


UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
FACULDADE DE ENGENHARIA – CAMPUS DE ILHA SOLTEIRA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Monara Pereira da Rosa Maeda

**Modelo Wavelet-ANFIS aplicado na previsão de carga de curto prazo de
níveis de consumo desagregado**

Ilha Solteira
2021



Monara Pereira da Rosa Maeda

Modelo Wavelet-ANFIS aplicado na previsão de carga de curto prazo de níveis de consumo desagregado

Tese apresentada à Faculdade de Engenharia
do Campus de Ilha Solteira – UNESP, como
parte dos requisitos para obtenção do título
de Doutor em Engenharia Elétrica.

Prof^ª. Dr^ª. Anna Diva Plasencia Lotufo
Orientadora

Ilha Solteira
2021



FICHA CATALOGRÁFICA
Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

Maeda, Monara Pereira da Rosa.
M184m Modelo Wavelet-ANFIS aplicado na previsão de carga de curto prazo de
níveis de consumo desagregado / Monara Pereira da Rosa Maeda. -- Ilha
Solteira: [s.n.], 2021
82 f. : il.

Tese (doutorado) - Universidade Estadual Paulista. Faculdade de Engenharia
de Ilha Solteira. Área de conhecimento: Automação, 2021

Orientador: Anna Diva Plasencia Lotufo
Inclui bibliografia

1. Previsão de cargas elétricas em nível desagregado. 2. Redes neurais
artificiais. 3. ANFIS. 4. Transformada *Wavelet*.


Raiane da Silva Santos

Supervisora Técnica de Seção
Seção Técnica de Referência, Atendimento ao usuário e Documentação
Diretoria Técnica de Biblioteca e Documentação
CRB/8 - 9999



UNIVERSIDADE ESTADUAL PAULISTA

Câmpus de Ilha Solteira

CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: Modelo Wavelet-ANFIS aplicado na previsão de carga de curto prazo de níveis de consumo desagregado

AUTORA: MONARA PEREIRA DA ROSA MAEDA

ORIENTADORA: ANNA DIVA PLASENCIA LOTUFO

Aprovada como parte das exigências para obtenção do Título de Doutora em ENGENHARIA ELÉTRICA, área: Automação pela Comissão Examinadora:

Prof^a. Dr^a. ANNA DIVA PLASENCIA LOTUFO (Participação Virtual)
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira - UNESP

Prof. Dr. MAURO DE SOUZA TONELLI NETO (Participação Virtual)
MacPhail School of Energy - Southern Alberta Institute of Technology - Calgary, AB, Canadá

Prof. Dr. CARLOS ROBERTO MINUSSI (Participação Virtual)
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira - UNESP

Prof. Dr. HUGO VALADARES SIQUEIRA (Participação Virtual)
Universidade Tecnológica Federal do Paraná - UTFPR

Prof. Dr. MARCO APARECIDO QUEIROZ DUARTE (Participação Virtual)
Departamento de Matemática / Universidade Estadual de Mato Grosso do Sul - UEMS

Ilha Solteira, 22 de janeiro de 2021

Ao meu esposo Kevin

AGRADECIMENTOS

A minha família, obrigada por todo apoio e carinho.

A minha mãe Aparecida por todo amor e compreensão, por me apoiar e por sempre acreditar em mim. Amo muito você!

Ao meu esposo Kevin por todo apoio, amor, carinho, por ser a melhor pessoa possível e estar sempre ao meu lado. Você é tudo pra mim!

Aos meus amados tios(as) Aparecido, Lucia e Luzia e aos meus primos queridos Ana e Du, por entenderem a minha ausência e me apoiarem em minha jornada, com muito amor e carinho.

A Marcia e ao Felix, por serem parte importante da minha vida, me ajudar e apoiar sempre e por acreditarem que sou capaz.

Agradeço aos colegas, amigos e professores por terem sido parte importante desta trajetória.

Agradeço especialmente aos meus amigos e padrinhos Natália e Marco, por todos os rolês e comidas, por todas as conversas e cafés, por serem os melhores amigos e vizinhos, vocês são muito importantes para mim e para a Brownie♥!

A Tania por ser tão especial para mim, me ajudar de tantas formas e cuidar de mim como se eu fosse sua filha, você é demais!

A Tateana por ter tido tanta paciência comigo, por me ajudar na descoberta da minha rede, pelas aulas de pilates e conversas sobre séries, você faz falta Tate!

A Patricia Fernanda e Gabriela Tereza por serem minhas primeiras companheiras de moradia em Ilha Solteira, vocês são especiais para mim!

Ao Marcos e a Marleide por toda a ajuda, principalmente no início, por todos os açaís e pelas caronas.

Ao Haislan, Aline, Carol, Nayara, Priscila, Dani ó Dani, Giovanni e a todos os integrantes do SINTEL pelos conhecimentos compartilhados, horas de estudo, conversas, cafés e caronas.

Agradeço ao Fabricio por todo o conhecimento e figurinhas compartilhados.

Agradeço ao Lucas pela ajuda no $\text{\LaTeX}$ e fotos de gatos compartilhadas.

Agradeço ao Mauro por toda a paciência, pela ajuda, pelas ideias e pelas boas conversas.

Agradeço especialmente a minha orientadora Anna Diva, pela oportunidade, dedicação, pelos conselhos em momentos difíceis e pela confiança durante estes anos.

Agradeço a professora Mara por tirar muitas dúvidas e por ser tão atenciosa e cuidadosa.

Agradeço ao Deoclécio por sempre cuidar muito bem do meu computador.

Agradeço ao Jundival por sempre guardar para mim um pão de batata.

Agradeço ao laboratório de Sistemas Inteligentes – SINTEL, ao Programa de Pós-Graduação em Engenharia Elétrica e à FEIS por proporcionarem a estrutura para a concretização deste trabalho.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

*“if you don’t know where you want to go,
then it doesn’t matter which path you take”*
(Lewis Carroll)

RESUMO

O presente trabalho tem como objetivo desenvolver um modelo baseado em redes neurais artificiais e transformada *wavelet* para a previsão de consumo de energia elétrica de um consumidor de nível desagregado. O conjunto de dados utilizado pertence a um Centro de Pesquisa Brasileiro e foi adquirido por meio de um medidor inteligente instalado no prédio, em que as medições foram feitas em intervalos de 15 minutos. Primeiramente, a rede neural ANFIS foi treinada com diferentes funções de pertinência com os dados brutos de consumo de energia a fim de selecionar a arquitetura que possui o melhor desempenho entre as diferentes configurações permitidas. Em seguida, usando essa arquitetura, a transformada *wavelet* foi aplicada aos dados de consumo de energia para remover o ruído e suavizar as curvas. Para tanto, diferentes *wavelets* foram utilizadas para determinar aquelas que melhor se adequam à aplicação. As previsões foram avaliadas por análise visual de gráficos e cálculo do MAPE. Os resultados obtidos com o modelo proposto são superiores quando comparados aos gerados apenas com os dados brutos. Dentre as *wavelets* utilizadas, aquelas que apresentam números adequados de momentos nulos, simetria e suporte compacto produziram as melhores previsões.

Palavras-chave: Lógica *Fuzzy*. Previsão de carga de curto prazo. Redes neurais artificiais. Transformada *Wavelet*.

ABSTRACT

This work presents a model based on the *Fast Wavelet Transform* and ANFIS neural network for prediction the electric consumption habits of a disaggregated level consumer. The dataset employed belongs to a Brazilian Research Center and it was acquired by a smart meter installed in the building, where measurements were made in a 15-minutes interval. Firstly, the ANFIS neural network was trained with different membership functions with the raw energy consumption data in order to select the architecture that has the best performance among the different configurations allowed. Then, using such architecture, the *Fast Wavelet Transform* was applied to the energy consumption data to remove noise and smooth the curves. For this purpose, different wavelets were used to determine those that best suit the application. The forecasts were evaluated by visual analysis of graphs and by calculating the MAPE. Results obtained with the *Fast Wavelet Transform* are superior when compared to the ones generated using only the raw data. Among the wavelets used, those that have an appropriate number of vanishing moments, symmetric property and compact support produced the best predictions.

Keywords: Artificial neural networks. Fuzzy logic. Short-term load forecast. Wavelet transform.

LISTA DE ILUSTRAÇÕES

Figura 1 – Processo de decomposicao da TWR.	26
Figura 2 – Processo de reconstrução da TWR.	27
Figura 3 – <i>Wavelet Haar</i>	28
Figura 4 – <i>Wavelet db4</i>	29
Figura 5 – <i>Wavelet db10</i>	29
Figura 6 – <i>Wavelet db20</i>	29
Figura 7 – <i>Wavelet sym4</i>	30
Figura 8 – <i>Wavelet sym10</i>	30
Figura 9 – <i>Wavelet sym20</i>	31
Figura 10 – <i>Wavelet coif1</i>	31
Figura 11 – <i>Wavelet coif2</i>	32
Figura 12 – <i>Wavelet coif5</i>	32
Figura 13 – <i>Wavelet Meyer</i>	33
Figura 14 – Sistema de aprendizagem supervisionada.	35
Figura 15 – Sistema de Inferência <i>Fuzzy</i>	36
Figura 16 – Estrutura da ANFIS.	37
Figura 17 – Variação dos parâmetros $\{a_i, b_i, c_i\}$	39
Figura 18 – Raciocínio <i>fuzzy</i> para a ANFIS com duas entradas e duas regras.	41
Figura 19 – Curva de consumo de energia semanal.	47
Figura 20 – Curva de consumo de energia com dias atípicos.	47
Figura 21 – Diagrama de blocos do modelo proposto.	49
Figura 22 – Previsões da ANFIS com duas funções de pertinência.	54
Figura 23 – Previsões da ANFIS com três funções de pertinência.	55
Figura 24 – Sinal decomposto via TWR em um nível de decomposição.	56
Figura 25 – Sinal reconstruído removendo os componentes de alta frequência da decomposição em nível 1.	56
Figura 26 – Sinal decomposto via TWR em dois níveis de decomposição.	57
Figura 27 – Sinal reconstruído removendo os componentes de alta frequência da decomposição em nível 2.	57
Figura 28 – Sinal decomposto via TWR em três níveis de decomposição.	58
Figura 29 – Sinal reconstruído removendo os componentes de alta frequência da decomposição em nível 3.	58
Figura 30 – MAPEs das <i>wavelets</i> da família Daubechies.	60
Figura 31 – MAPEs das <i>wavelets</i> da família Symlets.	60
Figura 32 – MAPEs das <i>wavelets</i> da família Coiflets.	61
Figura 33 – MAPEs das <i>wavelets</i> de Meyer.	61
Figura 34 – MAPEs das <i>wavelets</i> de Haar.	62

Figura 35 – Previsões de domingo no terceiro nível de decomposição.	68
Figura 36 – Previsões segunda-feira no terceiro nível de decomposição.	68
Figura 37 – Previsões terça-feira no terceiro nível de decomposição.	69
Figura 38 – Previsões quarta-feira no terceiro nível de decomposição.	69
Figura 39 – Previsões quinta-feira no terceiro nível de decomposição.	70
Figura 40 – Previsões sexta-feira no terceiro nível de decomposição.	70
Figura 41 – Previsões de sábado no terceiro nível de decomposição.	71
Figura 42 – Previsão da semana seguinte sem a aplicação da TWR.	71
Figura 43 – Previsão da semana seguinte com a <i>wavelet</i> de Meyer no primeiro nível de decomposição.	72
Figura 44 – Previsão da semana seguinte com a <i>wavelet</i> sym20 no segundo nível de decomposição.	72
Figura 45 – Previsão da semana seguinte com a <i>wavelet</i> sym4 no terceiro nível de decomposição.	73
Figura 46 – Previsão das melhores wavelets em relação à curva de consumo real. . .	73

LISTA DE TABELAS

Tabela 1	–	Duas fases do algoritmo de aprendizagem híbrido da ANFIS	42
Tabela 2	–	Resultado da previsão com diferentes funções de pertinência.	53
Tabela 3	–	Quantidade de amostras utilizadas.	59
Tabela 4	–	Detalhes da ANFIS.	59
Tabela 5	–	MAPEs para o sistema <i>wavelet</i> –ANFIS com a aplicação de diferentes <i>wavelets</i> com decomposição nível 1.	64
Tabela 6	–	MAPEs para o sistema <i>wavelet</i> –ANFIS com a aplicação de diferentes <i>wavelets</i> com decomposição nível 2.	64
Tabela 7	–	MAPEs para o sistema <i>wavelet</i> –ANFIS com a aplicação de diferentes <i>wavelets</i> com decomposição nível 3.	65
Tabela 8	–	MAPE para a previsão de todos os dias.	65

LISTA DE ABREVIATURAS E SIGLAS

AMR	Análise de Multirresolução
ANFIS	<i>Adaptive Neuro-Fuzzy Inference System</i>
ARIMA	<i>Autoregressive Integrated Moving Average</i>
ELM	<i>extreme learning machine</i>
LSTM	<i>Long Short-Term Memory</i>
LSE	<i>Least-Squares Estimator</i>
MAPE	<i>Mean Absolute Percentage Error</i>
MATLAB [®]	<i>Matrix Laboratory</i>
MLP	<i>Multilayer Perceptron</i>
RNA	Redes Neurais Artificiais
STLF	<i>Short-Term Load Forecast</i>
T-S	Takagi-Sugeno
TW	Transformada <i>Wavelet</i>
TWC	Transformada Wavelet Contínua
TWD	Transformada Wavelet Discreta

