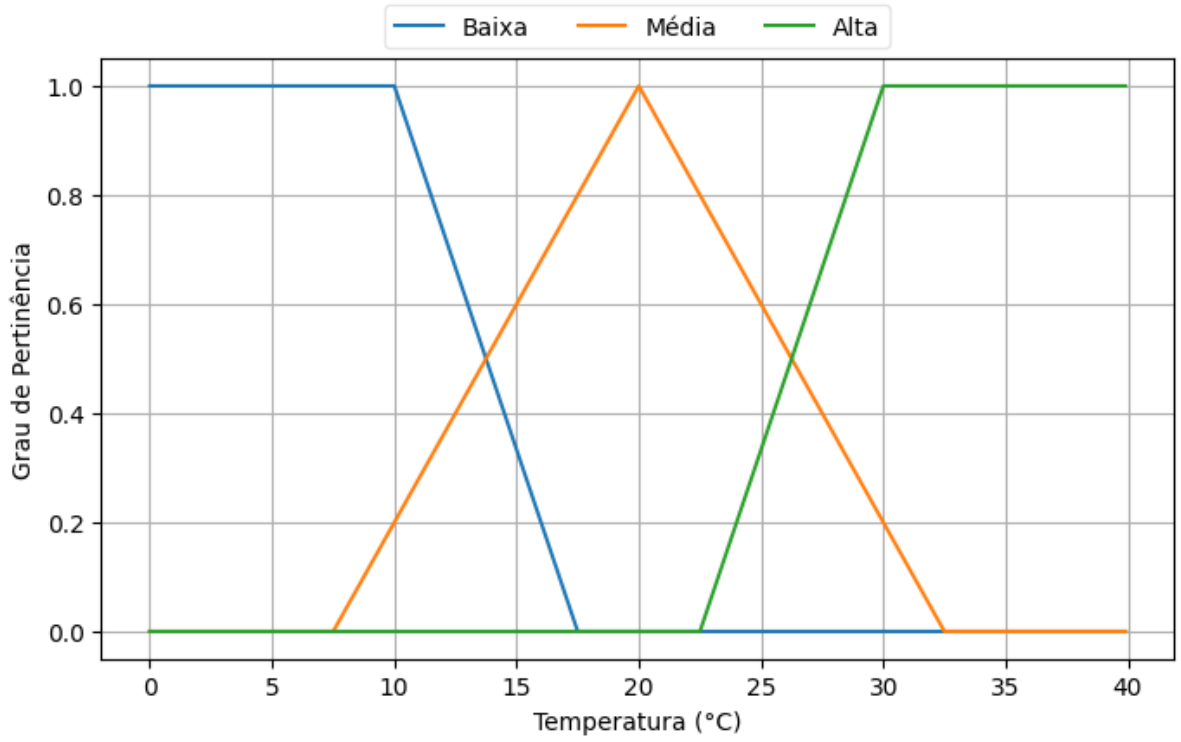
Cabe aqui ressaltar que a temperatura utilizada foi a temperatura média de toda a região sudeste do Brasil, para o ano de 2019, cujos valores foram obtidos através do Banco de Dados Meteorológicos, conforme já foi explicado anteriormente.

Tabela 8 – Parâmetros de classificação do modelo T1FIS para a entrada “temperatura”

Classificação	**Parâmetros**
baixa	[0, 0, 10, 17.5]
média	[7.5, 20, 32.5]
alta	[22.5, 30, 40, 40]

Fonte: Elaborado pelo autor.

Figura 25 – Funções de pertinência do modelo T1FIS para a entrada “temperatura”



Fonte: Elaborado pelo autor.

3.3.3.1.3 Horário

Para a entrada “horário” o universo de discurso foi definido com resolução de uma hora, de acordo com os horários do dia, sendo de 0 h até às 23 h. Para esta entrada, a sua classificação foi realizada de acordo com o hábito diário de consumidores em geral, sendo classificada em “sono 1”, “manhã”, “almoço”, “tarde”, “noite” e “sono 2”.

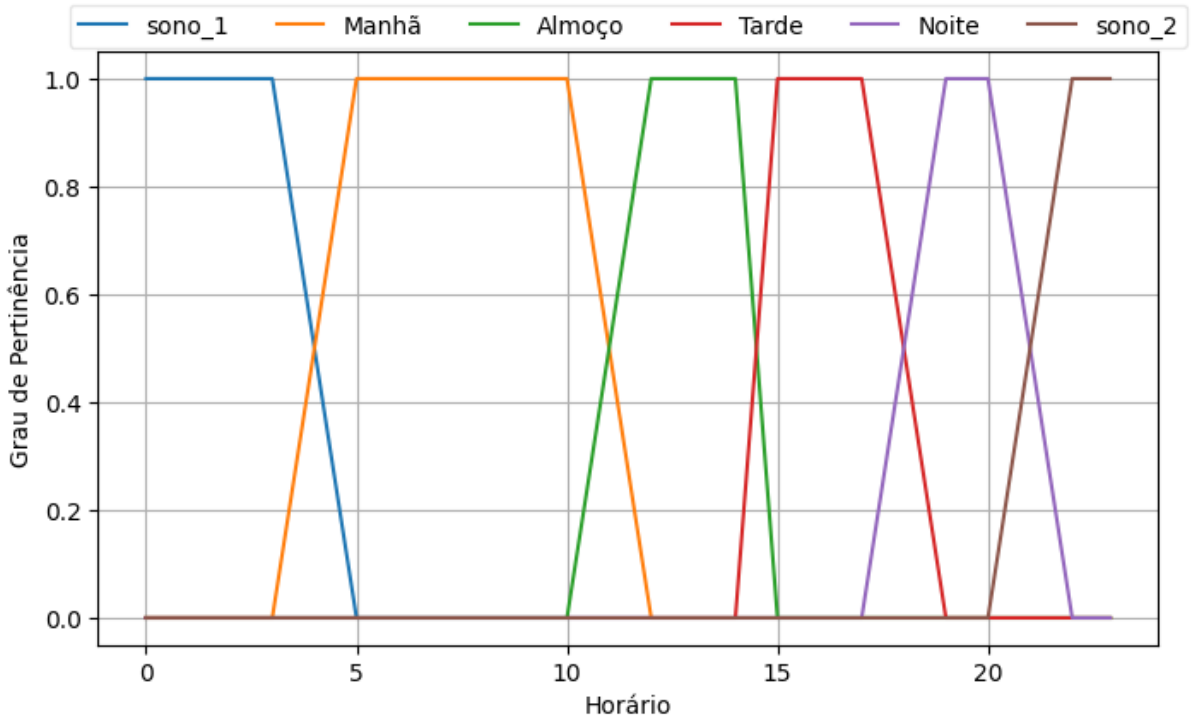
A Tabela 9 apresenta os parâmetros utilizados para cada uma das funções e a Figura 26 apresenta as funções de pertinência utilizadas no conjunto *fuzzy* para a variável de entrada “horário”.

Tabela 9 – Parâmetros de classificação do modelo T1FIS para a entrada “horário”

Classificação	**Parâmetros**
sono 1	[0, 0, 3, 5]
manhã	[3, 5, 10, 12]
almoço	[10, 12, 14, 15]
tarde	[14, 15, 17, 19]
noite	[17, 19, 20, 22]
sono 2	[20, 22, 23, 23]

Fonte: Elaborado pelo autor.

Figura 26 – Funções de pertinência do modelo T1FIS para a entrada “horário”



Fonte: Elaborado pelo autor.

3.3.3.1.4 Consumo de Energia

O universo de discurso para a saída “consumo de energia” foi definido de acordo com os valores mínimo (45,58 Wh) e máximo (604,68 Wh). A classificação foi realizada de acordo com a característica da série de dados, sendo dividida em “extremamente baixo”, “muito baixo”,“baixo”, “médio baixo”, “médio”, “médio alto”, “alto”, “muito alto” e “extremamente alto”.

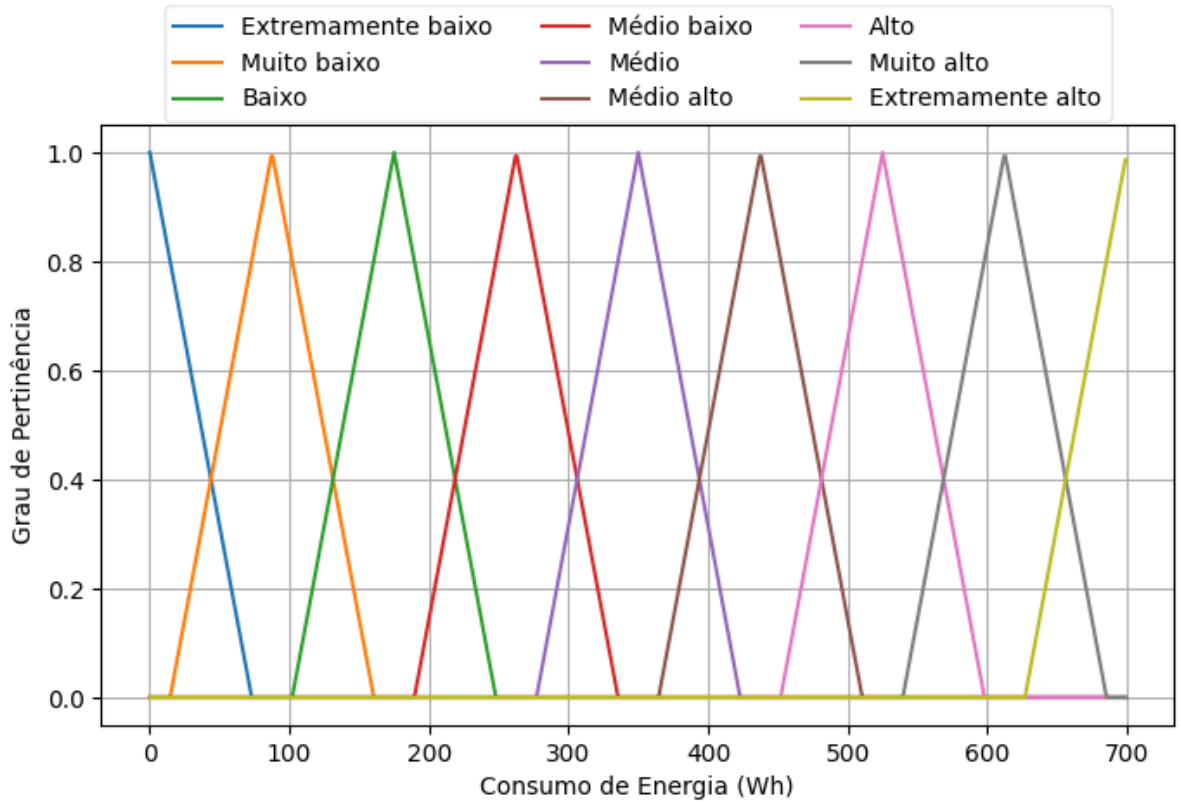
A Tabela 10 apresenta os parâmetros utilizados para cada uma das funções e a Figura 27 apresenta as funções de pertinência utilizadas no conjunto *fuzzy* para a variável de saída “consumo de energia”.