LISTA DE SÍMBOLOS

$\psi(t)$	Função <i>Wavelet</i>
$\mathbb{R}$	Conjunto dos números reais
$L^2(\mathbb{R})$	Espaço de funções de energia finita
c_ψ	Valor da condição de admissibilidade
$\Psi(\Omega)$	Transformada de Fourier da função <i>Wavelet</i>
j	Parâmetro imaginário da transformada de Fourier
u	Parâmetro de translação
s	Parâmetro de escala
ℓ	Nível de resolução
n	Índice de tempo discreto
V_ℓ	Espaço de aproximação no nível ℓ
W_ℓ	Espaço de detalhe no nível ℓ
$\mathbb{Z}$	Conjunto dos numeros inteiros
ϕ	Função escala
$\widetilde{H}$	Filtro passa-baixa de decomposição
$\widetilde{G}$	Filtro passa-alta de decomposição
$x[n]$	Sinal de tempo discreto
$\downarrow 2$	Operador <i>downsampling</i>
$\uparrow 2$	Operador <i>upsampling</i>
H	Filtro passa-baixa de reconstrução
G	Filtro passa-alta de reconstrução
N	Número de momentos nulos de uma <i>wavelet</i>
x_1 e x_2	Entradas da ANFIS
p, q, r	Conjunto de parâmetros do consequente

y	Saída do sistema <i>fuzzy</i>
$\mu A_i(x_1)$	Funções de pertinência das entradas
$\{a_i, b_i, c_i\}$	Conjunto de parâmetros dos antecedentes
w_i	Regras <i>fuzzy</i> do tipo T-S
p	Número de padrões de entrada
m	Número de variáveis de entrada
n	Número de neurônios na camada de regras
P	Número de padrões de entrada-saída
k	Vetor de parâmetros do consequente
α	Taxa de aprendizagem da rede
E	Erro quadrático do neurônio de saída da rede

SUMÁRIO

1	INTRODUÇÃO	12
1.1	Objetivos	13
1.2	Contribuições desta Tese	14
1.3	Estrutura do Texto	14
2	REVISÃO BIBLIOGRÁFICA	16
3	TRANSFORMADA WAVELET	23
3.1	Transformada Wavelet Contínua	23
3.2	Transformada Wavelet Discreta	24
3.3	Análise Multirresolução	25
3.3.1	Banco de Filtros	26
3.4	Famílias Wavelets	27
3.4.1	Haar	28
3.4.2	Daubechies	28
3.4.3	Symlets	30
3.4.4	Coiflets	31
3.4.5	Meyer	32
4	ADAPTIVE-NETWORK-BASED FUZZY INFERENCE SYS- TEM	34
4.1	Redes Neurais Adaptativas	34
4.2	Sistema de Inferência <i>Fuzzy</i>	35
4.3	Arquitetura da ANFIS	37
4.4	Aprendizagem da ANFIS	41
5	CENÁRIO DE ESTUDOS	46
6	MODELO PROPOSTO	49
6.1	Critério Para Avaliação da Previsão	52
7	RESULTADOS E DISCUSSÕES	53
7.1	Simulações e testes	53
7.2	Representação por meio da análise multirresolução	55
7.3	Previsões	58
7.4	Resultados Gráficos	67
7.4.1	Previsões individuais	67
7.4.2	Previsões semanais	71

8	CONCLUSÕES	75
8.1	Trabalhos Futuros	76
	REFERÊNCIAS	77

1 INTRODUÇÃO

O avanço tecnológico dos últimos anos tem contribuído para o desenvolvimento de novos conceitos e ferramentas para a solução de problemas do setor elétrico (JESUS; ANTUNES, 2018). Dentre estes conceitos, os sistemas de distribuição de energia elétrica modernos (*smart grid*) (WORIGHI et al., 2019; OURAHOU et al., 2020; DILEEP, 2020) ganharam atenção dos centros de pesquisa e das concessionárias de energia elétrica, uma vez que visam tornar o sistema inteligente e totalmente automatizado mediante o uso de tecnologias avançadas de monitoramento e gerenciamento da energia elétrica (ELZINGA; HEINEN, 2011; DILEEP, 2020).

Como consequência, esta automatização reduz a dependência e interferência dos operadores humanos na gestão de procedimentos e tomada de decisão. Em outras palavras, os índices de confiabilidade, continuidade e qualidade do fornecimento de energia são melhorados substancialmente e, concomitantemente, a lucratividade das empresas do setor elétrico (geração, transmissão e distribuição) (WORIGHI et al., 2019; OURAHOU et al., 2020).

No entanto, para que isto ocorra de maneira integral e abrangente, deve-se conhecer os distintos padrões de consumo de energia do consumidor final, e.g., residencial, rural ou comercial, para que assim sejam realizadas previsões de carga mais precisas e confiáveis (QUILUMBA et al., 2014; XU; WANG; TANG, 2019; XUE et al., 2019). Dentro desta perspectiva, os *smart meters* se tornam componentes indispensáveis da AMI (*Advanced Metering Infrastructure*), já que são os equipamentos que mantêm toda a *smart grid* conectada (SUN et al., 2015; LI; OTA; DONG, 2017; ASGHAR et al., 2017; PAU et al., 2018; AVANCINI et al., 2019). Por se comunicarem com os centros de operação, os *smart meters* fornecem os dados de consumo de cada um dos clientes em tempo real e em diferentes intervalos (LLORET et al., 2016), e.g., por minuto, por hora, por dia ou frações destes. É de extrema importância que cada carga seja classificada de acordo com o seu tipo, pois até mesmo uma pequena melhoria na precisão da previsão pode significar grande economia de custos e, também, uma grande contribuição para o meio ambiente. Essa técnica é conhecida na literatura como *bottom-up* e é aplicada a partir da separação de grandes blocos de consumo (nível agregado) em modelos individuais de pequenos blocos separados (nível desagregado) (ZHENG; CHEN; LUO, 2019).

Com o grande volume de dados, a inspeção visual e a seleção manual destas informações para estudos acerca da operação, do planejamento e da expansão tornam-se impraticáveis, estando também sujeitos a erros provocados pelos operadores humanos (TONELLI-NETO et al., 2017). Historicamente, a análise de tendências e o desenvolvimento de modelos de previsão têm sido realizados via métodos estatísticos, e.g., regressão linear simples ou múltipla (MADRIGAL, 2012), suavização exponencial (GARDNER JR, 1985) e (HAGAN; BEHR, 1987), ARIMA (BOX et al., 2015), ou com os sistemas inteligentes, e.g.,

machine learning (MICHIE, 1968) como as redes neurais artificiais (WIDROW; LEHR, 1990; KARTALOPOULOS, 1997; HAYKIN, 2001), lógica *fuzzy* (ZADEH, 1965; ZADEH, 1988) e sistemas imunológicos artificiais (DASGUPTA, 2012). Embora estes dois conceitos apresentem diversos pontos positivos, os sistemas inteligentes se destacam por serem mais precisos e confiáveis (BEDI; TOSHNIWAL, 2019). Isto é, eles possuem a capacidade de capturar singularidades (não linearidades) no banco de dados que, se não forem corretamente avaliadas, podem gerar previsões errôneas (BEDI; TOSHNIWAL, 2019). Assim, o consumidor final será diretamente impactado, uma vez que podem ser observadas interrupções no fornecimento de energia em virtude de planejamentos de geração de energia elétrica mal executados.

Dentro desta perspectiva, neste trabalho é proposta uma metodologia híbrida *wavelet*–ANFIS aplicada na previsão de cargas elétricas em curto prazo. A transformada *wavelet* tem como função a remoção de ruídos e *outliers* nas informações de consumo de energia elétrica presentes no banco de dados, o que aumenta a eficiência da previsão. A rede neural ANFIS foi escolhida por ser bastante robusta e rápida, pré-requisitos indispensáveis para aplicações em tempo real. Embora a ANFIS já produza resultados satisfatórios, sua combinação com a transformada *wavelet* mostrou-se superior em relação a outros estudos que empregam técnicas de pré-processamento para a remoção de ruídos. Para validação do método, foi usado um banco de dados de uma instituição de ensino brasileira que possui nível de consumo totalmente desagregado, i.e., os dados apresentam maior aleatoriedade (menos previsível) do que um local onde o consumo é agregado (mais previsível).

1.1 OBJETIVOS

O objetivo principal deste trabalho é desenvolver uma nova metodologia que seja eficiente para previsão de cargas elétricas em curto prazo de locais onde o perfil de consumo de energia elétrica é considerado desagregado (nível de consumidor). A partir da análise do comportamento da ANFIS na previsão, bem como o impacto da utilização da análise multirresolução na remoção de ruído das séries coletadas para o estudo.

Objetivos específicos:

- realizar pré-processamento dos dados, de modo a prepará-los para etapas de treinamento e previsão;
- codificar a ANFIS;
- realizar previsões de cargas com a ANFIS com diferentes configurações;
- selecionar a melhor configuração da ANFIS para o problema;

- representar os dados de consumo de energia por meio da análise multirresolução utilizando diferentes funções *wavelets*;
- realizar previsões com as séries suavizadas;
- determinar as *wavelets* que obtiveram melhores resultados.

1.2 CONTRIBUIÇÕES DESTA TESE

Neste trabalho é proposta uma nova metodologia para lidar com o problema da previsão de cargas elétricas em curto prazo em nível de consumidor final, desde o pré-processamento até a previsão.

Contribuições:

- investigar o impacto das previsões da ANFIS em ambientes de difícil previsão utilizando diferentes funções de pertinência;
- analisar a consequência da aplicação da análise multirresolução nas previsões;
- observar os gráficos do comportamento das previsões com as diferentes *wavelets*;
- selecionar as *wavelets* que obtiveram melhor desempenho a partir da análise dos MAPEs calculados, de modo a propor novas abordagens.

Resumidamente, este trabalho visa aplicar o modelo *wavelet*–ANFIS desenvolvido para previsão de carga de curto prazo em nível de consumo desagregado e analisar a capacidade do modelo proposto bem como suas deficiências.

1.3 ESTRUTURA DO TEXTO

Além deste capítulo introdutório, estão resumidos a seguir os sete capítulos restantes:

- O capítulo 2 contém a revisão bibliográfica, descrevendo as contribuições dos principais trabalhos presentes na literatura que abordam previsão de cargas elétricas em curto prazo em diferentes níveis de agregação, destacando os seus resultados e as técnicas utilizadas para realizar a previsão, bem como a utilização de ferramentas de remoção de ruídos nas séries históricas analisadas.
- No capítulo 3 são apresentados os principais conceitos da ferramenta utilizada para a remoção de ruídos dos dados de consumo de energia, i.e., a transformada *wavelet*, análise multirresolução, bem como as famílias *wavelets* utilizadas.

- O capítulo 4 traz uma breve descrição das redes neurais adaptativas e do sistema de inferência *fuzzy*, a descrição detalhada da arquitetura da ANFIS e a sua forma de aprendizagem.
- No capítulo 5 é descrito o cenário que fornece as informações de consumo de energia utilizadas neste trabalho e a maneira como os dados foram obtidos.
- O capítulo 6 engloba todos os passos efetuados no modelo proposto, desde o pré-processamento até a previsão.
- No capítulo 7 são apresentadas as simulações e testes realizados com a ANFIS, bem como com as diferentes *wavelets*, resultando no modelo proposto *wavelet*–ANFIS. São feitas comparações da performance da ANFIS com suas diferentes configurações e da performance da ANFIS com as *wavelets* utilizadas. Os resultados são avaliados a partir do cálculo do MAPE.
- As conclusões e sugestões de trabalhos futuros são apresentados no capítulo 8.

2 REVISÃO BIBLIOGRÁFICA

Na literatura especializada, é possível encontrar metodologias distintas que têm como principal objetivo a previsão de cargas elétricas em curto prazo, i.e., previsão da carga de meia hora até uma semana à frente (GROSS; GALIANA, 1987). Não obstante, quando se fala em previsão de cargas elétricas em curto prazo, a maioria dos estudos têm como foco o desenvolvimento de modelos previsores para cargas agregadas usando índices comportamentais, socioeconômicos, técnicos e climáticos. Tais estudos já foram aplicados em dados da África do Sul (LEBOTSA et al., 2018), Austrália (LI et al., 2017; XIAO et al., 2017; FAN; PENG; HONG, 2018; ZHANG et al., 2018; MOHAN; SOMAN; KUMAR, 2018; SINGH; DWIVEDI, 2018; TAVASSOLI-HOJATI et al., 2020), Canadá (EL-HENDAWI; WANG, 2020), China (XIAO et al., 2017; LIANG; NIU; HONG, 2019; HU et al., 2020), Coreia do Sul (KIM et al., 2019), Eslováquia (ZHANG et al., 2018; XIE et al., 2019), EUA (FAN; PENG; HONG, 2018; MOHAN; SOMAN; KUMAR, 2018; SINGH; DWIVEDI, 2018; BENTO et al., 2019; TAVASSOLI-HOJATI et al., 2020), Malásia (SADAEI et al., 2019), Portugal (BENTO et al., 2019) e Singapura (HE et al., 2017).

Li et al. (2017) apresentam um modelo híbrido para previsão de cargas elétricas em curto prazo para programar e gerenciar a geração da energia elétrica. Tal modelo é intitulado EEMD-SCGRNN-PSVR, que vem da combinação das técnicas, decomposição em modo empírico conjunto (EEMD), ajuste sazonal (S), validação cruzada (C), rede neural de regressão generalizada (GRNN) (SPECHT, 1991) e máquina de regressão vetorial de suporte otimizada pelo algoritmo enxame de partículas (PSVR). O modelo é utilizado para prever cargas elétricas uma semana à frente em dois conjuntos de dados da Austrália. O método proposto apresenta uma melhora significativa na previsão.

Xiao et al. (2017) propõem um modelo híbrido para previsão de cargas elétricas em curto prazo, previsão de velocidade de vento e previsão do preço da eletricidade. O modelo utiliza a análise espectral singular (SSA) e rede neural *wavelet* (WNN) modificada. Um algoritmo de *cuckoo search* (CS) otimizado é proposto para aprimorar os pesos iniciais e os parâmetros de escala e translação da WNN. Para a avaliação do mesmo, são usados dados de consumo de meia em meia hora e de hora em hora de regiões da Austrália, e os dados de energia eólica de quatro usinas de Penglai, na China. Os experimentos mostram que com a aplicação da ferramenta é possível melhorar os resultados alcançados.

He et al. (2017) realizam a previsão de cargas elétricas em curto prazo por meio da densidade de probabilidade de carga com a técnica *kernel-based support vector quantile regression* (KSVQR) e a teoria de cópulas. Foram comparadas três funções de núcleo neste trabalho, uma vez que esta função pode influenciar no desempenho da previsão. A previsão é avaliada considerando dois critérios: probabilidade de cobertura do intervalo de predição (PICP) e largura média normalizada do intervalo de predição (PINAW). Para a

previsão é utilizado um conjunto de dados reais de Singapura. Os resultados mostram o potencial de previsão do método quando a função apropriada do núcleo é selecionada.

Lebotsa et al. (2018) desenvolvem um modelo para previsão de cargas elétricas em curto prazo a partir da aplicação de modelos de regressão de quantil aditivo parcialmente linear (PLAQR). As previsões foram feitas com foco em horários de pico de consumo de energia, i.e., 18:00 às 20:00, utilizando dados da África do Sul medidos de janeiro de 2009 a junho de 2012. Os autores afirmam que o método pode auxiliar as concessionárias no agendamento e despacho de energia a um custo mínimo, especialmente durante o período de pico.

Zhang et al. (2018) descrevem um modelo baseado na decomposição em modo empírico otimizado (IEMD), ARIMA e rede neural *wavelet* (WNN) que é aprimorada pelo algoritmo de otimização *fruit fly* (FOA) para previsão de cargas elétricas em curto prazo. São utilizados dados de consumo de energia elétrica aferidos na cidade de Nova York e de consumo e temperatura aferidos na Austrália, ambos no período de 1º de novembro de 2011 a 31 de dezembro de 2012. Os resultados apresentam boa performance quando comparados a outras técnicas de previsão.

Mohan, Soman e Kumar (2018) propõem um modelo de previsão de cargas elétricas em curto prazo orientado por dados que empregam a técnica *dynamic mode decomposition* (DMD), o qual identifica com eficiência as características dos dados de carga afetados por vários fatores exógenos, e.g., hora, dia, clima, estações do ano, atividades sociais e aspectos econômicos. Os dados utilizados para essa pesquisa são provenientes de dois mercados de energia chamados AEMO (*Australian Energy Market Operator*) e NAEU (*North American Electric Utility*). Foram feitas medições de meia em meia hora (48 por dia) em 5 estados diferentes pela AEMO e no NAEU foram feitas medições horárias (24 por dia). Devido ao seu baixo custo computacional, os autores salientam que a metodologia é adequada para a previsão de cargas elétricas em tempo real.

Singh e Dwivedi (2018) utilizam redes neurais artificiais na execução da previsão de cargas elétricas em curto prazo. Para ajustar os parâmetros da rede perceptron de múltiplas camadas (MLP) com algoritmo de treinamento *backpropagation*, foi desenvolvido um algoritmo baseado no comportamento de ovelhas dentro de um rebanho em relação a sua movimentação, chamado *follow the leader* (FTL). Os dados com medições horárias foram aferidos nos anos de 2004 a 2007 em estados da Austrália e dos EUA. Por meio de três experimentos, é atestado que o método possui precisão preditiva elevada.

Fan, Peng e Hong (2018) descrevem um modelo híbrido para previsão de cargas elétricas em curto prazo, chamado PSR-BSK. Trata-se da junção do algoritmo *phase space reconstruction* (PSR) e o modelo de regressão *bi-square kernel* (BSK). O modelo proposto é testado em dados provenientes de dois mercados de energia, i.e., *New South Wales* localizado na Austrália e *New York Independent System Operator* nos EUA. Os resultados

mostram que o modelo proposto alcança o mais baixo índice de erro e também o menor tempo de processamento.

Liang, Niu e Hong (2019) apresentam uma ferramenta denominada EMD-mRMR-FOA-GRNN. Trata-se da combinação das técnicas *empirical mode decomposition* (EMD), *minimal redundancy maximal relevance* (mRMR), rede neural de regressão generalizada (GRNN) e o algoritmo de otimização *fruit fly* (FOA). Dados de consumo de energia provenientes de *Lang-fang*, uma cidade da China, juntamente com informações do dia, temperatura e condições meteorológicas são utilizados para verificar a eficácia da ferramenta proposta. Os autores concluem que a técnica é eficaz, eficiente e aplicável em termos de previsão de cargas elétricas em curto prazo.

Kim et al. (2019) utilizam uma rede neural convolucional de início recorrente (RICNN), que combina redes neurais recorrentes (RNN) e redes neurais convolucionais (CNN) de uma dimensão, para realizar a previsão de cargas elétricas em curto prazo de três grandes complexos de distribuição de energia da Coreia do Sul, onde as cargas foram aferidas em intervalos de 30 minutos. Segundo os autores, seus resultados demonstram que o modelo possui excelente performance ao serem comparados aos obtidos por modelos de referência, como MLP, RNN e a CNN de uma dimensão separadamente.

Xie et al. (2019) propõem um método intitulado PSO-ENN, baseado na combinação da rede neural de Elman (ENN) e no algoritmo de otimização de enxame de partículas (PSO) que busca a taxa de aprendizado ideal da rede neural. É mencionado que o desempenho da aplicação depende das condições iniciais da rede e que a única desvantagem do método proposto é o custo computacional elevado. Na validação do mesmo, são utilizados dados de consumo de energia elétrica da Eslováquia, aferido em intervalos de 30 minutos em janeiro de 1999. O PSO-ENN mostrou ser eficiente quando comparado com outras redes neurais, e.g., GRNN, ENN original e MLP.

Bento et al. (2019) apresentam um método híbrido para previsão de cargas elétricas em curto prazo combinando técnicas de seleção de dados aprimoradas e técnicas de extração de recursos, i.e., seleção com base nos dias semelhantes, correlação e análise *wavelet*, para trazer mais regularidade à série temporal para aplicação das redes neurais. A combinação dos algoritmos de gradiente conjugado *Bat* e *Scaled* é proposta com intuito de melhorar a capacidade de aprendizado da RNA. O modelo é testado em dados do sistema de carga nacional de Portugal e em dados de carga da Nova Inglaterra e Nova York e apresenta resultados promissores ao ser comparado com os métodos ENN, redes neurais com função de base radial (RBF) e máquinas de vetores suporte (SVM).

Sadaei et al. (2019) desenvolvem um método combinado para previsão de cargas elétricas em curto prazo baseado em séries temporais difusas (FTS) e CNN. Os dados usados na validação do modelo são provenientes de uma empresa de fornecimento de energia da cidade de Johor, na Malásia, e foram aferidos nos anos de 2009 e 2010. Os

autores salientam que o uso da lógica *fuzzy* contribui grandemente para a boa performance do método proposto, que prova sua eficiência ao se comparar com outros métodos, i.e., *seasonal autoregressive integrated moving average* (SARIMA), séries temporais nebulosas ponderadas probabilísticas (PWFTS) e suas variações e três modelos de *long short-term memory* (LSTM) em inúmeros experimentos.

Tavassoli-Hojati et al. (2020) propõem um modelo que visa realizar previsão de cargas elétricas em curto prazo de maneira rápida e precisa. Tal modelo é um aprimoramento do método *local linear neuro-fuzzy* (LLFN), que por sua vez trata-se da combinação de modelos neuro-fuzzy e técnicas de modelagem local. O modelo é testado com dados reais de dois mercados de energia, i.e., AEMO, que é localizado em New South Wale, estado no sudeste da Austrália e no *New York Independent System Operator* (NYISO) localizado nos EUA. São feitas previsões de uma, 12 e 24 horas à frente, alcançando resultados superiores comparados a métodos comumente utilizados na literatura.

El-Hendawi e Wang (2020) propõem o desenvolvimento de uma rede neural *wavelet* completa para previsão de cargas elétricas em curto prazo, a partir da transformada *wavelet* (TW) que é utilizada para decompor as informações do banco de dados em diferentes frequências e estas componentes são apresentadas à rede neural para o treinamento e previsão. Em todos os testes são utilizadas redes neurais MLP de três camadas, com 20 neurônios na camada escondida, utilizando como função de ativação a tangente hiperbólica e o algoritmo de treinamento Levenberg-Marquardt. O modelo é testado em dados do mercado de energia de Ontário, no Canadá. Os autores destacam que a abordagem proposta reduz consideravelmente o percentual de erro em comparação ao método de redes neurais artificiais tradicional.

Hu et al. (2020) propõem um modelo híbrido para previsão de cargas elétricas em curto prazo denominado série temporal *wavelet* (WTS), desenvolvido a partir da transformada *wavelet* (TW) de Daubechies, *Holt-Winters* (HW) e a rede neural RBF para que o cálculo rápido e a capacidade de ajuste de carga não linear sejam obtidos de maneira satisfatória. Neste estudo é utilizado conjunto de dados de consumo de energia providenciado pelo sistema de aquisição de dados de consumo de energia (PCDAS) da rede estadual e de dados meteorológicos reais da China, medidos de janeiro de 2009 a janeiro de 2014 com intervalos de 15 minutos, a temperatura é medida a cada hora e diariamente é feita a medição de chuva e umidade. É verificado pelos resultados numéricos que o modelo proposto é capaz de obter erros mínimos nas previsões.

Por outro lado, o número de estudos que abordam a previsão de cargas elétricas em curto prazo em nível desagregado é bastante reduzido. Alguns destes estudos foram realizados utilizando dados provenientes de bancos de dados da Austrália (KONG et al., 2017b; LUSIS et al., 2017), Canadá (KONG et al., 2017a), China (ZENG; LIU; YU, 2019), EUA (VOSS; BENDER-SAEBELKAMPF; ALBAYRAK, 2018; ZHENG; CHEN; LUO, 2019; CHITALIA et

al., 2020), Índia (CHITALIA et al., 2020), Irlanda (SHI; XU; LI, 2017; WANG et al., 2019), Reino Unido (ZHENG; CHEN; LUO, 2019) e Tailândia (CHITALIA et al., 2020).

Kong et al. (2017a) utilizam a rede LSTM para realizar a previsão de cargas elétricas em curto prazo em nível desagregado. Os dados de consumo de energia foram coletados por um ano inteiro em intervalos de 30 minutos em residências canadenses. Os dados foram coletados de seis aparelhos manuais que consomem energia e que são mais relevantes para o estilo de vida dos residentes, i.e., secadora de roupas, máquina de lavar roupas, máquina de lavar louça, bomba de calor, televisão e forno elétrico. Os resultados da previsão foram comparados com os resultados obtidos a partir do uso de uma perceptron de múltiplas camadas e a técnica *k-nearest neighbors* (KNN), e apresentou resultados superiores, alcançando torno de 23% de erro médio obtido por meio do cálculo do MAPE.

Kong et al. (2017b), similarmente à Kong et al. (2017a), propõem a aplicação da RNN LSTM em previsão de cargas elétricas em curto prazo em nível desagregado. Dados de consumo foram coletados de 69 residências australianas em intervalos de 30 minutos no período de 3 meses. Os autores salientam que RNNs possuem características ideais para o tipo de problema, alcançando MAPEs em torno de 44%. Os resultados mostram que a técnica proposta supera diversos algoritmos a que foi comparada em termos de previsão em residências individuais, i.e. MLP com algoritmo de treinamento *backpropagation*, KNN, máquinas de aprendizado extremo (ELM) e um algoritmo de seleção de entrada com uma estrutura de previsão híbrida (IS-HF).

Lusis et al. (2017) apresentam um estudo de como o calendário e a granularidade dos dados impactam diretamente na previsão de cargas elétricas em curto prazo em nível desagregado, principalmente dos consumidores residenciais. Foram aplicadas várias técnicas de previsão em um banco de dados que contém informações de 27 residências australianas com medições feitas de julho de 2010 a junho de 2013 em intervalos de 30 minutos. Os autores destacam que conforme a granularidade aumenta os resultados melhoram, pois as curvas de consumo ficam cada vez mais suaves, tendo em vista que todas as técnicas utilizadas falharam em capturar alguns dos picos de consumo. Os autores concluem que um ano de dados históricos é suficiente para desenvolver um modelo de previsão de carga para clientes residenciais e mostram que os erros de previsão podem ser reduzidos usando uma granularidade de previsão mais grosseira.