Tabela 10 – Parâmetros de classificação do modelo T1FIS para a saída “consumo de energia”

Classificação	**Parâmetros**
extremamente baixo	[0, 0, 73]
muito baixo	[14.5, 87.5, 160.5]
baixo	[102, 175, 248]
medio baixo	[189.5, 262.5, 335.5]
medio	[277, 350, 423]
medio alto	[364.5, 437.5, 510.5]
alto	[452, 525, 598]
muito alto	[539.5, 612.5, 685.5]
extremamente alto	[627, 700, 700]

Fonte: Elaborado pelo autor.

Figura 27 – Funções de pertinência do modelo T1FIS para a saída “consumo de energia”



Fonte: Elaborado pelo autor.

3.3.3.1.5 Base de regras e validação

Após as entradas e saída do modelo T1FIS serem estabelecidas, o próximo passo é a criação da base de regras. Para a definição desta base, foi utilizado o auxílio de dois especialistas na área.

Para isso, foi criado um formulário no *Google Forms* e enviado para a coleta de respostas, para posteriormente iniciar a criação da base de regras.

Como o modelo T1FIS que foi utilizado possui 4 classificações para a entrada "renda familiar", 3 classificações para a entrada "temperatura" e 6 classificações para a entrada "horário", a combinação de cada uma das classificações forma uma base de regras composta por 72 regras (4x3x6), sendo apresentada na Tabela 11.

Tabela 11 – Base de Regras

Regra	**Renda Familiar**	**Temperatura**	**Horário**	**Consumo de Energia**
1	baixa	baixa	sono 1	muito baixo
2	baixa	baixa	manhã	muito baixo
3	baixa	baixa	almoço	muito baixo
4	baixa	baixa	tarde	muito baixo
5	baixa	baixa	noite	extremamente baixo
6	baixa	baixa	sono 2	muito baixo
7	baixa	média	sono 1	extremamente baixo
8	baixa	média	manhã	muito baixo
9	baixa	média	almoço	muito baixo
10	baixa	média	tarde	extremamente baixo
11	baixa	média	noite	baixo
12	baixa	média	sono 2	muito baixo
13	baixa	alta	sono 1	muito baixo
14	baixa	alta	manhã	muito baixo
15	baixa	alta	almoço	muito baixo
16	baixa	alta	tarde	muito baixo
17	baixa	alta	noite	baixo
18	baixa	alta	sono 2	muito baixo
19	média baixa	baixa	sono 1	baixo
20	média baixa	baixa	manhã	baixo
21	média baixa	baixa	almoço	muito baixo
22	média baixa	baixa	tarde	médio
23	média baixa	baixa	noite	médio baixo
24	média baixa	baixa	sono 2	médio baixo
25	média baixa	média	sono 1	baixo
26	média baixa	média	manhã	baixo
27	média baixa	média	almoço	muito baixo
28	média baixa	média	tarde	baixo
29	média baixa	média	noite	médio alto

Tabela 11 - continuação

Regra	Renda Familiar	Temperatura	Horário	Consumo de Energia
30	média baixa	média	sono 2	médio baixo
31	média baixa	alta	sono 1	baixo
32	média baixa	alta	manhã	baixo
33	média baixa	alta	almoço	baixo
34	média baixa	alta	tarde	baixo
35	média baixa	alta	noite	médio alto
36	média baixa	alta	sono 2	médio alto
37	média alta	baixa	sono 1	baixo
38	média alta	baixa	manhã	médio baixo
39	média alta	baixa	almoço	muito baixo
40	média alta	baixa	tarde	alto
41	média alta	baixa	noite	médio baixo
42	média alta	baixa	sono 2	alto
43	média alta	média	sono 1	muito baixo
44	média alta	média	manhã	baixo
45	média alta	média	almoço	médio baixo
46	média alta	média	tarde	muito baixo
47	média alta	média	noite	médio baixo
48	média alta	média	sono 2	baixo
49	média alta	alta	sono 1	médio baixo
50	média alta	alta	manhã	médio
51	média alta	alta	almoço	baixo
52	média alta	alta	tarde	muito baixo
53	média alta	alta	noite	médio
54	média alta	alta	sono 2	baixo
55	alta	baixa	sono 1	baixo
56	alta	baixa	manhã	médio baixo
57	alta	baixa	almoço	baixo
58	alta	baixa	tarde	médio baixo
59	alta	baixa	noite	muito alto
60	alta	baixa	sono 2	alto
61	alta	média	sono 1	baixo
62	alta	média	manhã	médio baixo
63	alta	média	almoço	baixo
64	alta	média	tarde	médio baixo
65	alta	média	noite	extremamente alto

Tabela 11 - continuação

Regra	Renda Familiar	Temperatura	Horário	Consumo de Energia
66	alta	média	sono 2	alto
67	alta	alta	sono 1	muito baixo
68	alta	alta	manhã	muito baixo
69	alta	alta	almoço	baixo
70	alta	alta	tarde	médio baixo
71	alta	alta	noite	alto
72	alta	alta	sono 2	médio alto

Fonte: Elaborado pelo autor.

Para que seja possível realizar a validação do modelo, é necessário simular o sistema *fuzzy* com os valores da base de dados utilizada. Para isso, os dados foram carregados em um *dataframe*, no qual cada uma das colunas foi transformada em um arranjo de valores, por meio da função. Os valores então foram utilizados para estimar o valor do consumo de energia elétrica utilizando o modelo T1FIS.

3.3.3.2 Modelo IT2FIS

O modelo IT2FIS foi desenvolvido adicionando uma mancha de incerteza nas funções de pertinência utilizadas no modelo T1FIS. Para isso, método de inferência escolhido foi o *Mamdani*, com os parâmetros de t-norma sendo o operador mínimo, de t-conorma sendo o operador máximo, o método de defuzificação sendo o centroide e o algoritmo para redução de tipo sendo o algoritmo "Karnik-Mendel". O modelo foi implementado na linguagem de programação *Python* e a biblioteca utilizada foi apresentada na seção 2.5.

Para comparar os resultados deste modelo com o modelo T1FIS, foram utilizadas as mesmas entradas, a mesma saída, com o mesmo número de funções de pertinência e o mesmo universo de discurso para cada uma das variáveis. A seguir, são detalhados cada uma das variáveis e o modelo em geral.

3.3.3.2.1 Renda Familiar

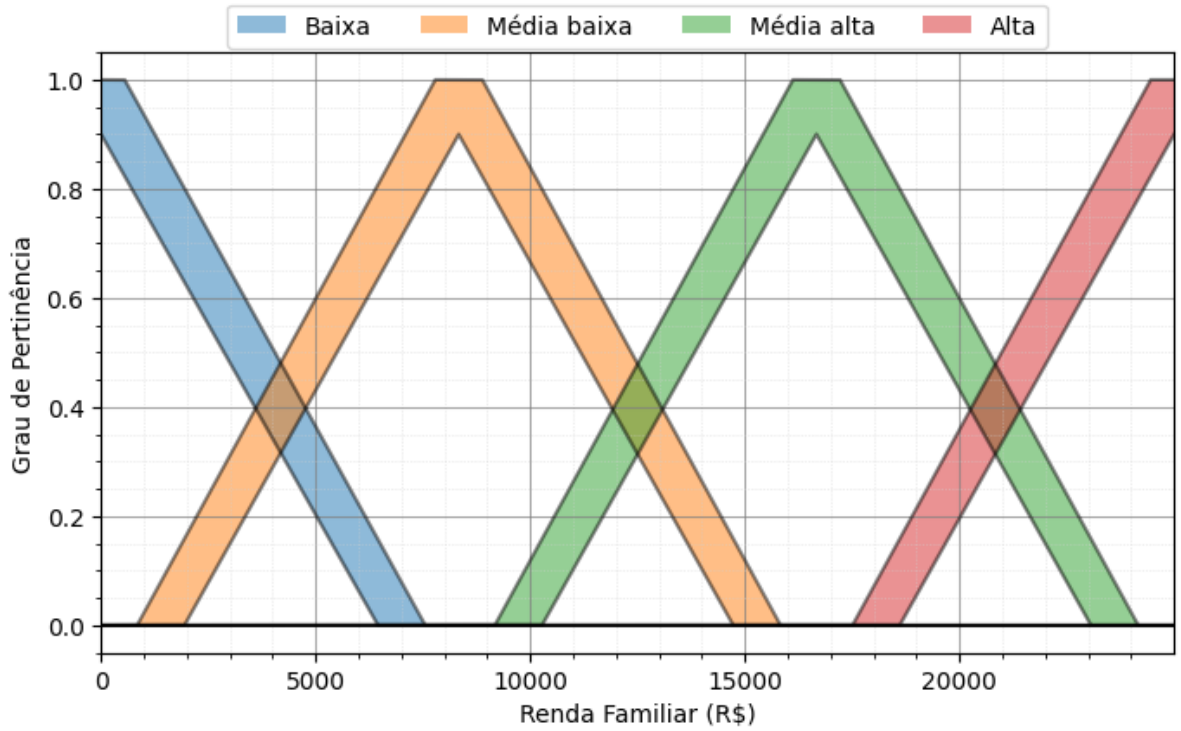
Da mesma maneira que foi feito no modelo T1FIS, conforme já citado, as classe vão da alta (A) até a mais baixa (D-E), dessa forma o universo de discurso vai de 1 a 6. Tal entrada foi classificada em cinco funções de pertinência, sendo elas "alta", "média-alta", "média", "média-baixa" e "baixa". A Tabela 12 apresenta os parâmeros utilizados para cada uma das funções e a Figura 28 apresenta as funções de pertinência utilizadas no conjunto *fuzzy* tipo-2 para a variável de entrada "renda familiar".