Shi, Xu e Li (2017) propõem uma RNN profunda baseada em agrupamento para previsão de cargas elétricas em curto prazo em nível desagregado. O modelo proposto agrupa perfis de consumo de energia dos clientes em um grupo de entradas para posterior previsão. O método desenvolvido é implementado em uma plataforma de aprendizagem profunda chamada *Tensorflow* e testado em 920 clientes da *Smart Metering Electricity Customer Behaviour Trials*, iniciado pela Comissão de Regulamentação de Energia da Irlanda. Os dados foram coletados de julho de 2009 a dezembro de 2010, contando com

mais de 5000 consumidores residenciais irlandeses e pequenas e médias empresas. Os autores salientam que os resultados obtidos pelo modelo proposto são satisfatórios ao comparar com performances de técnicas como ARIMA e RNN clássica.

Voß, Bender-Saebelkampff e Albayrak (2018) utilizam uma CNN e um modelo chamado *Wavenet*, que é baseado em CNN, que foi desenvolvido para lidar com dados de série temporal ruidosos para reconhecimento de voz e síntese, para previsão de cargas elétricas em curto prazo em nível desagregado. São utilizados dados provenientes do conjunto de dados de consumo doméstico do *Pecan Street Dataport* coletados de 2015 a 2016 em residências em Austin e em Boulder nos EUA. Nas previsões para residências individuais os resultados mostram que o modelo proposto possui desempenho similar e ligeiramente melhor do que o modelo de RNA a que foi comparado.

Zeng, Liu e Yu (2019) apresentam um estudo em que comparam a performance de quatro métodos de previsão de cargas elétricas em curto prazo em nível desagregado, i.e., RNA, *gaussian process regression* (GPR), *support vector machine* (SVM), *multivariate linear regression* (MLR). Os dados históricos utilizados são de diferentes tipos de consumidores, i.e., shoppings, escritórios e hotéis, todos localizados em Shangai, na China. Os autores destacam que, considerando a acurácia da previsão, a melhor técnica dentre as analisadas é a MLR, enquanto SVM é o melhor para lidar com entradas complexas, GPR apresenta menor custo computacional e o uso de RNA não é recomendado a não ser que haja muitas incertezas no banco de dados analisado.

Zheng, Chen e Luo (2019) defendem a abordagem *bottom-up* baseada no filtro de Kalman para execução da previsão de cargas elétricas em curto prazo em nível desagregado. Os dados de consumo são provenientes de três bancos de dados distintos e públicos. Os dois primeiros de duas residências dos EUA, uma do *National Institute of Standards of Technology*, em que dados foram coletados por 11 meses, e a outra da *University of California*, coletados durante um período de aproximadamente 4 anos com intervalo de 1 minuto, o terceiro banco de dados é de cinco residências do Reino Unido coletado por um período de 5 anos. Os autores salientam que uma abordagem *bottom-up* equipada com um algoritmo leve como o filtro de Kalman pode superar os resultados obtidos com RNN LSTM, com menos dados históricos e com menor custo computacional

Wang et al. (2019) propõem um método probabilístico para previsão de cargas elétricas em curto prazo em nível desagregado. A RNN LSTM é utilizada para modelar as curvas de consumo e a função *pinball loss* guia o treinamento dos parâmetros, de maneira que a previsão baseada em LSTM tradicional é estendida para a previsão probabilística na forma de quantis. O modelo é aplicado em um conjunto de dados irlandeses oriundos de um conjunto de dados aberto da Irlanda, que contém em torno de 6000 curvas de consumo de residências e comércios medidos com intervalos de 30 minutos. As previsões foram comparadas com a LSTM tradicional, com *quantile regression neural network* (QRNN) e

quantile gradient boosting regression tree (QGBRT). Os autores concluem que o método proposto obteve melhor performance do que os modelos aos quais os resultados foram comparados.

Chitalia et al. (2020) apresentam uma estrutura para previsão de cargas elétricas em curto prazo em nível desagregado. São testadas nove redes neurais recorrentes, dentre elas estão as RNN LSTM, BiLSTM, CNN, modelo Encoder-Decoder e as combinações dos mesmos. A estrutura proposta é validada em dados de cinco consumidores comerciais de diferentes tipos, i.e., escritório, escola, loja de doces, academia e laboratório de pesquisa, localizados em diferentes regiões dos EUA, i.e., Virginia, New York e Massachusetts, em Bangkok, na Tailândia e em Hyderabad, na Índia. Os autores concluem que de acordo com os resultados obtidos a robustez da estrutura proposta é validada para previsão de consumo de energia em nível de consumidor.

3 TRANSFORMADA WAVELET

A transformada *wavelet* (GROSSMANN; MORLET, 1984; MEYER, 1985) é uma ferramenta prática para análise de sinais. Tal ferramenta pode ser utilizada na decomposição de sinais em diferentes níveis de resoluções. Isso pode ser feito por meio de funções denominadas *wavelets*. Tais funções satisfazem certos requisitos matemáticos e são usadas na representação de dados ou outras funções (GRAPS, 1995). A análise *wavelet* é baseada na decomposição do sinal em diferentes componentes e, então, se estuda cada um destes componentes em suas respectivas escalas (DAUBECHIES, 1992).

Diferente da transformada de Fourier janelada, que decompõe os sinais na mesma resolução de tempo e frequência, a transformada *wavelet* altera a resolução de tempo e frequência. Isto resolve o problema de processamento de sinais, quando um sinal inclui estruturas com diferentes resoluções de tempo-frequência, algumas sendo muito localizadas no tempo e outras muito localizadas na frequência (MALLAT et al., 2009).

Uma *wavelet* real é uma função $\psi(t) \in L^2(\mathbb{R})$, ou seja, uma função de energia finita, que satisfaz a condição de admissibilidade (1) (CALDERÓN, 1964)

$$c_\psi = \int_0^\infty \frac{|\Psi(\Omega)|^2}{\Omega} d\Omega < +\infty, \quad (1)$$

sendo $\Psi(\Omega)$ a Transformada de Fourier da função *wavelet*, isto é,

$$\Psi(\Omega) = \int_{-\infty}^{\infty} \psi(t) e^{-j\Omega t} dt, \quad (2)$$

em que j representa a unidade imaginária.

Uma das maneiras de se caracterizar uma *wavelet* é por meio do seu número de momentos nulos, quanto mais momentos nulos mais suave é a função *wavelet* (MEYER, 1993). Uma *wavelet* possui N momentos nulos se a condição expressa pela Equação (3) for verificada.

$$\int_{-\infty}^{+\infty} t^\eta \psi(t) dt = 0, \quad \eta = 0, 1, \dots, N-1. \quad (3)$$

3.1 TRANSFORMADA WAVELET CONTÍNUA

A transformada *wavelet* contínua utiliza versões transladadas e escalonadas como função básica, ou seja, conforme definida pela equação (4) (DAUBECHIES, 1988; MALLAT,

1989; GROSSMANN; MORLET, 1984; MEYER, 1989; VETTERLI; KOVACEVIC, 1995).

$$\psi_{u,s}(t) = \frac{1}{\sqrt{s}} \psi\left(\frac{t-u}{s}\right), \quad (4)$$

sendo:

u : parâmetro de translação; e

s : parâmetro de escala.

O parâmetro de translação determina a posição em que a *wavelet* se localiza no eixo das abscissas, ou seja, determina a sua localização no tempo, e o parâmetro de escala mede o grau de dilatação da *wavelet* (MALLAT et al., 2009).

Para os parâmetros de escala s , $s > 0$, e de translação u , e para uma *wavelet* real $\psi(t)$, a transformada *wavelet* contínua de um sinal de tempo contínuo $f(t) \in L^2(\mathbb{R})$, é definida pela Equação (5) (GROSSMANN; MORLET, 1984; DAUBECHIES, 1992).

$$W(u, s) = \langle f, \psi_{u,s} \rangle = \int_{-\infty}^{+\infty} f(t) \frac{1}{\sqrt{s}} \psi\left(\frac{t-u}{s}\right) dt, \quad (5)$$

A transformada *wavelet* contínua de um sinal depende da função *wavelet* escolhida. Quanto maior for o parâmetro s , maior será o suporte efetivo da *wavelet* e vice-versa, logo, escalas altas estão associadas a representação dos sinais de componentes de baixa frequência e escalas baixas estão associadas a representação dos sinais de componentes de alta frequência (DAUBECHIES, 1992).

3.2 TRANSFORMADA WAVELET DISCRETA

Uma forma prática de implementar a transformada *wavelet* é utilizar a seguinte discretização dos parâmetros de escala e de translação (DAUBECHIES, 1992; MALLAT et al., 2009):

- $s = s_0^\ell$
- $u = \eta u_0 s_0^\ell$
- $\ell, \eta \in \mathbb{Z}$
- $s_0 > 1, u_0 > 0$ (valores fixos).

Isto é feito pois, na prática, a transformada *wavelet* contínua é implementada por meio da discretização destes parâmetros.

Se $s_0 = 2$ e $u_0 = 1$, então existe ψ , com propriedades de localização tempo-frequência adequadas, tal que,

$$\psi_{\ell,\eta} = 2^{-\ell/2} \psi(2^{-\ell}t - \eta), \quad (6)$$

constitui uma base ortonormal para $L^2(\mathbb{R})$. Neste caso a transformada *wavelet* discreta (TWD) é referida como transformada *wavelet* diática ortonormal (MALLAT et al., 2009) e é implementada por meio da transformada *wavelet* rápida que, por sua vez, vem da análise multirresolução.

3.3 ANÁLISE MULTIRRESOLUÇÃO

Uma análise multirresolução em $L^2(\mathbb{R})$ é uma sequência de subespaços fechados V_ℓ , $\ell \in \mathbb{Z}$ de $L^2(\mathbb{R})$, que satisfazem as seguintes propriedades (MALLAT, 1989):

$$V_\ell \subset V_{\ell-1}, \quad (7)$$

$$f \in V_\ell \Leftrightarrow f(2u) \in V_{\ell-1}, \quad (8)$$

$$\bigcap_{\ell \in \mathbb{Z}} V_\ell = \{0\}, \quad (9)$$

$$\overline{\bigcap_{\ell \in \mathbb{Z}} V_\ell} = (L^2\mathbb{R}), \quad (10)$$

$$\exists \phi \in V_0 \text{ tal que } \{\phi(u - k); k \in \mathbb{Z}\} \text{ é uma base ortonormal de } V_0, \quad (11)$$

sendo que (9) é consequência de (7), (8) e (11) (DAUBECHIES, 1992).

As representações por multirresolução são muito eficazes para analisar o conteúdo de informação dos sinais. Uma base *wavelet* ortonormal em $L^2(\mathbb{R})$ pode ser utilizada para obter a diferença e a aproximação entre as informações de um sinal nas resoluções $2^{\ell+1}$ e 2^ℓ . Esta diferença é chamada sinal de detalhe na resolução 2^ℓ . As aproximações nas resoluções $2^{\ell+1}$ e 2^ℓ de um sinal são iguais às suas projeções ortogonais em $V_{2^{\ell+1}}$ e V_{2^ℓ} respectivamente. (MALLAT et al., 2009)

Para todo $\ell \in \mathbb{Z}$, W_{2^ℓ} é definido como o complemento ortogonal de V_{2^ℓ} em $V_{2^{\ell+1}}$, ou seja,


$$V_{2^{\ell+1}} = V_{2^\ell} \oplus W_{2^\ell}. \quad (12)$$

Do ponto de vista de processamento de sinais, uma *wavelet* é um filtro passa-banda (VETTERLI; KOVACEVIC, 1995), e no espaço W_{2^j} inclui os detalhes do sinal na escala 2^j , que pode ser obtido utilizando este filtro.

3.3.1 Banco de Filtros

A transformada *wavelet* diádica ortogonal pode ser implementada por meio da análise multirresolução a partir de um banco de filtros de dois canais, passa-baixa ($\tilde{H}$) e passa-alta ($\tilde{G}$). Um banco de filtros é um conjunto de filtros que podem estar conectados por operadores de amostragem, como decimadores (*downsampling*) e interpoladores (*upsampling*). A Figura 1 ilustra o processo de decomposição em três níveis de resolução via transformada *wavelet* rápida (TWR).


Figura 1 – Processo de decomposicao da TWR.



Fonte: Adaptado de Strang e Nguyen (1996)

O sinal de entrada $x[\eta]$ é processado pelo filtro passa-baixa para obter seus componentes de baixa frequência, e também pelo filtro passa-alta para obter seus componentes de alta frequência. Essa abordagem se chama de codificação de sub-banda (STRANG; NGUYEN, 1996). Em seguida os sinais de baixa e alta frequência formam um conjunto da representação do sinal original com o dobro de amostras. Para reduzir o número de amostras ao tamanho original do sinal é necessário descartar metade das amostras de cada um, utilizando o operador *downsampling* ($\downarrow 2$). A saída do banco de análise representa o sinal de entrada do mesmo tamanho do sinal original, em termos de seus componentes de baixa e alta frequência (GOMES; VELHO, 2015).

Para reconstruir o sinal original $x[\eta]$, o operador *upsampling* será utilizado, como ilustrado na Figura 2.

Figura 2 – Processo de reconstrução da TWR.

Fonte: Adaptado de Strang e Nguyen (1996)

No passo de reconstrução, o operador *upsampling* é aplicado aos componentes dos canais passa-baixa e passa-alta e os respectivos sinais passam pelos filtros H e G para que o sinal original seja reconstruído a partir da combinação destes componentes processados. Se os filtros de decomposição $\widetilde{H}$ e $\widetilde{G}$ forem ortogonais então os filtros de reconstrução H e G estão relacionados da seguinte forma:

$$\begin{aligned}\widetilde{H} &= H^* \\ \widetilde{G} &= G^*\end{aligned}\tag{13}$$

em que $*$ denota o complexo conjugado. Caso os filtros de decomposição não sejam ortogonais, os filtros de reconstrução serão diferentes.

O filtro H é chamado de filtro conjugado, e o filtro G é obtido por meio deste. Tais filtros geram a base *wavelet* ortogonal do $L^2(\mathbb{R})$ (MALLAT, 1989).

3.4 FAMÍLIAS WAVELETS

Diversas *wavelets* podem ser utilizadas tanto para TWC quanto para TWD, porém na análise multirresolução é possível apenas o uso de *wavelets* ortogonais ou bi-ortogonais, pois elas possuem filtros e funções escalas associadas. Algumas *wavelets* ortogonais pertencem a famílias específicas, ou seja, que são geradas a partir de uma metodologia em comum.

Nas seções seguintes serão apresentados alguns exemplos de funções *wavelets* e suas funções de escala associadas que serão utilizadas no trabalho.


3.4.1 Haar

A *wavelet* de Haar (HAAR; KÁRMÁN, 1909) é o exemplo mais simples e antigo de uma *wavelet* e é definida conforme a Equação (14) (DAUBECHIES, 1992).

$$\psi(t) = \begin{cases} 1 & \text{se } 0 \leq t < \frac{1}{2} \\ -1 & \text{se } \frac{1}{2} \leq t < 1 \\ 0 & \text{caso contrário} \end{cases} \quad (14)$$

A Figura 3 ilustra as formas de onda da função escala (em azul) e da função *wavelet* (em vermelho) de Haar. Esta função não demonstra suavidade, pois ela é descontínua em certos pontos, e também só possui um momento nulo.

Figura 3 – *Wavelet Haar*.






Fonte: Adaptado de Daubechies (1992).

A *wavelet* de Haar é a única *wavelet* ortogonal simétrica e de suporte compacto possível, pois não se pode obter simetria para *wavelets* ortogonais de suporte compacto, exceto para a Haar. No entanto é possível chegar próximo a uma simetria como são as *wavelets* das famílias Symlets e Coiflets (DAUBECHIES, 1988).

3.4.2 Daubechies

As *wavelets* da família Daubechies foram as primeiras *wavelets* ortogonais de suporte compacto apresentadas formalmente na literatura (DAUBECHIES, 1988). A notação *dbN* significa que uma *wavelet* de Daubechies possui *N* momentos nulos. O valor de *N* também indica que o filtro *wavelet* possui comprimento $2N$.

As Figuras 4, 5 e 6 ilustram as formas de onda da função escala e da função *wavelet* referentes às *wavelets* *db4*, *db10* e *db20* respectivamente.

Figura 4 – *Wavelet db4*.**Fonte:** Adaptado de Daubechies (1992).**Figura 5** – *Wavelet db10*.**Fonte:** Adaptado de Daubechies (1992).**Figura 6** – *Wavelet db20*.**Fonte:** Adaptado de Daubechies (1992).


Ao observar as imagens apresentadas é possível perceber que ao passo que o número de momentos nulos aumenta, a forma de onda da *wavelet* fica mais suave.

3.4.3 Symlets

As *wavelets* da família Symlets podem ser vistas como uma modificação das *wavelets* da família Daubechies, que buscam manter a propriedade simétrica das *wavelets* o mais fiel possível (DAUBECHIES, 1993). A notação *symN* significa que uma *wavelet* da família Symlets possui N momentos nulos, e que seus respectivos filtros *wavelet* possuem comprimento $2N$.


As Figuras 7, 8 e 9 ilustram as formas de onda da função escala e da função *wavelet* *sym4*, *sym10* e *sym20* respectivamente.

Figura 7 – Wavelet *sym4*.




Fonte: Adaptado de Daubechies (1993).

Figura 8 – Wavelet *sym10*.



Fonte: Adaptado de Daubechies (1993).


Figura 9 – *Wavelet sym20*.

Fonte: Adaptado de Daubechies (1992).


3.4.4 Coiflets

As *wavelets* coiflets são geradas a partir de um método que restringe condições de números de momentos nulos para a função escala (DAUBECHIES, 1993). A notação *coifN* denota uma *wavelet* da família Coiflets com $2N$ momentos nulos. Nesse caso, o comprimento dos filtros associado é $6N$.


As Figuras 10, 11 e 12 ilustram as formas de onda da função escala, e da função *wavelet* para *coif1*, *coif2* e *coif5*, respectivamente.

Figura 10 – *Wavelet coif1*.

Fonte: Adaptado de Daubechies (1993).

Figura 11 – Wavelet *coif2*.

Fonte: Adaptado de Daubechies (1993).

Figura 12 – Wavelet *coif5*.

Fonte: Adaptado de Daubechies (1993).

As *wavelets* da família Coiflets, assim como as Symlets, são aproximadamente simétricas.

3.4.5 Meyer

A *wavelet* de Meyer pode ser definida no domínio da frequência (MALLAT et al., 2009):

$$\hat{\psi}(\omega) = \begin{cases} 0 & \text{if } |\omega| \leq \frac{2\pi}{3} \\ 2^{-\frac{1}{2}} G\left(\frac{\omega}{2}\right) & \text{if } \frac{2\pi}{3} \leq |\omega| \leq \frac{4\pi}{3} \\ 2^{-\frac{1}{2}} \exp\left(\frac{-1\omega}{2}\right) H\left(\frac{\omega}{4}\right) & \text{if } \frac{4\pi}{3} \leq |\omega| \leq \frac{8\pi}{3} \\ 0 & \text{if } |\omega| > \frac{8\pi}{3} \end{cases} \quad (15)$$

sendo


$$H(\omega) = \begin{cases} \sqrt{2} & \text{if } \omega \in [-\frac{\pi}{3}, \frac{\pi}{3}] \\ 0 & \text{if } \omega \in [-\pi, -\frac{2\pi}{3}] \cup [\frac{2\pi}{3}, \pi] \end{cases}, \quad (16)$$

e

$$G(\omega) = e^{-j\omega} H^*(\omega + \pi). \quad (17)$$

A Figura 13 ilustra as formas de onda da função escala em azul, e da função *wavelet* em vermelho, das *wavelets* de Meyer (1993). A *wavelet* de Meyer é de fato simétrica, porém não possui suporte compacto. Entretanto, $\psi(t)$ tende a zero quando t tende a $\pm\infty$.

Figura 13 – *Wavelet Meyer*.



Fonte: Adaptado de Daubechies (1992).

A relação entre *wavelets*, análise multiresolução e banco de filtros foi desenvolvida enfatizando a relação entre as ideias fundamentais de cada uma delas, que é a de que funções ou sinais sejam divididos em sinais de componentes em diferentes resoluções. (VETTERLI; HERLEY, 1992)

4 ADAPTIVE-NETWORK-BASED FUZZY INFERENCE SYSTEM

A *Adaptive-Network-Based Fuzzy Inference System* (ANFIS), proposta por Jang (1993), é uma rede neural artificial adaptativa de múltiplas camadas não recorrentes (*feedforward*), em que cada neurônio executa uma função particular nos sinais de entrada e também no conjunto de parâmetros pertencentes a este neurônio. Para representar a diferença entre os neurônios adaptativos e não adaptativos, são utilizados círculos e quadrados. Os círculos se referem aos neurônios não adaptativos e os quadrados se referem aos neurônios adaptativos, e estes possuem parâmetros. O conjunto de parâmetros de uma rede adaptativa é a união dos conjuntos de parâmetros de cada neurônio, que são atualizados de acordo com os dados de treinamento fornecidos e um procedimento de aprendizagem baseado no gradiente descendente com o objetivo de alcançar um mapeamento de entrada-saída desejado (JANG, 1993).

4.1 REDES NEURAIS ADAPTATIVAS

A habilidade que permite que os computadores aprendam por experiências anteriores, por exemplos apresentados e por analogia é conhecida atualmente como aprendizado de máquina. Esta capacidade pode fazer com que a performance de sistemas inteligentes melhore com o tempo. As redes neurais artificiais estão entre as mais populares dentre as técnicas de aprendizagem de máquina (NEGNEVITSKY, 2005).

Uma rede neural artificial é desenvolvida com o objetivo de copiar a forma de aprendizado do cérebro humano, que por sua vez é um sistema de processamento de informação altamente complexo, não linear e paralelo, se adaptar a maneira como o mesmo realiza tarefas específicas e reproduzir de maneira artificial o comportamento dos neurônios ao processarem os estímulos recebidos e transmitidos aos outros neurônios de maneira a estimar uma saída (HAYKIN, 2001).


As redes estruturadas de forma *feedforward* possuem seus neurônios interligados dispostos em camadas, em que as informações inseridas na camada de entrada são propagadas na direção da saída da rede, i.e., os sinais de entrada são apresentados à primeira camada da rede e a saída desta primeira camada será a entrada da segunda camada, e assim por diante, até alcançar a camada de saída (HAYKIN, 2001). A ANFIS é usualmente representada por uma rede neural *feedforward* de cinco camadas.

Um sistema adaptativo caracteriza-se por possuir uma forma de aprendizagem que nunca para. Esta aprendizagem é realizada enquanto o processamento de sinal está sendo executado pelo sistema, i.e., o sistema responde a toda entrada distinta como sendo uma entrada nova. Esta forma de aprendizagem também é conhecida como aprendizagem em tempo real (*on-the-fly*) ou aprendizagem contínua (HAYKIN, 2001). Jang (1997) define

rede adaptativa como uma rede em que o comportamento é determinado por uma coleção de parâmetros modificáveis que relacionam as saídas com as entradas. É composta por conjuntos de neurônios artificiais diretamente conectados e cada neurônio possui uma função estática em seus sinais de entrada para gerar uma saída única transmitida de um neurônio para outro.

Quanto à aprendizagem, a ANFIS deve possuir parâmetros ajustáveis que são atualizados por uma regra de aprendizado supervisionado (JANG, 1997). Na Figura 14 é apresentado um diagrama de blocos que ilustra o funcionamento da aprendizagem supervisionada (HAYKIN, 2001).

Figura 14 – Sistema de aprendizagem supervisionada.



Fonte: Adaptado de Haykin (2001).

O conceito de aprendizado supervisionado também é conhecido por “aprendizado com um professor”, em que esse professor é o bloco que possui conhecimento sobre o ambiente, i.e., banco de dados que será apresentado à rede. Este conhecimento é representado por um conjunto de exemplos de entrada-saída, sendo que a saída é desconhecida pelo sistema de aprendizagem. A resposta desejável a ser alcançada pela rede neural é fornecida pelo professor e então o sinal de erro é definido a partir da diferença entre a saída desejada e a saída calculada pela rede. Por fim, os parâmetros da rede são ajustados iterativamente, combinando o sistema de aprendizagem e o sinal de erro até que a rede alcance um critério de parada, podendo ser este a resposta ótima. Isto significa que a rede está pronta para lidar com o ambiente por si só e não precisa mais do professor.


4.2 SISTEMA DE INFERÊNCIA FUZZY

A ANFIS é um sistema de inferência neuro-fuzzy adaptativo, o que significa que possui a capacidade de adaptação e aprendizagem das redes neurais artificiais descritas na seção 4.1 e o processamento linguístico de um sistema de inferência fuzzy. Um sistema de inferência fuzzy é composto basicamente de três componentes, sendo uma base de regras,

que contém uma seleção de regras *fuzzy*; um banco de dados (ou dicionário), que define as funções de pertinência utilizadas nas regras *fuzzy*; e um mecanismo de raciocínio, que executa o procedimento de inferência mediante as regras para obter um resultado razoável (JANG, 1997).

Em um sistema de inferência *fuzzy* básico, é possível ter tanto entrada *fuzzy* como entrada real, i.e, escalar, que pertencem ou não a determinado conjunto, este é visto como uma “entrada *fuzzy* única”, já as saídas que o sistema produz serão conjuntos *fuzzy*. Assim sendo, é necessário um método de defuzzificação para extrair os valores reais que melhor representam o conjunto *fuzzy* (JANG, 1997).

A Figura 15 ilustra um sistema de inferência *fuzzy* com saída real, em que a linha pontilhada indica um sistema de inferência *fuzzy* básico, e o bloco de defuzzificação serve ao propósito de transformar uma saída *fuzzy* em um valor real.



Fonte: Adaptado de Kosko (1992).

Na arquitetura híbrida da ANFIS, o sistema de inferência *fuzzy* é baseado no modelo T-S (TAKAGI; SUGENO, 1985) para construir o mapeamento de entrada e saída, em que os parâmetros do consequente da regra são calculados via LSE, e a aprendizagem da rede é baseada no algoritmo *backpropagation* (JANG, 1993).

Neste modelo, as regras são definidas com base nos antecedentes (SE) e consequentes (ENTÃO) por meio da combinação linear ponderada das entradas, as equações (18) e (19) apresentam as regras para um sistema ANFIS com duas entradas (x_1 e x_2) e uma saída y (TAKAGI; SUGENO, 1985).

$$\text{Regra 1: SE } x_1 \text{ é } P_1 \text{ E } x_2 \text{ é } Q_1, \text{ ENTÃO } y_1 = p_1 x_1 + q_1 x_2 + r_1 \quad (18)$$


$$\text{Regra 2: SE } x_2 \text{ é } P_2 \text{ E } x_2 \text{ é } Q_2, \text{ ENTÃO } y_1 = p_2x_1 + q_2x_2 + r_2 \quad (19)$$

As regras SE-ENTÃO *fuzzy* são utilizadas frequentemente com intuito de capturar a forma imprecisa de raciocínio como os seres humanos desempenham ao tomar decisões em ambientes imprevisíveis. A ANFIS pode servir como base para a construção de um conjunto de regras com funções de pertinência apropriadas para gerar pares de entrada e saída precisos (JANG, 1993).