Tabela 12 – Parâmetros de classificação do modelo IT2FIS para a entrada “renda familiar”

Classificação	**Parâmetros**	
baixa	Função de pertinência superior	[0, 0, 550, 7550, 1.0]
	Função de pertinência inferior	[0, 0 ,6450, 0.9]
média baixa	Função de pertinência superior	[840, 7783, 8883, 15826, 1.0]
	Função de pertinência inferior	[1940, 8333, 14726, 0.9]
média alta	Função de pertinência superior	[9172, 16116, 17216, 24160, 1.0]
	Função de pertinência inferior	[10272, 16666, 23060, 0.9]
alta	Função de pertinência superior	[17505, 24450, 25000, 25000.1, 1.0]
	Função de pertinência inferior	[18605, 25000, 25000, 0.9]

Fonte: Elaborado pelo autor.

Figura 28 – Funções de pertinência do modelo IT2FIS para a entrada “renda familiar”



Fonte: Elaborado pelo autor.

3.3.3.2.2 Temperatura

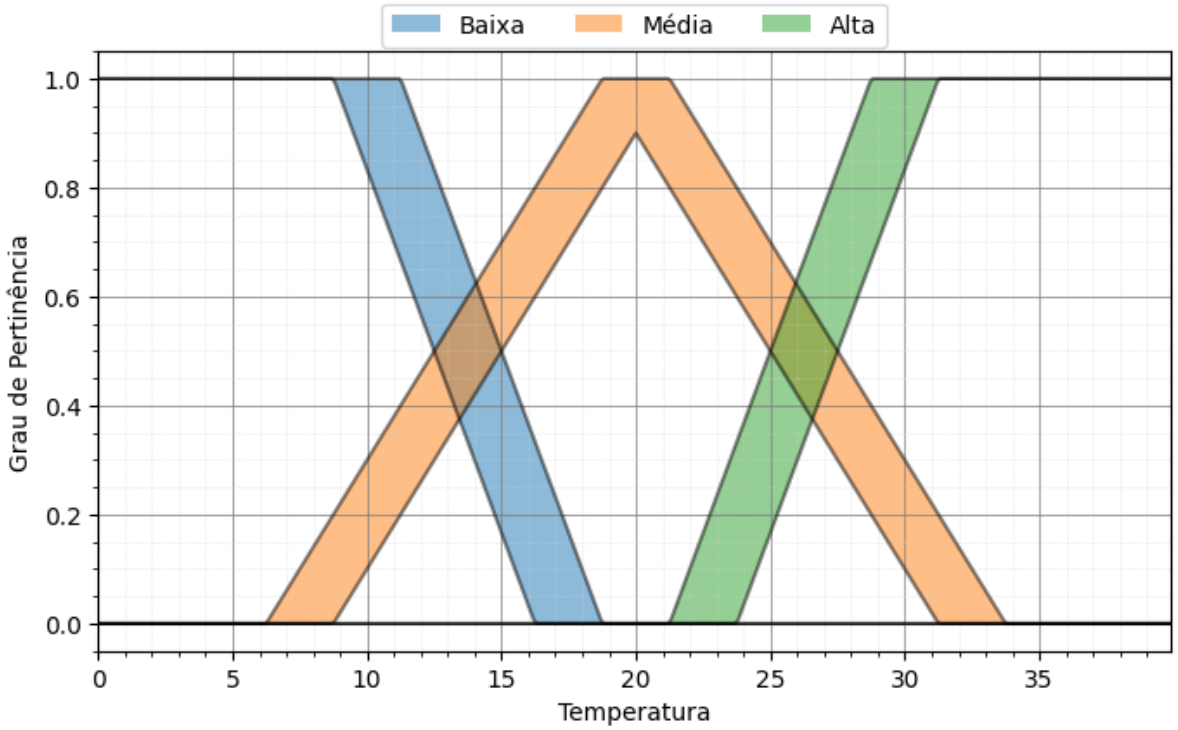
Na variável de entrada de temperatura para o modelo IT2FIS, foram utilizadas as mesmas classificações e o mesmo universo de discurso do modelo T1FIS, com a inserção da FOU, utilizada em IT2FIS. A Tabela 13 apresenta os parâmeros utilizados para cada uma das funções e a Figura 29 apresenta as funções de pertinência utilizadas no conjunto *fuzzy* tipo-2 para a variável de entrada “temperatura”.

Tabela 13 – Parâmetros de classificação do modelo IT2FIS para a entrada “temperatura”

Classificação	**Parâmetros**	
baixa	Função de pertinência superior	[0, 0, 11.25, 18.75, 1.0]
	Função de pertinência inferior	[0, 0, 8.75, 16.25, 1.0]
média	Função de pertinência superior	[6.25, 18.75, 21.25, 33.75, 1.0]
	Função de pertinência inferior	[8.75, 20, 31.25, 0.9]
alta	Função de pertinência superior	[21.25, 28.75, 40, 40.01, 1.0]
	Função de pertinência inferior	[23.75, 31.25, 40, 40.01, 1.0]

Fonte: Elaborado pelo autor.

Figura 29 – Funções de pertinência do modelo IT2FIS para a entrada “temperatura”



Fonte: Elaborado pelo autor.

3.3.3.2.3 Horário

Assim como nas variáveis anteriores, para a variável de entrada “horário” foram utilizadas as mesmas classificações e universo de discurso do modelo T1FIS. A FOU criada adicionando-se $\pm 0,5h$ de incerteza sobre a função de pertinência considerada no modelo T1FIS.

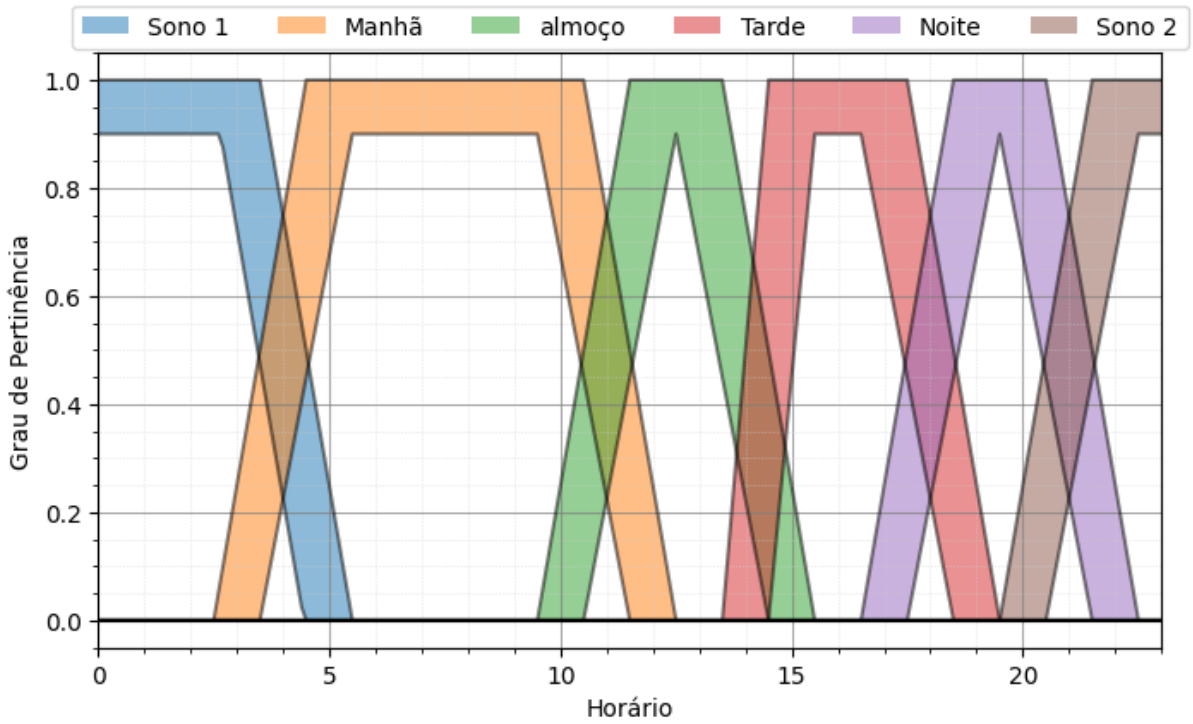
A Tabela 14 apresenta as classificações e parâmetros utilizados e a Figura 30 apresenta as funções de pertinência utilizadas no conjunto *fuzzy* tipo-2 para a variável de entrada “horário”.

Tabela 14 – Parâmetros de classificação do modelo IT2FIS para a entrada “horário”

Classificação	**Parâmetros**	
sono 1	Função de pertinência superior	[0, 0, 3.5, 5.5, 1.0]
	Função de pertinência inferior	[0, 0, 2.65, 4.45, 0.9]
manhã	Função de pertinência superior	[2.5, 4.5, 10.5, 12.5, 1.0]
	Função de pertinência inferior	[3.5, 5.5, 9.5, 11.5, 0.9]
almoço	Função de pertinência superior	[9.5, 11.5, 13.5, 15.5, 1.0]
	Função de pertinência inferior	[10.5, 12.5, 14.5, 0.9]
tarde	Função de pertinência superior	[13.5, 14.5, 17.5, 19.5, 1.0]
	Função de pertinência inferior	[14.5, 15.5, 16.5, 18.5, 0.9]
noite	Função de pertinência superior	[16.5, 18.5, 20.5, 22.5, 1.0]
	Função de pertinência inferior	[17.5, 19.5, 21.5, 0.9]
sono 2	Função de pertinência superior	[19.5, 21.5, 23, 25, 1.0]
	Função de pertinência inferior	[20.5, 22.5, 23, 25, 0.9]

Fonte: Elaborado pelo autor.

Figura 30 – Funções de pertinência do modelo IT2FIS para a entrada “horário”



Fonte: Elaborado pelo autor.