4.3 ARQUITETURA DA ANFIS

A arquitetura da ANFIS é similar a uma perceptron de múltiplas camadas. É formada basicamente por neurônios dispostos em cinco camadas interligadas por pesos unitários e cada camada é responsável por uma operação que resultará em uma saída que será propagada até a última camada. Então será verificado se o critério de parada foi satisfeito, para dar continuidade ao treinamento. A Figura 16 ilustra a arquitetura da rede ANFIS.

Figura 16 – Estrutura da ANFIS.



Fonte: Adaptado de Negnevitsky (2005).

Cada uma de suas camadas possui um processo específico (JANG, 1993):

Camada 1: Os parâmetros desta camada se referem aos parâmetros da premissa das regras. Cada neurônio dessa camada é representado por um quadrado com a função de neurônio dada pelas equações (20) para a entrada x_1 e (21) para a entrada x_2 .

$$O_i^{11} = \mu A_i(x_1), \quad i = 1, 2, \quad (20)$$

$$O_i^{12} = \mu B_i(x_2), \quad i = 1, 2, \quad (21)$$

sendo,

x_1, x_2 : são as entradas da rede;

A_i, B_i : representam as variáveis linguísticas associadas à função do respectivo neurônio i ;

O_i^{11}, O_i^{12} : representam as funções de pertinência das entradas.

As funções de pertinência especificam com que grau x_1 pertence a A_i e x_2 pertence a B_i . No modelo de Jang (1993) as funções de pertinência são descritas por uma função do tipo sino, no entanto, em um sistema *fuzzy* é possível utilizar outras funções de pertinência, como a gaussiana, trapezoidal e triangular (MENDEL, 1995; JANG, 1997; KASABOV, 1998; RIBACIONKA, 1999; NEGNEVITSKY, 2005).

A função tipo sino para as entradas x_1 e x_2 é calculada conforme as Equações (22) e (23).

$$\mu A_i(x_1) = \exp \left\{ - \left[\left(\frac{x_1 - c_i}{a_i} \right)^2 \right]^{b_i} \right\}, \quad (22)$$

$$\mu B_i(x_2) = \exp \left\{ - \left[\left(\frac{x_2 - c_i}{a_i} \right)^2 \right]^{b_i} \right\}, \quad (23)$$

sendo,


a : o centro da curva da função de pertinência do tipo sino;

b : a largura da curva da função de pertinência do tipo sino;

c : a inclinação da curva da função de pertinência do tipo sino;

$\{a_i, b_i, c_i\}$: o conjunto de parâmetros dos antecedentes da regra.

Caso os parâmetros do antecedente sejam alterados, as funções de pertinência podem variar de acordo com a alteração feita. A Figura 17 representa graficamente como os parâmetros da função de pertinência podem influenciar a aparência da curva.

Figura 17 – Variação dos parâmetros $\{a_i, b_i, c_i\}$.**Fonte:** Elaborado pela autora.

Camada 2: Cada neurônio dessa camada é não adaptativo e é representado por um círculo rotulado com Π , tem como saída o produto dos seus sinais de entrada, que pode ser chamada de peso da regra (*firing strength*), dada pela Equação (24).

$$O_i^2 = w_i = \mu A_i(x_1) \times \mu B_i(x_2), i = 1, 2, \quad (24)$$

sendo,

w_i : as regras *fuzzy* do tipo T-S;

O_i^2 : a saída da camada 2.

Para a Figura 16, as regras da camada 2 são representadas pelas Equações (25), (26), (27) e (28).

$$w_1: \text{SE } x_1 \text{ é } A_1 \text{ E } x_2 \text{ é } B_1, \text{ ENTÃO } y_1 = p_1x_1 + q_1x_2 + r_1, \quad (25)$$

$$w_2: \text{SE } x_1 \text{ é } A_1 \text{ E } x_2 \text{ é } B_2, \text{ ENTÃO } y_2 = p_2x_1 + q_2x_2 + r_2, \quad (26)$$

$$w_3: \text{SE } x_1 \text{ é } A_2 \text{ E } x_2 \text{ é } B_1, \text{ ENTÃO } y_3 = p_3x_1 + q_3x_2 + r_3, \quad (27)$$

$$w_4: \text{SE } x_1 \text{ é } A_2 \text{ E } x_2 \text{ é } B_2, \text{ ENTÃO } y_4 = p_4x_1 + q_4x_2 + r_4, \quad (28)$$

Camada 3: Os neurônios desta camada também são não adaptativos, rotulados com a letra N . O i -ésimo neurônio calcula a relação do peso da regra do neurônio i com a soma dos pesos de todas as outras regras, i.e., o peso normalizado de cada regra, dado pela Equação (29).

$$O_i^3 = \overline{w_i} = \frac{w_i}{w_1 + w_2 + w_3 + w_4}, \quad (29)$$

sendo,

$\overline{w}_i$: o valor da normalização das regras;

O_i^3 : a saída da camada 3.

Camada 4: Esta é uma camada adaptativa, os neurônios são representados por um quadrado e possuem uma função, calculada conforme a Equação (30).

$$O_i^4 = \overline{w}_i y_i = \overline{w}_i (p_i x_1 + q_i x_2 + r_i), \quad (30)$$

sendo,

$\{p_i, q_i, r_i\}$: o conjunto de parâmetros do consequente da regra i ;


O_i^4 : representa a saída da camada 4.

Cada neurônio desta camada é conectado ao seu respectivo neurônio normalizado pela camada anterior e recebem os valores das entradas x_1 e x_2 .

Camada 5: O único neurônio que compõe essa camada é um neurônio não adaptativo representado por um círculo rotulado com $\sum$, que calcula a soma de todos os sinais de entrada gerando uma saída global, conforme a Equação (31).

$$O_i^5 = \sum_{i=1}^n \overline{w}_i y_i = \sum_{i=1}^n \overline{w}_i (p_i x_1 + q_i x_2 + r_i). \quad (31)$$

Como a saída global da ANFIS pode ser expressa como a combinação linear dos parâmetros dos consequentes das regras, na Figura 18 é possível observar um raciocínio equivalente para uma rede que possui duas entradas e duas regras (JANG, 1993).

Figura 18 – Raciocínio *fuzzy* para a ANFIS com duas entradas e duas regras.

Fonte: Adaptado de Jang (1993).

A Equação (32) apresenta a saída y , que representa a saída geral do sistema, reescrita de forma mais precisa.

$$\begin{aligned}
 y &= \frac{w_1}{w_1 + w_2}y_1 + \frac{w_2}{w_1 + w_2}y_2 \\
 &= \bar{w}_1y_1 + \bar{w}_2y_2 \\
 &= \bar{w}_1(p_1x_1 + q_1x_2 + r_1) + \bar{w}_2(p_2x_1 + q_2x_2 + r_2).
 \end{aligned} \tag{32}$$

Deste modo é construída uma rede neural adaptativa e funcionalmente equivalente a um sistema de inferência *fuzzy* do tipo Takagi-Sugeno e seus parâmetros antecedentes podem ser atualizados de acordo com o procedimento do gradiente descendente. No entanto, muitas vezes é difícil ou mesmo impossível especificar o consequente de uma regra em um polinômio. Convenientemente, não é necessário ter nenhum conhecimento prévio dos parâmetros consequentes das regras para que a ANFIS lide com um problema, pois a rede aprende estes parâmetros e ajusta as funções de associação (NEGNEVITSKY, 2005).

4.4 APRENDIZAGEM DA ANFIS

Para o treinamento, a ANFIS faz uso de um algoritmo de aprendizagem híbrido, é composto pelo LSE (*least-squares estimator*) e o algoritmo *backpropagation* que é baseado no gradiente descendente. Neste treinamento, cada época é composta de duas fases, i.e., *forward* e *backward*, sintetizadas na Tabela 1 (JANG, 1993).

Tabela 1 – Duas fases do algoritmo de aprendizagem híbrido da ANFIS

	Antecedente	Consequente	Sinais propagados
Fase <i>forward</i>	Parâmetros fixos	LSE	Saídas dos neurônios
Fase <i>backward</i>	<i>backpropagation</i>	Parâmetros fixos	Sinais de erro

Fonte: Adaptado de Jang (1993).

Na fase *forward*, um conjunto de treinamento dos padrões de entrada é apresentado à rede, as saídas dos neurônios são calculadas, camada por camada e os parâmetros consequentes das regras são calculados pelo LSE, enquanto os parâmetros do antecedente são mantidos fixos (JANG, 1993).

Segundo Negnevitsky (2005), o motivo pelo qual o LSE irá calcular o conjunto de parâmetros do consequente, necessários para o cálculo da saída da *Camada 4*, se dá por ser muito difícil ou até impossível especificar um consequente de regra em forma polinomial.

Portanto, dados os valores dos parâmetros das funções de pertinência e um conjunto de padrões de entrada-saída de treinamento, é possível formar P equações lineares nos termos dos parâmetros dos consequentes (NEGNEVITSKY, 2005), conforme a Equação (33).

$$\left\{ \begin{array}{l} y_d(1) = \overline{w_1}(1)y_1(1) + \overline{w_2}(1)y_2(1) + \dots + \overline{w_n}(1)y_n(1) \\ y_d(2) = \overline{w_1}(2)y_1(2) + \overline{w_2}(2)y_2(2) + \dots + \overline{w_n}(2)y_n(2) \\ \vdots \\ y_d(p) = \overline{w_1}(p)y_1(p) + \overline{w_2}(p)y_2(p) + \dots + \overline{w_n}(p)y_n(p) \\ \vdots \\ y_d(P) = \overline{w_1}(P)y_1(P) + \overline{w_2}(P)y_2(P) + \dots + \overline{w_n}(P)y_n(P) \end{array} \right. , \quad (33)$$

sendo,

$y_d(p)$: a saída desejada para os padrões de entrada $x_1(p), x_2(p), \dots, x_m(p)$;

m : o número de variáveis de entrada;

n : o número de neurônios na camada de regras; e

P : o conjunto de padrões entrada-saída.

Calculando de maneira semelhante ao que foi apresentado na Figura 18, temos o

cálculo dos parâmetros dos consequentes conforme a Equação (34).

$$\left\{ \begin{array}{l} y_d(1) = \overline{w}_1(1)[\lambda_{10} + \lambda_{11}x_1(1) + \lambda_{12}x_2(1) + \cdots + \lambda_{1m}x_m(1)] \\ \quad + \overline{w}_2(1)[\lambda_{20} + \lambda_{21}x_1(1) + \lambda_{22}x_2(1) + \cdots + \lambda_{2m}x_m(1)] \\ \quad + \cdots \\ \quad + \overline{w}_n(1)[\lambda_{n0} + \lambda_{n1}x_1(1) + \lambda_{n2}x_2(1) + \cdots + \lambda_{nm}x_m(1)] \\ y_d(2) = \overline{w}_1(2)[\lambda_{10} + \lambda_{11}x_1(2) + \lambda_{12}x_2(2) + \cdots + \lambda_{1m}x_m(2)] \\ \quad + \overline{w}_2(2)[\lambda_{20} + \lambda_{21}x_1(2) + \lambda_{22}x_2(2) + \cdots + \lambda_{2m}x_m(2)] \\ \quad + \cdots \\ \quad + \overline{w}_n(2)[\lambda_{n0} + \lambda_{n1}x_1(2) + \lambda_{n2}x_2(2) + \cdots + \lambda_{nm}x_m(2)] \\ \quad \vdots \\ y_d(p) = \overline{w}_1(p)[\lambda_{10} + \lambda_{11}x_1(p) + \lambda_{12}x_2(p) + \cdots + \lambda_{1m}x_m(p)] \\ \quad + \overline{w}_2(p)[\lambda_{20} + \lambda_{21}x_1(p) + \lambda_{22}x_2(p) + \cdots + \lambda_{2m}x_m(p)] \\ \quad + \cdots \\ \quad + \overline{w}_n(p)[\lambda_{n0} + \lambda_{n1}x_1(p) + \lambda_{n2}x_2(p) + \cdots + \lambda_{nm}x_m(p)] \\ \quad \vdots \\ y_d(P) = \overline{w}_1(P)[\lambda_{10} + \lambda_{11}x_1(P) + \lambda_{12}x_2(P) + \cdots + \lambda_{1m}x_m(P)] \\ \quad + \overline{w}_2(P)[\lambda_{20} + \lambda_{21}x_1(P) + \lambda_{22}x_2(P) + \cdots + \lambda_{2m}x_m(P)] \\ \quad + \cdots \\ \quad + \overline{w}_n(P)[\lambda_{n0} + \lambda_{n1}x_1(P) + \lambda_{n2}x_2(P) + \cdots + \lambda_{nm}x_m(P)] \end{array} \right. \quad (34)$$

Em notação matricial, temos a Equação (35).

$$y_d = A\lambda, \quad (35)$$

sendo,

y_d : o vetor de saída desejada de dimensão $P \times 1$,

$$y_d = \begin{bmatrix} y_d(1) \\ y_d(2) \\ \vdots \\ y_d(p) \\ \vdots \\ y_d(P) \end{bmatrix}, \quad (36)$$