3.3.3.2.4 Consumo de energia

Para a variável de saída “consumo de energia”, da mesma maneira que foi feito com as variáveis de entrada, a classificação e o universo de discurso foi considerado da mesma maneira que no modelo T1FIS. A Tabela 15 apresenta os parâmetos utilizados para cada uma das funções

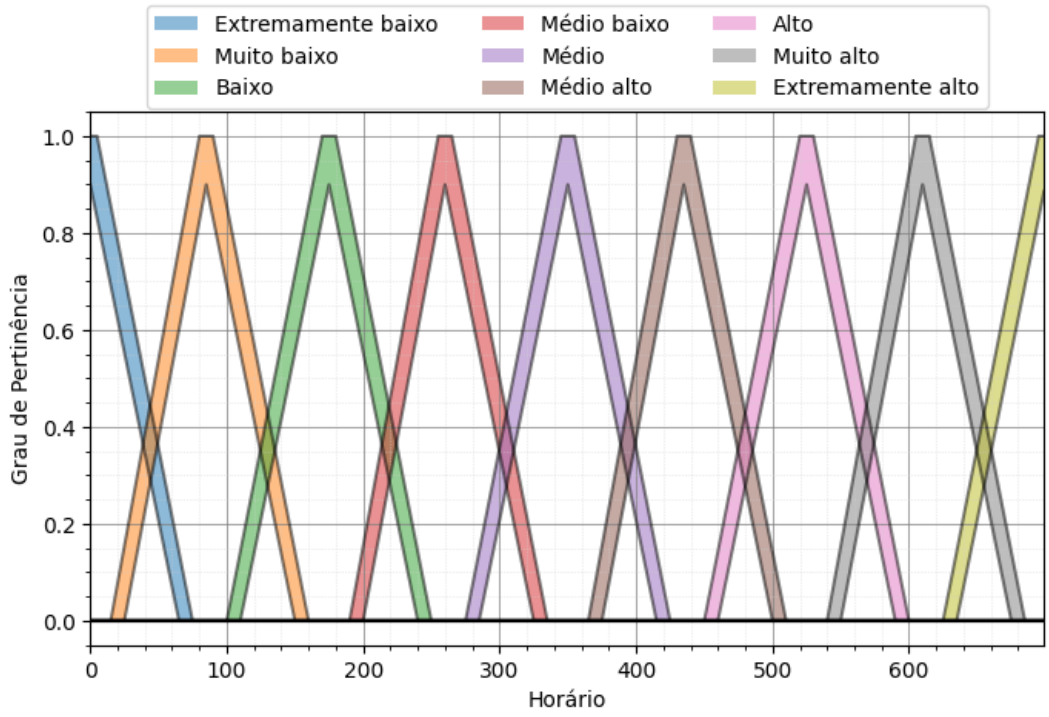
e a Figura 31 apresenta as funções de pertinência utilizadas no conjunto *fuzzy* tipo-2 para a variável de entrada “consumo de energia”.

Tabela 15 – Parâmetros de classificação do modelo IT2FIS para a saída “consumo de energia”

Classificação	**Parâmetros**	
extremamente baixo	Função de pertinência superior	[0, 0, 5, 75, 1.0]
	Função de pertinência inferior	[0, 0, 65, 0.9]
muito baixo	Função de pertinência superior	[15, 80, 90, 160, 1.0]
	Função de pertinência inferior	[25, 85, 150, 0.9]
baixo	Função de pertinência superior	[100, 170, 180, 250, 1.0]
	Função de pertinência inferior	[110, 175, 240, 0.9]
médio baixo	Função de pertinência superior	[190, 255, 265, 335, 1.0]
	Função de pertinência inferior	[200, 260, 325, 0.9]
médio	Função de pertinência superior	[275, 345, 355, 425, 1.0]
	Função de pertinência inferior	[285, 350, 415, 0.9]
médio alto	Função de pertinência superior	[365, 430, 440, 510, 1.0]
	Função de pertinência inferior	[375, 435, 500, 0.9]
alto	Função de pertinência superior	[450, 520, 530, 600, 1.0]
	Função de pertinência inferior	[460, 525, 590, 0.9]
muito alto	Função de pertinência superior	[540, 605, 615, 685, 1.0]
	Função de pertinência inferior	[550, 610, 675, 0.9]
extremamente alto	Função de pertinência superior	[625, 695, 705, 715, 1.0]
	Função de pertinência inferior	[635, 700, 710, 0.9]

Fonte: Elaborado pelo autor.

Figura 31 – Funções de pertinência do modelo IT2FIS para a saída “consumo de energia”



Fonte: Elaborado pelo autor.

3.3.3.2.5 Base de regras e simulação

Para o modelo IT2FIS foi utilizada a mesma base de regras elaborada para o modelo T1FIS, conforme apresentado na Tabela 11, sendo cada regra definida pelos seus antecedentes e consequentes.

Semelhante ao modo que foi feito no modelo T1FIS, para realizar a validação do modelo, é necessário simular o sistema *fuzzy* tipo-2 intervalar com os valores da base de dados utilizada. Para isso, os dados foram carregados da mesma maneira apresentada para o modelo T1FIS, sendo utilizados para estimar o valor do consumo de energia elétrica pelo modelo IT2FIS.

3.3.4 Modelo ANFIS

Alguns trabalhos anteriores, tais como (KAYSAL *et al.*, 2018; OLADIPO; SUN; AMOLE, 2022), já trabalharam com a estimativa do consumo de energia utilizando modelos ANFIS. A presente pesquisa se diferencia dos demais trabalhos, pois utiliza variáveis de entrada diferentes e é aplicado ao cenário brasileiro de consumo de energia elétrica residencial.

Para a estimativa do consumo horário utilizando o modelo ANFIS, foi utilizado como base o modelo T1FIS. Como ferramenta de implementação, foi utilizado no *Python* a biblioteca *lazuardy_anfis*, a qual é uma implementação computacional do método proposto por Jang (1993).

O sistema ANFIS utiliza algoritmos de aprendizagem de redes neurais para treinar os parâmetros de um sistema *fuzzy*, para isso os dados devem ser separados em dados de treinamento e validação. Dessa forma, os dados foram separados em 80% para treinamento e 20% para validação, os quais são embaralhados antes da separação para evitar viés decorrente da ordem das observações. Para realizar tal separação no *Python*, foi utilizada a função *train_test_split* da biblioteca *sklearn*.

Para fazer uma comparação entre os modelos propostos nesta pesquisa, para o modelo ANFIS foi utilizado o mesmo número de entradas e saída do modelo T1FIS, bem como o mesmo número de funções de pertinência para cada uma delas. Porém, o sistema gerado pelo modelo ANFIS é do tipo Sugeno, enquanto os modelos T1FIS e IT2FIS foram do tipo Mamdani.

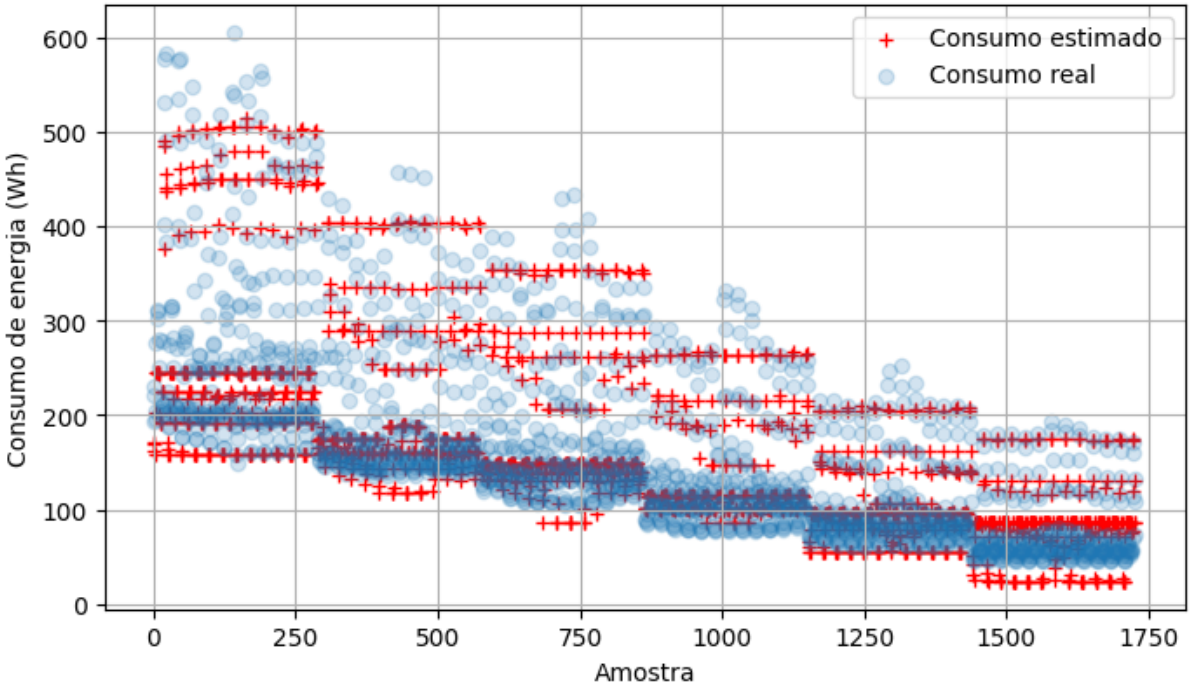
4 RESULTADOS E DISCUSSÕES

Os modelos desenvolvidos foram validados utilizando as métricas citadas em 2.4, comparando os resultados estimados com os resultados apresentados pela PPH-2019. Os resultados foram obtidos para cada um dos modelos apresentados e de acordo com a configuração de entradas e saídas já definidas no Capítulo 3. Para que os resultados dos modelos T1FIS, IT2FIS e ANFIS possam ser comparados, foram utilizados os mesmos dados em todos os modelos.

4.1 MODELO T1FIS

De posse dos resultados da estimativa para o modelo inicial T1FIS, denominado T1FIS-1, foi plotado um gráfico apresentando os valores estimados e os valores esperados para todas as amostras do conjunto de dados. Tal gráfico pode ser visualizado na Figura 32.

Figura 32 – Valores esperados *vs* valores estimados para modelo T1FIS-1



Fonte: Elaborado pelo autor.

Na Figura 32, observa-se que há um certo erro, pois os pontos dos valores de consumo estimados não se sobrepõe exatamente nos pontos dos valores do consumo real. Porém, como apresentado por Jang (1993), a criação da base de regras e os ajustes das funções de pertinência não seguem um processo organizado e, na maioria das vezes, é realizado de modo empírico.

Ao combinar todas as possíveis entradas, obteve-se uma base de regras com 72 regras (4x3x6). Como o número de regras é alto, o processo de ajuste e combinação é muito difícil e trabalhoso.

Para minimizar o erro na base de regras, foi realizada uma consulta com dois especialistas na área, considerando uma lógica entre as variáveis de entrada e a de saída.

Além deste modelo, foram feitos outros testes com diferentes modelos T1FIS, apresentados na Tabela 16. O modelo T1FIS-1 trata-se do modelo apresentado no Capítulo 3, enquanto os demais modelos tratam-se de variações deste modelo, alterando-se o número de funções de pertinência e seu tipo para as entradas e saída.