A : uma matriz de dimensão $P \times n(1 + m)$,

$$A = \begin{bmatrix} \overline{w_1}(1) & \overline{w_1}(1)x_1(1) & \cdots & \overline{w_1}(1)x_m(1) & \cdots & \overline{w_n}(1) & \overline{w_n}(1)x_1(1) & \cdots & \overline{w_n}(1)x_m(1) \\ \overline{w_1}(2) & \overline{w_1}(2)x_1(2) & \cdots & \overline{w_1}(2)x_m(2) & \cdots & \overline{w_n}(1) & \overline{w_n}(2)x_1(2) & \cdots & \overline{w_n}(2)x_m(2) \\ \vdots & \vdots & \cdots & \vdots & \cdots & \vdots & \vdots & \cdots & \vdots \\ \overline{w_1}(p) & \overline{w_1}(p)x_1(p) & \cdots & \overline{w_1}(p)x_m(p) & \cdots & \overline{w_n}(1) & \overline{w_n}(p)x_1(p) & \cdots & \overline{w_n}(p)x_m(p) \\ \vdots & \vdots & \cdots & \vdots & \cdots & \vdots & \vdots & \cdots & \vdots \\ \overline{w_1}(P) & \overline{w_1}(P)x_1(P) & \cdots & \overline{w_1}(P)x_m(P) & \cdots & \overline{w_n}(1) & \overline{w_n}(P)x_1(P) & \cdots & \overline{w_n}(P)x_m(P) \end{bmatrix}, \quad (37)$$

e,

λ : um vetor dos parâmetros do consequente (desconhecido) de dimensão $n(1 + m) \times 1$,

$$\lambda = \begin{bmatrix} \lambda_{10}\lambda_{11}\lambda_{12} & \cdots & \lambda_{1m}\lambda_{20}\lambda_{21}\lambda_{22} & \cdots & \lambda_{2m} & \cdots & \lambda_{n0}\lambda_{n1}\lambda_{n2} & \cdots & \lambda_{nm} \end{bmatrix}^T. \quad (38)$$

O número P de padrões de entrada-saída usados no treinamento é maior que o número $n(1 + m)$ de parâmetros do consequente. Isto quer dizer que a solução exata para a Equação (35) pode não existir (NEGNEVITSKY, 2005). Por isso é necessário encontrar a solução de mínimos quadrados, que é o vetor de menor norma euclidiana que minimiza $\|A\lambda - y_d\|^2$ (LIPSCHUTZ; LIPSON, 2009). Este vetor λ^* é calculado conforme a Equação (39).

$$\lambda^* = (A^T A)^{-1} A^T y_d \quad (39)$$

sendo,

A^T : a transposta de A ; e

$(A^T A)^{-1} A^T$: a pseudoinversa de A ou inversa de Moore-Penrose se $(A^T A)$ é não-singular (LIPSCHUTZ; LIPSON, 2009).

Assim que os parâmetros dos consequentes das regras são calculados é possível calcular a saída y , que é a saída calculada pela *Camada 5* e então calcular o vetor ϵ , que é o vetor de erro obtido conforme a Equação (40), para assim dar início à fase *backward*.

$$\epsilon = y_d - y. \quad (40)$$

Na fase *backward*, o algoritmo *backpropagation* (WERBOS, 1974) propaga os sinais do erro para as camadas anteriores até alcançar a primeira camada, e ajusta os parâmetros do antecedente de acordo com a regra da cadeia. Nesta fase, os parâmetros do consequente, calculados anteriormente, permanecem fixos (JANG, 1993).

Os parâmetros do antecedente das regras serão calculados de acordo com a regra da cadeia (NEGNEVITSKY, 2005). Para realizar o ajuste do parâmetro a da função de ativação tipo sino utilizada no neurônio $A1$, deve-se calcular como na Equação (41).

$$\Delta a = -\alpha \frac{\partial E}{\partial a} = -\alpha \frac{\partial E}{\partial \epsilon} \times \frac{\partial \epsilon}{\partial y} \times \frac{\partial y}{\partial (\bar{w}_i y_i)} \times \frac{\partial (\bar{w}_i y_i)}{\partial \bar{w}_i} \times \frac{\partial \bar{w}_i}{\partial w_i} \times \frac{\partial w_i}{\partial w_{A1}} \times \frac{\partial w_{A1}}{\partial a}, \quad (41)$$

sendo,

α : a taxa de aprendizagem e E representa o valor do erro quadrático instantâneo do neurônio de saída da rede, calculado conforme a Equação (42).

$$E = \frac{1}{2} \epsilon^2 = \frac{1}{2} (y_d - y)^2, \quad (42)$$

então,

$$\Delta a = -\alpha (y_d - y) (-1) y_i \times \frac{\bar{w}_i (1 - \bar{w}_i)}{w_i} \times \frac{w_i}{w_{A1}} \times \frac{\partial w_{A1}}{\partial a}, \quad (43)$$

sendo,

$$\begin{aligned} \frac{\partial w_{A1}}{\partial a} &= -\frac{1}{\left[1 + \left(\frac{x_1 - a}{c}\right)^{2b}\right]^2} \times \frac{1}{c^{2b}} \times 2b \times (x_1 - a)^{2b-1} \times (-1) \\ &= w_{A1}^2 \times \frac{2b}{c} \times \left(\frac{x_1 - a}{c}\right)^{2b-1}. \end{aligned} \quad (44)$$

O mesmo deverá ser feito de forma similar para ajustar os outros parâmetros da função sino.

Concluindo esta etapa, ambos os parâmetros do antecedente e do consequente são otimizados. Em alguns casos, quando o conjunto de dados de entrada e saída são relativamente pequenos, as funções de pertinência podem ser descritas por especialistas humanos. Nestas situações específicas os valores das funções de pertinência são mantidos fixos ao longo do processo de treinamento e apenas os parâmetros dos consequentes são ajustados (JANG, 1997).

Já em sistemas maiores, o processo de criação de funções de pertinência é complexo. Sendo assim, o procedimento de aprendizagem da ANFIS permite o ajuste dos parâmetros de entrada e saída, funções de pertinência e polinômios, modificando as características destas funções e alcançando resultados mais precisos (NEGNEVITSKY, 2005).


5 CENÁRIO DE ESTUDOS

Os dados utilizados no presente trabalho são dados reais de consumo de energia elétrica de uma microrrede inteligente, provenientes de um complexo de prédios de um polo científico tecnológico brasileiro, o qual possui uma área de 50 mil metros quadrados. Neste se encontram diversas entidades públicas e privadas, e.g., empresas da área de tecnologia e instituições de ensino. A região está localizada a 180 metros acima do nível do mar com um clima subtropical temperado super úmido.


O local é um centro de ensino e pesquisa em educação, ciência e tecnologia criado há quase duas décadas por uma empresa brasileira, onde, nas décadas de 1970–1980 foram ocupados por operários que construíram uma usina hidrelétrica. Este foi construído com o objetivo de estimular o progresso das regiões das adjacências da usina e atender às necessidades de modernização das instalações da usina. Atualmente, neste complexo de prédios, é trabalhada a educação nos níveis essenciais para o desenvolvimento social da população, desde a alfabetização até pós-graduação e capacitação tecnológica, lá se encontram ativas por volta de 2 mil pessoas, contando com funcionários, pesquisadores, professores, empresários, entre outros. Somando todos os blocos a área total é de 50 mil metros quadrados.

Para a aquisição do consumo de energia foram instalados *smart meters* em cada um dos blocos, sendo os dados coletados e armazenados em um servidor por meio de uma rede dedicada de par trançado blindado (*shielded twisted pair*). O bloco utilizado neste estudo foi desagregado de seu conjunto e as medições do consumo de energia elétrica foram realizadas em intervalos de 15 minutos, que somam um total de noventa e seis registros diários. Além disso, foram coletadas informações de data, hora e temperatura externa no mesmo intervalo de tempo. O bloco estudado abrange uma área climatizada de $1200m^2$ com um restaurante, uma agência bancária, uma agência dos correios e uma cafeteria. Os dados históricos considerados para o estudo são referentes ao período de 21 de dezembro de 2012 a 19 de março de 2013.

A Figura 19 ilustra graficamente o consumo de energia de uma semana, do dia 10 de março de 2013, que é um domingo, a 16 de março de 2013, que é um sábado. Ao analisar o gráfico é possível observar que o consumo de energia elétrica cai consideravelmente nos finais de semana, pois são os dias menos movimentados no bloco.

Figura 19 – Curva de consumo de energia semanal.

A Figura 20 apresenta curvas de consumo de energia aferidas durante os feriados prolongados de final de ano.

Figura 20 – Curva de consumo de energia com dias atípicos.

De acordo com a curva de consumo apresentada é possível identificar a existência de dias atípicos, e.g., feriados. Neste caso foram selecionados como exemplos os feriados de Natal e Ano Novo. As curvas apresentadas são referentes aos dias 21 de dezembro de 2012, que é uma sexta-feira, a 04 de janeiro de 2013, que é uma sexta-feira.

É possível observar também que a diferença no consumo de energia não atinge apenas os dias em que os feriados acontecem, mas os dias anteriores e posteriores também podem ser influenciados, o que causou a diminuição do consumo de energia elétrica nos dias observados. Ainda porque estes feriados aconteceram em finais de semana, o que pode caracterizá-los como feriados prolongados, e tendo como consequência uma quantidade maior de dias consecutivos com consumo reduzido.


Os dias atípicos não podem ser confundidos com *outliers*, pois estes podem ser justificados a partir da ocorrência de eventos ou fenômenos que causam mudanças bruscas nas rotinas. Estes são identificados por sua discrepância com a maior parcela dos dados históricos (MÜLLER, 2018). Por exemplo a pandemia de COVID-19, a qual atingiu o mundo todo em 2020, fez com que a rotina da maioria das pessoas fosse alterada bruscamente, exigindo que elas circulem menos nas ruas por tempo indeterminado. Em consequência disso, previsões de consumo de energia para este período dificilmente alcançariam resultados satisfatórios.

6 MODELO PROPOSTO

Considerando os dados obtidos a partir dos *smart meters* inseridos no cenário descrito no Capítulo 5, foi realizada uma série de procedimentos até ser possível realizar a previsão de consumo de energia elétrica de curto prazo, que é o objetivo do presente trabalho. Os dias selecionados estão compreendidos entre 21 de dezembro de 2012 e 19 de março de 2013 e somam um total de 89 dias, os quais apresentam uma quantidade menos significativa de dados faltantes.

A Figura 21 apresenta um diagrama de blocos da sequência dos procedimentos realizados ao longo do trabalho, desde a coleta dos dados até o resultado das previsões.

Figura 21 – Diagrama de blocos do modelo proposto.



Fonte: Elaborado pela autora.

O modelo proposto consiste primeiramente na separação do banco de dados, dividido em variáveis externas, i.e., hora, dia da semana e estação do ano, e dados de consumo de energia.

Foi necessária a realização de um pré-processamento dos dados de consumo de energia, pois haviam dados faltantes, *outliers* e amostras irregulares no banco de dados original. Foi feita uma avaliação detalhada dos dados de consumo de energia, dia por dia, e a seleção dos dias que estão com as informações mais completas para serem utilizados no modelo e a exclusão dos demais.

O passo seguinte é a aplicação da TWR, que se fez necessária pelo fato do comportamento da carga neste cenário ser diretamente influenciado por ações humanas causando picos ou ausência de consumo em momentos muitas vezes de difícil previsibilidade. Dito isto, objetivo da aplicação da TWR é suavizar as curvas de consumo fazendo com que os picos presentes na curva, causados por atividades humanas imprevisíveis, fiquem mais suaves, sem perder a característica da curva, para que assim os dados fiquem mais compreensíveis para o treinamento via redes neurais artificiais. Para isso, os dados serão decompostos em diferentes níveis de resolução pela TWR e, dessa forma, apenas os sinais de aproximação serão utilizados para a representação dos mesmos, i.e., os sinais de detalhes assumirão valores nulos no processo de reconstrução.

Conforme visto na Figura 1, a TWR decompõe um sinal $x[\eta]$ em coeficientes de aproximação e detalhe. Os coeficientes de aproximação $cA_\ell[\eta]$ e os coeficientes de detalhe $cD_\ell[\eta]$ no nível ℓ podem ser obtidos pelos coeficientes de aproximação no nível $\ell - 1$.

$$cA_\ell[\eta] = \sum_{k=-\infty}^{+\infty} h[k - 2\eta]cA_{\ell-1}[\eta], \quad (45)$$

$$cD_\ell[\eta] = \sum_{k=-\infty}^{+\infty} g[k - 2\eta]cA_{\ell-1}[\eta], \quad (46)$$

sendo h e g as respostas impulsivas dos filtros H e G respectivamente. Nesse caso, o sinal de decomposição $x[\eta]$, que nesse trabalho é o sinal que representa o consumo de carga, pode ser denotado como $cA_0[\eta]$. No processo de reconstrução, têm-se (MALLAT et al., 2009):

$$cA_{\ell-1}[\eta] = \sum_{k=-\infty}^{+\infty} h[k - 2\eta]cA_{\ell-1}[\eta] + \sum_{k=-\infty}^{+\infty} g[k - 2\eta]cD_{\ell-1}[\eta]. \quad (47)$$

O método proposto nesse trabalho, zera os sinais de detalhes para se obter uma representação mais suave do sinal. Dessa forma, fazendo $cD_\ell[\eta] = 0$, obtemos a seguinte

expressão dos sinais utilizados para a previsão de carga:

$$X_{A\ell}[\eta] = \sum_{k=-\infty}^{+\infty} h[\eta - 2k]cA_{\ell}[\eta], \quad (48)$$

O processo de reconstrução garante que o sinal $X_{A\ell}[\eta]$ tenha o mesmo comprimento que o sinal original $x[\eta]$. Assim, são evitados efeitos de borda ou de fase que uma simples filtragem pode apresentar. Uma vez que $\{\phi_{\ell,\eta}\}_{\eta \in \mathbb{Z}}$ é uma base ortogonal de W_{ℓ} , a projeção neste espaço é caracterizada pelos coeficientes de detalhe $cD_{\ell}[\eta]$. Assim, a eficiência do método proposto depende de como a base wavelet irá representar as transições bruscas.