Tabela 16 – Detalhes dos modelos T1FIS testados

Modelo	Renda Familiar		Temperatura		Horário		Consumo	
	nº	tipo	nº	tipo	nº	tipo	nº	tipo
T1FIS-1	4	Triangular	3	Trapezoidal	6	Trapezoidal	9	Triangular
T1FIS-2	4	Gaussiana	3	Gaussiana	6	Gaussiana	9	Gaussiana
T1FIS-3	3	Triangular	2	Trapezoidal	6	Trapezoidal	7	Triangular
T1FIS-4	3	Gaussiana	2	Gaussiana	6	Gaussiana	7	Gaussiana

Fonte: Elaborado pelo autor.

A Tabela 17 apresenta os resultados das métricas de avaliação para cada um dos modelos T1FIS.

Tabela 17 – Resultados das métricas de avaliação dos modelos T1FIS

Modelo	MAE	MAPE	MSE	RMSE
T1FIS-1	21,03	16,04%	832,04	28,85
T1FIS-2	25,06	19,12%	1172,26	34,24
T1FIS-3	51,60	35,29%	4026,89	63,46
T1FIS-4	42,07	28,54%	2921,75	54,05

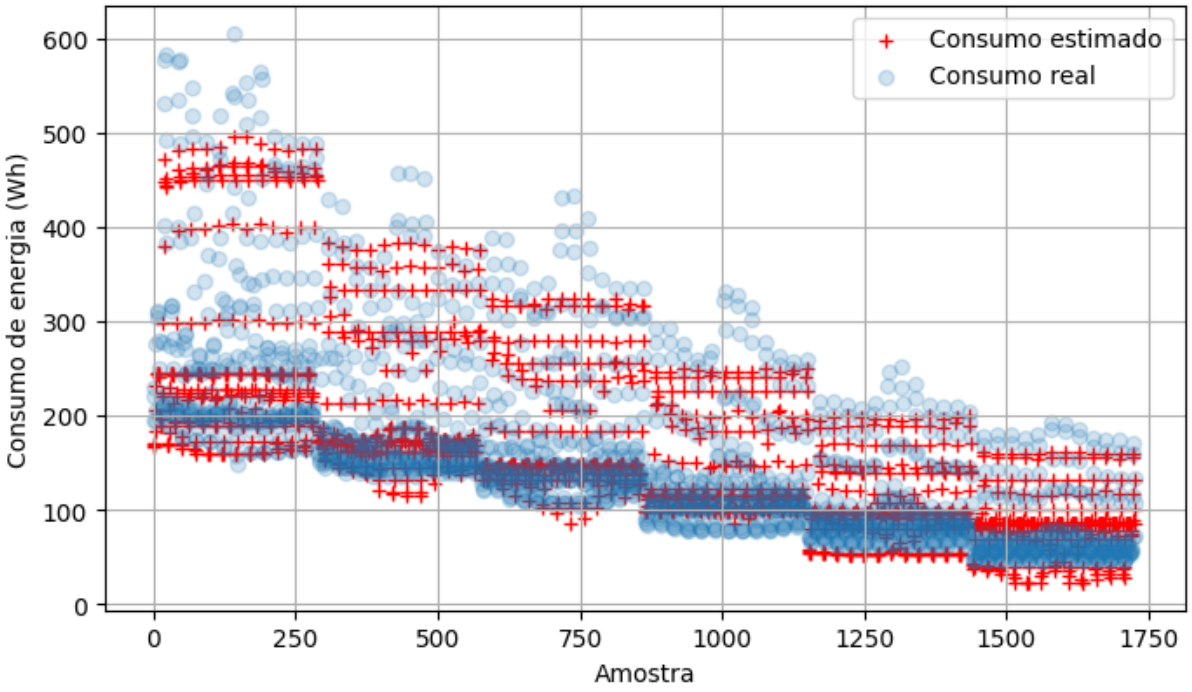
Fonte: Elaborado pelo autor.

Pode-se observar que os modelos T1FIS-1 e T1FIS-2 apresentam resultados bem próximos. Todos os erros do modelo T1FIS-2 foram um pouco maiores que os do modelo T1FIS-1. Já os modelos T1FIS-3 e T1FIS-4, em que foram reduzidas as funções de pertinência das entradas "renda familiar" e "temperatura", consequentemente, tiveram um menor número de regras, sendo 48. O número de funções de pertinência para a saída "consumo" também foi reduzido para 7 funções. Porém, tal mudança fez com que os erros fossem maiores para ambos os modelos, com uma redução do modelo T1FIS-4 em relação ao modelo T1FIS-3.

4.2 MODELO IT2FIS

Para o modelo IT2FIS, assim como no modelo T1FIS, foi plotado um gráfico apresentando os valores estimados e os valores esperados para todas as amostras do conjunto de dados, sendo apresentado na Figura 33

Figura 33 – Valores esperados *vs* valores estimados para modelo IT2FIS



Fonte: Elaborado pelo autor.

Na Figura 33 pode-se observar que, assim como no modelo T1FIS, os pontos dos valores de consumo estimados não se sobrepõem aos pontos dos valores do consumo real, evidenciando que há um erro entre os valores estimados e reais. O modelo IT2FIS, além dos mesmos problemas do T1FIS, apresenta um problema a mais para ser enfrentado, pois também requer um ajuste das manchas de incerteza das funções de pertinência de cada uma das variáveis.

Foram desenvolvidos mais cinco modelos IT2FIS para testes. No modelo IT2FIS-2, foi aumentada a mancha de incerteza das funções de pertinência da saída. Já no modelo IT2FIS-3, foi aumentada a mancha das funções de pertinência das entradas “renda familiar” e “temperatura” e a saída foi mantida a mesma FOU do modelo IT2FIS-2. Por fim, para o modelo IT2FIS-4, a FOU da entrada “horário” foi aumentada. Nos modelos IT2FIS-5 e IT2FIS-6, foram alterados os tipos das funções de pertinência das entradas e saídas, sendo utilizada a função do tipo gaussiana. A Tabela 18 apresenta os detalhes de cada um dos modelos testados e a Tabela 19 apresenta os resultados das métricas de avaliação do modelo IT2FIS.

Tabela 18 – Detalhes dos modelos IT2FIS testados

Modelo	Renda Familiar		Temperatura		Horário		Consumo	
	tipo	FOU	tipo	FOU	tipo	FOU	tipo	FOU
IT2FIS-1	Triangular	10%	Trapezoidal	10%	Trapezoidal	10%	Triangular	10%
IT2FIS-2	Triangular	10%	Trapezoidal	10%	Trapezoidal	10%	Triangular	25%
IT2FIS-3	Triangular	20%	Trapezoidal	20%	Trapezoidal	10%	Triangular	25%
IT2FIS-4	Triangular	20%	Trapezoidal	20%	Trapezoidal	20%	Triangular	25%
IT2FIS-5	Gaussiana	10%	Gaussiana	10%	Gaussiana	10%	Gaussiana	10%
IT2FIS-6	Gaussiana	20%	Gaussiana	20%	Gaussiana	20%	Gaussiana	25%

Fonte: Elaborado pelo autor.

Tabela 19 – Resultados das métricas de avaliação dos modelos IT2FIS

Modelo	MAE	MAPE	MSE	RMSE
IT2FIS-1	20,95	15,49%	840,76	29,00
IT2FIS-2	20,97	15,38%	856,59	29,27
IT2FIS-3	22,06	16,58%	914,14	30,23
IT2FIS-4	29,06	23,59%	1623,87	40,30
IT2FIS-5	23,55	17,61%	1014,41	31,85
IT2FIS-6	27,78	22,03%	1347,87	36,71

Fonte: Elaborado pelo autor.

Pode-se observar que os modelos IT2FIS-1 e IT2FIS-2 obtiveram resultados bem próximos, sendo que, pela observação do MAPE, o modelo IT2FIS-2 teve um desempenho ligeiramente melhor. Os modelos IT2FIS-3 e IT2FIS-5 tiveram desempenhos inferiores aos dois modelos analisados anteriormente, porém os resultados não são tão destoantes. Já os modelos IT2FIS-4 e IT2FIS-6 obtiveram resultados mais distantes dos outros modelos, performando de maneira pior que os demais, com destaque ao modelo IT2FIS-4 que obteve o pior resultado.

A variação da FOU na saída não obteve um grande impacto nos resultados, como é demonstrado através dos resultados entre os modelos IT2FIS-1 e IT2FIS-2. Mas o aumento das FOUs nas entradas refletiu em um em um maior impacto nos resultados, demonstrando que com o aumento destas FOUs há uma piora no desempenho do modelo. O caso que obteve o pior desempenho entre os modelos foi no modelo IT2FIS-4, onde todas as FOUs, tanto das entradas quanto das saídas, foram aumentadas.

Os modelos IT2FIS-1 e IT2FIS-5 possuem os mesmos percentuais de FOU nas entradas e saídas e o mesmo ocorre entre os modelos IT2FIS-4 e IT2FIS-6, sendo que a diferença entre tais modelos são os formatos das funções de pertinência. Entre os modelos IT2FIS-1 e IT2FIS-5, observa-se que a utilização das funções de pertinência triangulares e trapezoidais obteve melhor resultado. Porém, ao realizar tal comparação entre os modelos IT2FIS-4 e IT2FIS-6, ocorre o

contrário, a utilização das funções de pertinência gaussianas obteve melhores resultados do que com a utilização das funções de pertinência triangulares e trapezoidais.

Comparando os resultados das métricas dos modelos T1FIS e IT2FIS, nota-se que o modelo IT2FIS-2 teve uma ligeira vantagem em relação ao modelo T1FIS-1. Isso pode significar que tal modelo, através das manchas de incerteza, conseguiu captar melhor as incertezas associadas aos aspectos comportamentais humano, aos aspectos econômicos-sociais e aos aspectos climáticos no consumo de energia da classe residencial.

4.3 MODELO ANFIS

Neste modelo, conforme já foi descrito no Capítulo 3, os dados foram divididos entre dados para treinamento e dados para validação, ambos de maneira aleatória. Dessa maneira, inicialmente serão apresentados os resultados para o conjunto de dados de treinamento e logo após os resultados para o conjunto de dados de validação, ou seja, um conjunto de dados que não foi utilizado para o treinamento. Posteriormente, para fins de comparação com os outros dois modelos desenvolvidos, será apresentado o resultado para todo o conjunto de dados.

A Figura 34 apresenta os valores estimados e os valores esperados para o conjunto de dados de treinamento do modelo. Pode-se observar que na região de maior concentração dos dados, os pontos dos valores estimados estão bem próximos aos pontos de valores esperados, e na região de valores mais extremos, os pontos estimados estão um pouco mais distantes dos pontos esperados.

Na Figura 35 são apresentados os valores estimados e os valores esperados para o conjunto de dados de validação do modelo. Observa-se que, assim como ocorreu com os dados de treinamento, os valores estimados estão bem próximos dos valores esperados na maioria dos pontos, porém, nos valores mais extremos, há um pequeno aumento da distância.

A Tabela 20 apresenta os resultados das métricas de avaliação para o modelo ANFIS, tanto os resultados de treinamento quanto de validação.

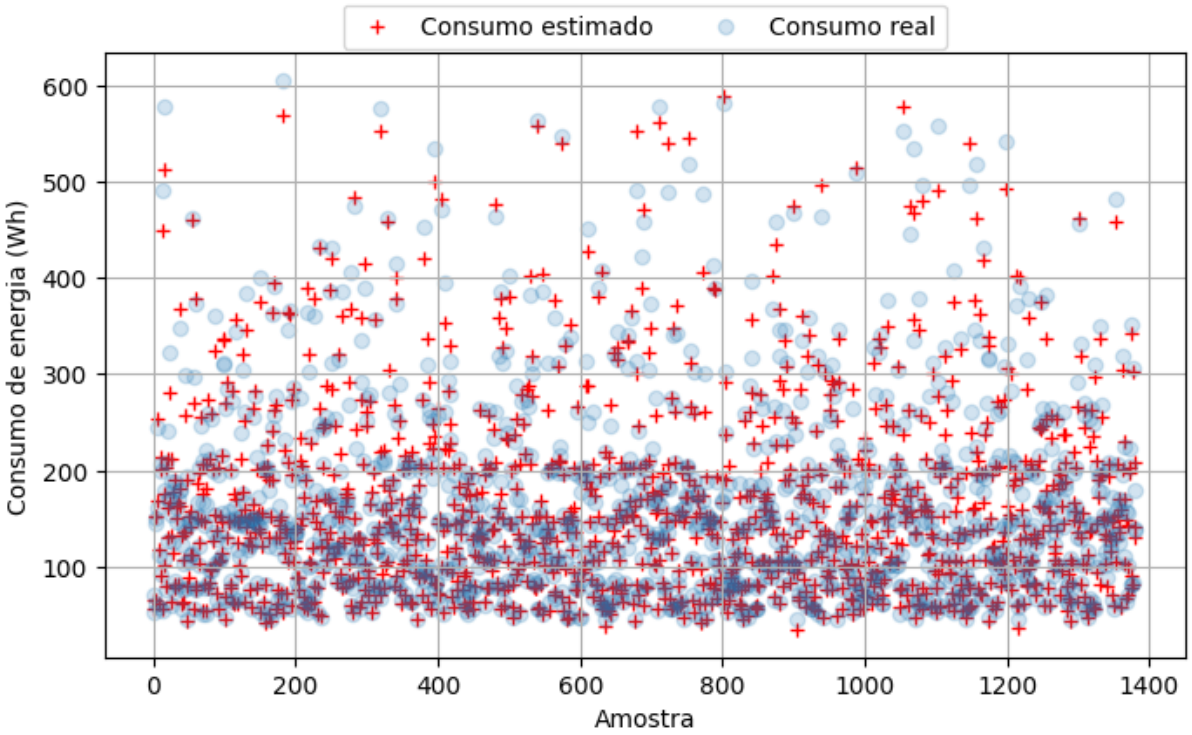
Tabela 20 – Resultados das métricas de avaliação do modelo ANFIS

Conjunto de dados	MAE	MAPE	MSE	RMSE
Treinamento	7,77	4,62%	147,56	12,15
Validação	8,48	5,12%	176,80	13,30

Fonte: Elaborado pelo autor.

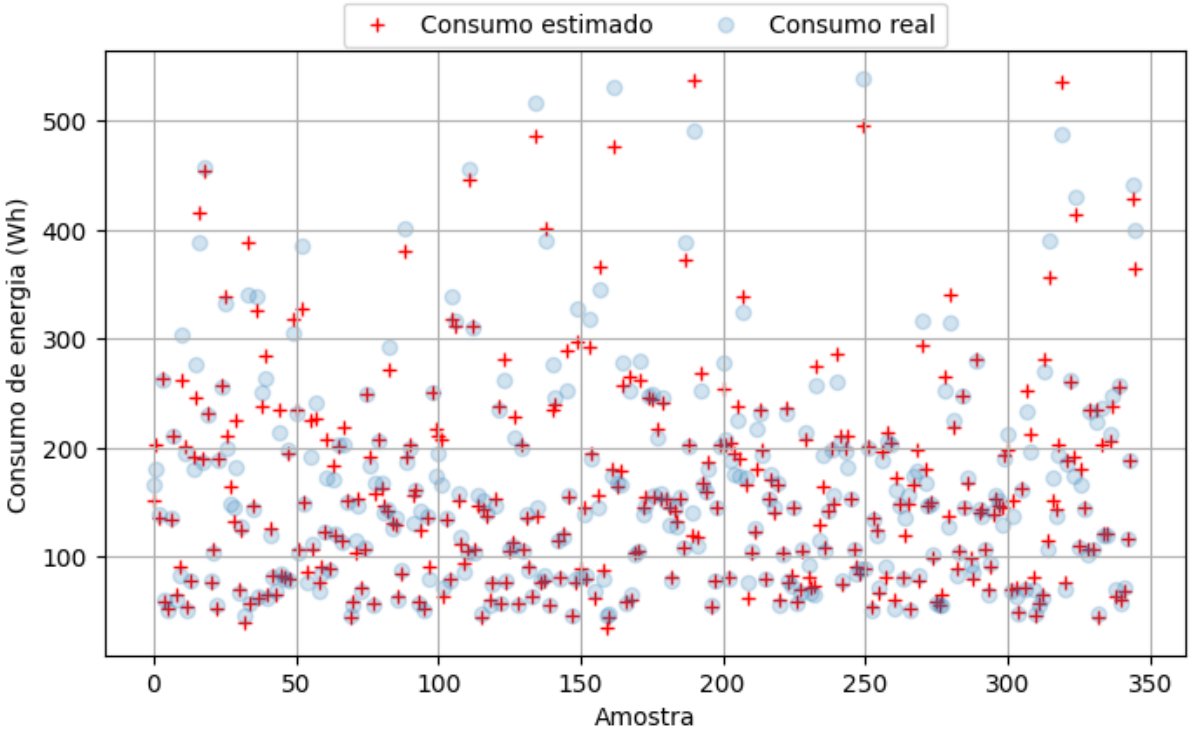
Para fins de comparação, da mesma maneira que nos modelos anteriores, T1FIS e IT2FIS, foi plotado um gráfico apresentando os valores estimados e os valores esperados para todas as amostras do conjunto de dados, sendo apresentado na Figura 36

Figura 34 – Valores esperados *vs* valores estimados para modelo ANFIS (dados de treinamento)



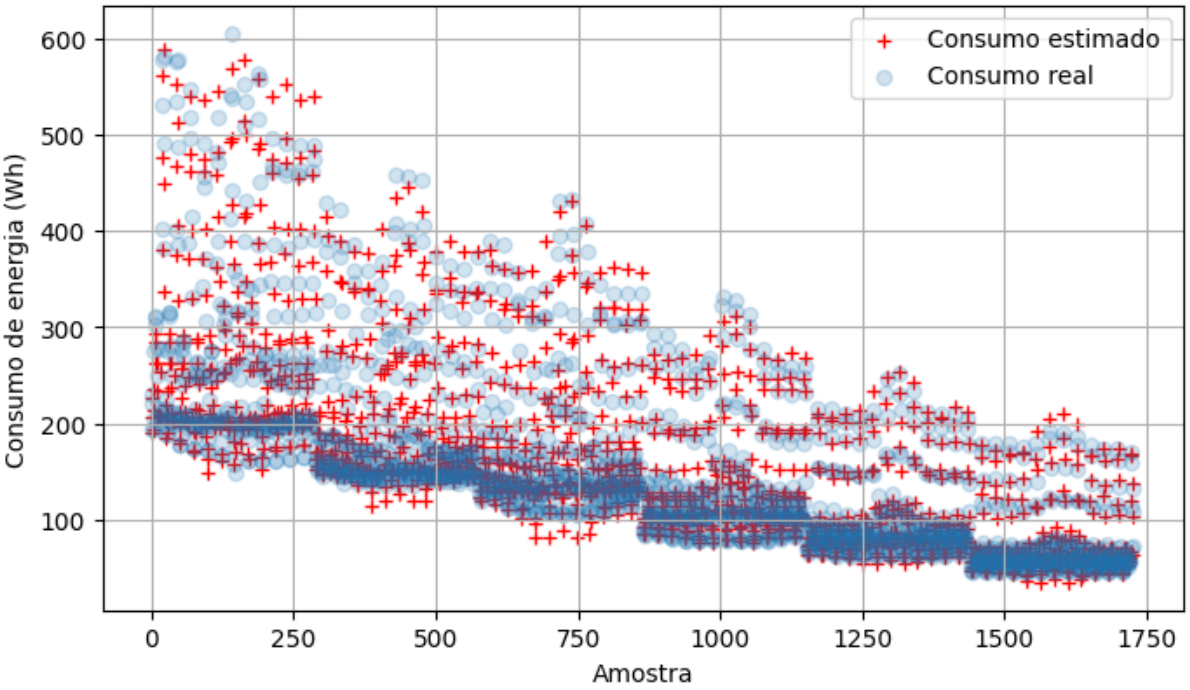
Fonte: Elaborado pelo autor.

Figura 35 – Valores esperados *vs* valores estimados para modelo ANFIS (dados de validação)



Fonte: Elaborado pelo autor.

Figura 36 – Valores esperados *vs* valores estimados para modelo IT2FIS



Fonte: Elaborado pelo autor.

Observa-se na figura que os pontos dos valores de consumo estimados estão bem próximos aos pontos dos valores do consumo real, indicando que há um erro menor que nos modelos T1FIS e IT2FIS. A Tabela 21 apresenta os resultados das métricas de avaliação para o modelo ANFIS, considerando todo o conjunto de dados. O modelo ANFIS obteve resultados mais expressivos, apresentando valores de estimativa com erros bem menores quando comparados aos modelos T1FIS e IT2FIS.

Tabela 21 – Resultados das métricas de avaliação do modelo ANFIS

Conjunto de dados	MAE	MAPE	MSE	RMSE
Total	7,91	4,72%	153,41	12,39

Fonte: Elaborado pelo autor.

5 CONCLUSÕES

Nesta pesquisa foi proposta a estimativa do consumo de energia elétrica residencial correlacionando o aspecto climático, o aspecto econômico-social e o aspecto comportamental humano, utilizando uma ferramenta gratuita para a construção e simulação dos modelos. Dessa maneira, foram elaborados modelos de estimativa utilizando T1FIS, IT2FIS e ANFIS, onde dado uma determinada temperatura, renda familiar e horário, é realizado a estimativa de consumo de energia elétrica para o referido horário. Tais modelos podem ser utilizados como ferramenta de planejamento por diversos agentes do setor energético, tais como consumidores individuais, concessionárias de distribuição e até mesmo agentes governamentais.

O objetivo proposto foi cumprido, pois os modelos T1FIS, IT2FIS e ANFIS apresentaram bons resultados, conseguindo correlacionar todos os aspectos mencionados no objetivo. Além disso, a ferramenta utilizada foi a programação em *Python*, uma ferramenta gratuita que se mostrou de grande valia para a modelagem de sistemas *fuzzy*.

No modelo T1FIS, os formatos das funções de pertinência das entradas e saídas não provocaram um grande impacto no resultado, porém a utilização de funções de pertinência triangulares e trapezoidais obteve um melhor resultado. Já a diminuição do número de funções de pertinência das entradas e da saída tem um grande impacto no resultado, ocasionando um amento expressivo no erro de previsão.

No modelo IT2FIS, assim como no modelo T1FIS, a utilização de funções de pertinência triangulares e trapezoidais nas entradas e saídas obtiveram um melhor resultado. Já com relação à FOU dos modelos, o melhor resultado foi obtido com a utilização de uma FOU de 10%, tanto para as entradas quanto para as saídas. O modelo IT2FIS apresentou um resultado ligeiramente melhor que o modelo T1FIS.

O modelo ANFIS obteve resultados mais expressivos, apresentando valores de estimativa de consumo de energia com erros bem menores, quando comparados aos modelos T1FIS e IT2FIS. Dessa maneira, pode-se concluir que o modelo ANFIS é o mais adequado na utilização de estimativa do consumo de energia elétrica residencial correlacionando, o aspecto climático, o aspecto econômico-social e o aspecto comportamental humano.

Como sugestão para trabalhos futuros, pode-se verificar a utilização de outras variáveis de entrada dos modelos, as quais possam ser correlacionadas ao consumo de energia elétrica em unidades consumidoras residenciais. Pode-se, também, investigar a possibilidade de utilização de sistemas de inferência fuzzy tipo-3 para o problema proposto.

REFERÊNCIAS

ABREU, T. *et al.* Residential electric load curve profile based on fuzzy systems. In: 2015 IEEE PES INNOVATIVE SMART GRID TECHNOLOGIES LATIN AMERICA (ISGT LATAM). **Proceedings [...]**. Montevideo: IEEE, 2015. p. 591–596.

ABREU, T. *et al.* Electrical customer profile using fuzzy logic theory. **IEEE Latin America Transactions**, Piscataway, v. 18, n. 8, p. 1353–1361, 2020.

ALI, S. *et al.* The rise of python: a survey of recent research. **International Journal of Computer Science and Network Security**, Seoul, v. 23, n. 8, p. 16–25, 2023.

ALOORRAVI, S. **Mastering time series analysis and forecasting with python**: bridging theory and practice through insights, techniques, and tools for effective time series analysis in python. Delhi: Orange Education Pvt Ltd, 2024.

ASSOCIAÇÃO BRASILEIRA DE EMPRESAS DE PESQUISA. **Alterações na aplicação do critério Brasil**. São Paulo: ABEP, 2019. Disponível em: www.abep.org. Acesso em: 26 ago. 2025.

BALACHANDRA, P.; CHANDRU, V. Modelling electricity demand with representative load curves. **Energy**, Londres, v. 24, n. 3, p. 219–230, 1999.

BERTRAND, J. W. M.; FRANSOO, J. C. Operations management research methodologies using quantitative modeling. **International Journal of Operations and Production Management**, Bingley, v. 22, p. 241–264, 2002.

BRASIL. Ministério de Minas e Energia; EMPRESA DE PESQUISA ENERGÉTICA. **Plano nacional de energia 2050**: relatório final do pne 2050. Brasília: MME/EPE, 2020.

BRASIL. Ministério de Minas e Energia; EMPRESA DE PESQUISA ENERGÉTICA. **Estudos do plano decenal de expansão de energia 2032**: demanda e eficiência energética. Brasília: MME/EPE, 2023.

CAPASSO, A. *et al.* A bottom-up approach to residential load modeling. **IEEE Transactions on Power Systems**, Piscataway, v. 9, n. 2, p. 957–964, 1994.

CASARIN, H. de Castro silva; CASARIN, S. J. **Pesquisa científica**: da teoria à prática. Curituba: InterSaberes, 2012.

CASTILLO, O.; MELIN, P. **Type-2 fuzzy logic**: theory and applications. Berlin: Springer, 2008. (Studies in fuzziness and soft computing).

CHANG, F.-J.; CHANG, Y.-T. Adaptive neuro-fuzzy inference system for prediction of water level in reservoir. **Advances in Water Resources**, Oxford, v. 29, n. 1, p. 1–10, 2006.

CHICCO, D.; WARRENS, M. J.; JURMAN, G. The coefficient of determination r-squared is more informative than smape, mae, mape, mse and rmse in regression analysis evaluation. **PeerJ Computer Science**, PeerJ Inc., Londres, v. 7, p. 1–24, 2021.

DIAS, R. A.; MATTOS, C. R.; BALESTIERI, J. A. P. Energy education: breaking up the rational energy use barriers. **Energy Policy**, Londres, v. 32, p. 1339–1347, 2004.

DODURKA, M. F. *et al.* Boundary function based karnik–mendel type reduction method for interval type-2 fuzzy pid controllers. In: 2014 IEEE INTERNATIONAL CONFERENCE ON FUZZY SYSTEMS (FUZZ-IEEE). **Proceedings [...]**. Beijing, China, 2014. p. 619–625.

DUNN, P. K. **Scientific research and methodology**. Australia: Bookdown, 2021.

ELETROBRAS. **Pesquisa de posse e hábitos de uso de equipamentos elétricos na classe residencial 2019**: resumo executivo. 2019. Disponível em: https://eletrobras.com/pt/Paginas/PPH-2019.aspx. Acesso em: 18 jul. 2025.

ELETROBRAS. **PPH 2019 web**. 2019. Disponível em: https://eletrobras.com/pt/Paginas/PPH-2019.aspx. Acesso em: 3 ago. 2025.

EMPRESA DE PESQUISA ENERGÉTICA. **Modelo de demanda de energia do setor residencial (MSR)**: aspectos metodológicos. Rio de Janeiro, 2021.

EMPRESA DE PESQUISA ENERGÉTICA. **Boletim trimestral de consumo de eletricidade**. Rio de Janeiro, 2023. v. 4, n. 16.

EMPRESA DE PESQUISA ENERGÉTICA. **Resenha mensal do mercado de energia elétrica**. Rio de Janeiro, 2024. v. 17, n. 200.

EMPRESA DE PESQUISA ENERGÉTICA. **Painel de monitoramento do consumo de energia elétrica**. 2025. Disponível em: https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/consumo-de-energia-eletrica. Acesso em: 22 set. 2025.

FACELI, K. *et al.* **Inteligência artificial: uma abordagem de aprendizado de máquina**. Rio de Janeiro: LTC, 2011.

FILIPPINI, R. Operations management research: some reflections on evolution, models and empirical studies in om. **International Journal of Operations Production Management**, Bingley, v. 17, p. 655–670, 1997.

GARCíA, S.; LUENGO, J.; HERRERA, F. **Data preprocessing in data mining**. Dordrecht: Springer International Publishing, 2015. (Intelligent systems reference library).

GIL, A. C. **Métodos e técnicas de pesquisa social**. 6. ed. São Paulo: Editora Atlas S. A., 2008.

GRANDJEAN, A.; ADNOT, J.; BINET, G. A review and an analysis of the residential electric load curve models. **Renewable and Sustainable Energy Reviews**, Oxford, v. 16, n. 9, p. 6539–6565, 2012.

HAAS, R. Energy efficiency indicators in the residential sector: what do we know and what has to be ensured? **Energy Policy**, Londres, v. 25, p. 789–802, 1997.

HAGHRAH, A. A.; GHAEMI, S.; BADAMCHIZADEH, M. A. Pyit2fls: an open-source python framework for flexible and scalable development of type 1 and interval type 2 fuzzy logic models. **SoftwareX**, Amsterdam, v. 30, 2025.

HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting**: principles and practice. 2nd. ed. Melbourne, Australia: OTexts, 2018.

IGLEWICZ, B.; HOAGLIN, D. C. **How to detect and handle outliers**. Nova York: John Wiley & Sons, 1993. v. 16. (The ASQC basic references in quality control: statistical techniques, v. 16).

IMANI, M. Electrical load-temperature cnn for residential load forecasting. **Energy**, Londres, v. 227, 7 2021.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Panorama do censo 2022**. Brasília: IBGE, 2023. Disponível em: https://censo2022.ibge.gov.br/panorama/. Acesso em: 18 jul. 2025.

IZBICKI, R.; SANTOS, T. M. dos. **Aprendizado de máquina**: uma abordagem estatística. São Carlos: [*s.n.*], 2020.

JANG, J.-S. Anfis: adaptive-network-based fuzzy inference system. **IEEE transactions on systems, man, and cybernetics**, IEEE, Piscataway, v. 23, n. 3, p. 665–685, 1993.

KAPLER, P. Forecasting of residential power consumer load profiles using a type-2 fuzzy inference system. **Acta Polytechnica Hungarica**, Budapeste, v. 19, n. 9, p. 201–219, 2022.

KAYSAL, A. *et al.* Artificial neural networks and adaptive neuro-fuzzy inference systems approaches to forecast the electricity data for load demand, an analysis of Dinar district case. In: 2018 2ND International Symposium ON Multidisciplinary Studies AND Innovative Technologies (ISMSIT). **Proceedings [...]**. Ankara, Turkey: IEEE, 2018. p. 1–6.

KLIR, G. J.; YUAN, B. **Fuzzy sets and fuzzy logic**: theory and applications. Upper Saddle River: Pearson College Div, 1996.

LAZUARDY. **Lazuardy-anfis**: adaptive neuro fuzzy inference system implementation in python. [*S.l.*], 2024. Disponível em: https://pypi.org/project/lazuardy-anfis/. Acesso em: 12 set. 2025.

LI, A.; SU, H.; CHU, J. Forecasting building energy consumption using neural networks and hybrid neuro-fuzzy system: a comparative study. **Energy and Buildings**, Amsterdam, v. 43, p. 2893–2899, 2011.

LI, K. The influence of python on logical thinking and analysis of teaching countermeasures. **Journal of Physics: Conference Series**, Bristol, v. 1744, n. 4, p. 142–164, 2021.

LI, S. *et al.* A novel temporal domain adaptation framework for residential electricity consumption forecasting under incomplete information. **Energy and Buildings**, Amsterdam, v. 333, p. 115513, 2025.

LI, X. *et al.* Low carbon heating and cooling of residential buildings in cities in the hot summer and cold winter zone - A bottom-up engineering stock modeling approach. **Journal of Cleaner Production**, Amsterdam, v. 220, p. 271–288, 2019.

LOPEZ-RODROGUEZ, M. A. *et al.* Analysis and modeling of active occupancy of the residential sector in spain: an indicator of residential electricity consumption. **Energy Policy**, Londres, v. 62, p. 742–751, 11 2013.

MATSUDO, E. **A reestruturação setorial e os reflexos sobre o planejamento e os estudos de mercado das distribuidoras de energia elétrica.** Orientador: Ildo Luis Sauer. 2001. Tese (Doutorado) — Universidade de São Paulo, São Paulo, 2001.

MENDEL, J. M. Fuzzy logic systems for engineering: a tutorial. **Proceedings of the IEEE**, Nova York, v. 83, n. 3, p. 345–377, 1995.

MENDEL, J. M. Type-2 fuzzy sets and systems: an overview. **IEEE Computational Intelligence Magazine**, Piscataway, v. 2, p. 20–29, 2007.

MEZA, J. C. *et al.* Utilização de um modelo neuro-fuzzy para a localização de defeitos em sistemas de potência. **Controle & Automação**, Campinas, v. 17, n. 2, p. 150–160, 2006.

MORISHITA, C. **Impacto do regulamento para eficiência energética em edificações no consumo de energia elétrica do setor residencial brasileiro.** Orientador: Enedir Ghisi. 2011. Tese (Doutorado) — Universidade Federal de Santa Catarina, Florianópolis, 2011.

NOKAR, M. A.; TASHTARIAN, F.; MOGHADDAM, M. H. Y. Residential power consumption forecasting in the smart grid using ANFIS system. In: INTERNATIONAL CONFERENCE ON COMPUTER AND KNOWLEDGE ENGINEERING (ICCKE 2017), 2017. **Proceedings [...]**. Mashhad: IEEE, 2017. p. 111–118.

OLADIPO, S.; SUN, Y.; AMOLE, A. Performance evaluation of the impact of clustering methods and parameters on adaptive neuro-fuzzy inference system models for electricity consumption prediction during COVID-19. **Energies**, Basel, v. 15, n. 21, p. 7863, 2022.

PAATERO, J. V.; LUND, P. D. A model for generating household electricity load profiles. **International Journal of Energy Research**, Oxford, v. 30, p. 273–290, 4 2006.

PALIT, A. K.; POPOVICĆ, D. **Computational intelligence in time series forecasting**: theory and engineering applications. Londres: Springer London, 2005. 372 p. (Advances in Industrial Control).

POPOOLA, O. M.; MUNDA, J.; MPANDA, A. Residential lighting load profile modelling. **Energy and Buildings**, Amsterdam, v. 102, p. 8–21, 2015.

POPOOLA, O. M.; MUNDA, J.; MPANDA, A. Residential lighting load profile modelling: ANFIS approach using weighted and non-weighted data. **Energy Efficiency**, Dordrecht, v. 11, n. 1, p. 169–188, 2018.

PROCEL. **Pesquisa de posse de equipamentos e hábitos de consumo de energia**. Rio de Janeiro: PROCEL, 2006. Disponível em: http://www.procelinfo.com.br/data/Pages/LUMIS05070313PTBRIE.htm. Acesso em: 21 nov. 2024.

PROEDROU, E. A comprehensive review of residential electricity load profile models. **IEEE Access**, Piscataway, v. 9, p. 12114–12133, 2021.

RICHARDSON, I. *et al.* Domestic electricity use: a high-resolution energy demand model. **Energy and Buildings**, Amsterdam, v. 42, n. 10, p. 1878–1887, 2010.

RIZOL, P. M. S. R.; DIAS, R. A. Desmistificando a lógica fuzzy. In: CONGRESSO BRASILEIRO DE EDUCAçãO EM ENGENHARIA (COBENGE). **Proceedings [...]**. Juiz de Fora, 2014.

RIZOL, P. M. S. R.; MESQUITA, L.; SAOTOME, O. Lógica fuzzy tipo-2. **Sodebras**, [*S.l.*], v. 6, p. 27–46, 2011.

SADOLLAH, A. **Fuzzy logic based in optimization methods and control systems and its applications**. Rijeka: IntechOpen, 2018.

SANDRI, S. ; CORREA, C. Lógica nebulosa. **V Escola de Redes Neurais**, [*S.l.*], p. c073–c090, 1999.

SCIKIT-FUZZY DEVELOPERS. **Scikit-fuzzy documentation, version 0.4.2**. [*S.l.: s.n.*], 2025. Disponível em: https://scikit-fuzzy.github.io/scikit-fuzzy/. Acesso em: 11 ago. 2025.

SILVA, E. L. d.; MENEZES, E. M. **Metodologia da pesquisa e elaboração de dissertação**. Florianópolis: UFSC, 2005.

STREICHER, K. N. *et al.* Analysis of space heating demand in the Swiss residential building stock: element-based bottom-up model of archetype buildings. **Energy and Buildings**, Amsterdam, v. 184, p. 300–322, 2019.

SWAN, L. G.; UGURSAL, V. I. Modeling of end-use energy consumption in the residential sector: a review of modeling techniques. **Renewable and Sustainable Energy Reviews**, Oxford, v. 13, n. 8, p. 1819–1835, 2009.

TEIXEIRA, C. A. **Aplicação do método bottom-up para estimativa dos usos finais de energia elétrica no setor residencial brasileiro.** Orientador: Roberto Lambert. 2020. Tese (Doutorado) — Universidade Federal de Santa Catarina, Florianópolis, 2020.

TRAIN, K.; HERRIGES, J.; WINDLE, R. Statistically adjusted engineering (SAE) models of end-use load curves. **Energy**, Londres, v. 10, n. 10, p. 1103–1111, 1985.

TURRIONI, J. B.; MELLO, C. H. P. **Metodologia de pesquisa em engenharia de produção**. Itajubá: UNIFEI, 2012.

WALKER, C. F.; POKOSKI, J. L. Residential load shape modeling based on customer behavior. **IEEE Power Engineering Review**, Piscataway, v. 5, n. 7, p. 34–34, 1985.

WU, D.; MENDEL, J. M. Enhanced karnik–mendel algorithms. **IEEE Transactions on Fuzzy Systems**, Piscataway, v. 17, n. 4, p. 923–934, 2009.

ZADEH, L. A. Fuzzy sets. **Information and Control**, Maryland Heights, v. 8, p. 338–353, 1965.

ZADEH, L. A. Fuzzy sets as a basis for a theory of possibility. **Fuzzy Sets and Systems**, Amsterdam, v. 100, p. 9–34, 1999.

ZHU, Y. *et al.* Exploration on blended teaching mode of python programming based on pbl. In: INTERNATIONAL CONFERENCE INNOVATION ENGINEERING AND TECHNOLOGY. **Proceedings [...]**. Fujisawa: IEEE, 2023.

ZÚÑIGA, K.; CASTILLA, I.; AGUILAR, R. Using fuzzy logic to model the behavior of residential electrical utility customers. **Applied Energy**, Oxford, v. 115, p. 384–393, 2014.

DADOS CURRICULARES

IDENTIFICAÇÃO	
	LUCAS FURTADO RODRIGUES 17/05/1984
Nacionalidade	Brasileira
Nome em citações bibliográficas	Rodrigues, Lucas Furtado Rodrigues, L. F.
Currículo Lattes	https://lattes.cnpq.br/8580903314838987
FORMAÇÃO ACADÊMICA	
2005/2010	Engenharia Elétrica - Engenheiro Eletricista Universidade Federal de Viçosa - UFV
2015/2015	Pós-Graduação Latu Sensu em Docência na Educação Profissional e Tecnológica SENAI CETIQT
PRODUÇÃO BIBLIOGRÁFICA	
RODRIGUES, L. F.; RIZOL, P. M. S. R. Estimating Hourly Consumption for Residential Consumer Units Using Fuzzy Inference Systems and ANFIS. *In:* Congreso Estudiantil de Inteligencia Artificial Aplicada a la ingeniería y Tecnología (CEIAAIT), 2023, México. 2023. p. 29-34.	
RODRIGUES, L. F.; RIZOL, P. M. S. R. Forecasting Residential Electricity Consumption in Southeastern Brazil Using Type-2 Interval Fuzzy Inference Systems. *In:* International Conference on Industry Applications (INDUSCON), 2025, São Sebastião. 2025.	
PARTICIPAÇÃO EM BANCAS E ORIENTAÇÕES	
Bancas de trabalhos de conclusão	
RIZOL, P. M. S. R.; NASCIMENTO, L. F. C.; RODRIGUES, L. F.; LOPES NETO, P. N. Participação em banca de Raquel de Oliveira Paula Andrade. **Comparação entre modelos *fuzzy* e *fuzzy* tipo-2 intervalar para verificar os impactos da poluição do ar na saúde infantil**. 2023. Trabalho de Conclusão de Curso (Graduação em Engenharia Elétrica) - Faculdade de Engenharia e Ciências, Guaratinguetá, 2023.	
RIZOL, P. M. S. R.; RODRIGUES, L. F.; MESQUITA, Gestão de microgeração de energia fotovoltaica residencial por meio de um sistema *fuzzy*. 2024. Trabalho de Conclusão de Curso (Graduação em Engenharia Elétrica) - Faculdade de Engenharia e Ciências, Guaratinguetá, 2024.	

PARTICIPAÇÃO EM EVENTOS CIENTÍFICOS
Congreso Estudiantil de Inteligencia Artificial Aplicada a la ingeniería y Tecnología (CEIAAIT), 2023, (México). Estimating Hourly Consumption for Residential Consumer Units Using Fuzzy Inference Systems and ANFIS. 2023. (Congresso).
International Conference on Industry Applications (INDUSCON), 2025, (São Sebastião). Forecasting Residential Electricity Consumption in Southeastern Brazil Using Type-2 Interval Fuzzy Inference Systems. 2025. (Congresso).