Neste passo as variáveis externas são reintegradas ao banco de dados, formando dois tipos de entrada para o treinamento da rede, i.e., um conjunto de dados em que o de consumo de energia não foi submetido à análise e a representação da AMR. Cada uma destas entradas são organizadas em es.

O vetor de entrada a é definido na Equação (49).

$$a = [t \ s \ d \ l(t)], \quad (49)$$

sendo,

t : a codificação do horário das medições que foram feitas de 15 em 15 minutos, resultando em 96 dados por dia, em que 1 corresponde a 00:00h, e 96 se refere a 23:45h;

s : informativo da estação do ano com números de 1 a 4 representando cada uma das estações (1 = primavera, 2 = verão, 3 = outono e 4 = inverno);

d : codificação do dia da semana, contando de domingo à sábado, sendo 1 equivalente a domingo e 7 referente a sábado;

$l(t)$: informação de consumo de energia referente ao instante t .

Este vetor de entrada a se refere à entrada da rede, ou seja, o vetor a será apresentado à ANFIS para que esta realize o treinamento e teste, com o objetivo de prever o consumo de energia. Como a ANFIS é uma rede supervisionada, é necessário um vetor alvo, este é representado pelo vetor b , que é definido na Equação (50).

$$b = [l(t + 1)], \quad (50)$$

sendo,

$l(t + 1)$: informação de consumo de energia referente ao instante $t + 1$, que se refere ao consumo medido 15 minutos após a medição no instante t .

Em seguida os dados são separados em dados de treinamento e de teste, sendo 70% para treinamento e 30% para teste, para assim serem inseridos na rede, que por sua

vez nos apresenta o resultado da previsão de um dia a frente para cada dia da semana.

6.1 CRITÉRIO PARA AVALIAÇÃO DA PREVISÃO

Estes resultados são avaliados por meio do cálculo da métrica mais comum encontrada na literatura que verifica a precisão da previsão, i.e., o MAPE (*mean absolute percentage error*), que é calculado conforme a Equação (51) (PARK et al., 1991):

$$\text{MAPE} = \frac{1}{N} \sum_{n=1}^N \left| \frac{y_{real}(n) - y_{previsto}(n)}{y_{real}(n)} \right| \times 100, \quad (51)$$

sendo,

n : número de amostragens da série temporal;

y_{real} : valor do consumo real obtido pelo medidor;

$y_{previsto}$: valor previsto pela ANFIS.

7 RESULTADOS E DISCUSSÕES

Todas simulações e testes foram realizadas em um PC Core i7-4770 3.40 GHz com 8.00 GB RAM e com o software MATLAB®.

Neste trabalho foram avaliados sinais provenientes de uma série temporal que representa o consumo de energia elétrica de um estabelecimento específico. Primeiramente, foram feitas previsões do consumo de energia com diferentes configurações que a arquitetura da ANFIS permite e, em seguida os dados foram submetidos a remoção de ruídos via TWR. Após selecionar a melhor configuração para a rede, os resultados foram comparados por meio do cálculo do MAPE e apresentados em tabelas e gráficos comparativos.

7.1 SIMULAÇÕES E TESTES

Como discutido no Capítulo 4, a arquitetura ANFIS permite o uso de diferentes funções de pertinência, como a função triangular, trapezoidal, gaussiana e a função tipo sino, que é utilizada no presente trabalho.

Nos testes realizados, além de treinar a rede com as diferentes funções de pertinência, foi alterada a quantidade das mesmas no sistema, resultando em diferentes números de regras e funções lineares a serem calculadas. O que modifica o tempo necessário para o treinamento da ANFIS, que passou de 30 segundos para 12 minutos quando o número de funções de pertinência passou de 2 para 3. Isto se deve ao fato de o número de regras ter passado de 16 para 81 e o número de funções lineares de 80 para 405, respectivamente. Na Tabela 2 estão descritos os resultados das previsões feitas com as diferentes funções de pertinência.

Tabela 2 – Resultado da previsão com diferentes funções de pertinência.


Métrica	MAPE (%)							
	Sino		Gaussiana		Trapezoidal		Triangular	
Tipo	2	3	2	3	2	3	2	3
MFs								
Domingo	3,3391	12,029	10,9419	12,2307	8,4187	13,1023	26,8034	107,2617
Segunda-feira	7,7228	15,3629	9,3158	16,0054	7,8563	12,8918	10,3568	21,0697
Terça-feira	5,6800	10,6231	7,9135	10,4240	6,2782	11,2776	9,4831	9,4105
Quarta-feira	8,0994	8,8366	6,8054	9,0610	6,7351	7,7427	7,5420	12,4096
Quinta-feira	11,0739	13,0554	12,2177	12,0317	8,6634	14,1955	13,0856	33,6507
Sexta-feira	6,6879	13,5324	7,1999	14,6919	7,2576	11,9181	9,3096	10,5671
Sábado	4,4359	15,1589	9,4883	13,4291	9,8848	15,6036	21,5062	17,9987
Todos os dias	6,7199	12,6569	9,1261	12,5534	7,8706	12,3902	14,0124	30,3383

Fonte: Elaborado pela autora.

De acordo com os valores obtidos por meio do cálculo do MAPE, é possível verificar na Tabela 2 que a configuração da ANFIS com duas funções de pertinência do tipo sino é a mais adequada para ser utilizada neste tipo de problema, pois obteve os melhores resultados em cinco dos sete dias da semana previstos, não se destacando apenas na terça e quinta-feira, em que o sistema obteve melhor resultado com a função trapezoidal. A função sino obteve também melhor resultado no cálculo realizado para a previsão de todos os dias em conjunto.

A Figura 22 ilustra graficamente a performance da ANFIS configurada com duas funções de pertinência na previsão de todos os dias da semana.


Figura 22 – Previsões da ANFIS com duas funções de pertinência.



Fonte: Elaborado pela autora.

É possível observar que a performance da ANFIS com a função triangular foi inferior ao ser comparada as outras, principalmente nos finais de semana, em que a previsão atingiu picos ainda mais altos do que nos dias de semana. Com esta função de pertinência o sistema não é capaz de distinguir os dias da semana de maior consumo de energia, finais de semanas e dias atípicos o que é perceptível no início da manhã de quinta-feira, no sábado, no domingo e na segunda-feira. Enquanto com as outras funções de pertinência a ANFIS faz esta distinção de modo correto, consegue acompanhar a curva de consumo e não apresenta nenhum valor exorbitante.

Na Figura 23 é apresentada a performance da ANFIS configurada com três funções de pertinência na previsão de todos os dias da semana.

Figura 23 – Previsões da ANFIS com três funções de pertinência.

Fonte: Elaborado pela autora.

Neste caso é perceptível que a performance da ANFIS com a função triangular conseguiu acompanhar melhor a curva em alguns dias, porém no domingo atingiu resultados discrepantes, justificando o MAPE altíssimo obtido neste dia, o que torna a utilização desta configuração inviável.

Apesar de as demais funções de pertinência não terem apresentado problemas ao acompanhar a curva de consumo na previsão, a configuração da ANFIS com duas funções de pertinência do tipo sino foi a que, em geral, atingiu os melhores resultados. Por este motivo as outras configurações foram descartadas para as etapas seguintes do trabalho.

7.2 REPRESENTAÇÃO POR MEIO DA ANÁLISE MULTIRRESOLUÇÃO


Os valores aferidos representam registros de 15 em 15 minutos, ou seja, constituem uma sequência de valores discretos obtidos com uma frequência de amostragem equivalente a 4 amostras por hora. Além disso, são evidentes diversas transições bruscas no sinal adquirido em virtude da dinâmica do consumo de energia. Dentro deste contexto, o referido sinal pode ser analisado e representado em outros domínios discretos com o intuito de obter uma representação mais suave dos dados analisados.

Com o propósito de suavizar tais transições, a TWR foi aplicada. Cada sinal foi decomposto em três níveis de resolução e, em seguida, o sinal foi reconstruído desconsiderando os coeficientes de detalhes. Desta forma, componentes de alta frequência que podem representar as transições bruscas do sinal são removidas. Assim, tem-se uma repre-

sentação dos sinais em uma resolução mais baixa, mas com o mesmo número de amostras. Como exemplo foi feita a decomposição dos dados de uma semana qualquer, de domingo a sábado, em três níveis de resolução e suas respectivas reconstruções.


A Figura 24 ilustra o comportamento do sinal de aproximação (vermelho) e do sinal de detalhe (verde) considerando o primeiro nível de resolução e a Figura 25 apresenta o sinal reconstruído após remoção dos componentes de alta frequência do sinal analisado.

Figura 24 – Sinal decomposto via TWR em um nível de decomposição.



Fonte: Elaborado pela autora.

Figura 25 – Sinal reconstruído removendo os componentes de alta frequência da decomposição em nível 1.




Fonte: Elaborado pela autora.

Já a Figura 26 ilustra o comportamento do sinal de aproximação (vermelho) e do sinal de detalhe (verde) considerando dois níveis de resolução e a Figura 27 apresenta


os sinais reconstruídos após a remoção dos componentes de alta frequência dos sinais analisados.

Figura 26 – Sinal decomposto via TWR em dois níveis de decomposição.



Fonte: Elaborado pela autora.


Figura 27 – Sinal reconstruído removendo os componentes de alta frequência da decomposição em nível 2.




Fonte: Elaborado pela autora.

É possível observar que os sinais são levemente suavizados à medida que o nível de decomposição aumenta, diminuindo os picos de consumo e deixando os dias de semana com maior semelhança entre eles, diferindo apenas do comportamento da série nos dias que indicam o final de semana.

A Figura 28 ilustra o sinal decomposto em três níveis de resolução. Nas extremidades, em que as amostras representam o final de semana, quase não há variação aparente da amplitude e o comportamento dos dias de semana se mostram muito semelhantes e também muito suaves, como apresenta a sua forma reconstruída na Figura 29.

Figura 28 – Sinal decomposto via TWR em três níveis de decomposição.

Fonte: Elaborado pela autora.

Figura 29 – Sinal reconstruído removendo os componentes de alta frequência da decomposição em nível 3.

Fonte: Elaborado pela autora.

Nas decomposições apresentadas pelas Figuras 24 a 29 foram empregadas as *wavelets* de Meyer (MEYER, 1985; MEYER, 1990) para demonstração de sinais decompostos e reconstruídos. Entretanto foram testadas neste trabalho diversas *wavelets*, como *Haar*, *db4*, *db10*, *db20*, *sym4*, *sym10*, *sym20*, *coif1*, *coif2*, *coif5* e *Meyer*. Dessa forma, wavelets com diferentes características e momentos nulos serão exploradas, com objetivo de analisar qual delas melhor satisfaz o problema das variações bruscas apresentadas nas curvas de consumo de energia em nível desagregado e, conseqüentemente, obtém resultado da previsão mais aceitável quando apresentadas à rede.

7.3 PREVISÕES

O banco de dados utilizado nesta metodologia é proveniente de medições de consumo de energia realizadas no período compreendido entre 21 de dezembro de 2012 e 19 de março de 2013, totalizando 89 dias, sendo que seis destes dias foram excluídos do banco de dados na etapa de pré-processamento devido a dados faltantes em excesso. Os dados

restantes foram divididos em dados de treinamento e teste, com 70% para o treinamento e 30% para o teste da rede, sendo que a última semana, que compreende os dias 13 a 19 de março de 2013, foi excluída destes dados, para validação do método proposto. O banco de dados de treinamento conta com a quantidade de dados apresentados na Tabela 3, todos com as informações de horário, estação do ano, dia da semana e consumo de energia.

Tabela 3 – Quantidade de amostras utilizadas.

Dias	Treinamento e Teste	Dados
Domingo	11 dias	1056
Segunda-feira	9 dias	864
Terça-feira	8 dias	768
Quarta-feira	13 dias	1248
Quinta-feira	12 dias	1152
Sexta-feira	13 dias	1248
Sábado	10 dias	960
Total	76 dias	7296

Fonte: Elaborado pela autora.

A configuração final que foi selecionada para ser utilizada na ANFIS para as previsões após o pré-processamento está descrita na Tabela 4, e o tempo necessário para treinamento do sistema *wavelet*-ANFIS com a configuração apresentada foi de aproximadamente 20 segundos, o que é muito rápido em comparação ao tempo que a ANFIS levou para treinar os dados brutos.


Tabela 4 – Detalhes da ANFIS.

Número de padrões entradas	4
Número de funções de pertinência	2
Tipo da função de pertinência	Sino

Fonte: Elaborado pela autora.

Nas Figuras 30 a 34 são apresentados graficamente os resultados obtidos, por meio do cálculo do MAPE, das previsões da ANFIS em sua configuração final antes e após o pré-processamento e aplicação das *wavelets*.


A Figura 30 apresenta o gráfico dos MAPEs obtidos com o treinamento realizado após os dados serem submetidos as *wavelets* da família Daubechies, i.e., *db4*, *db10* e *db20* em três níveis de decomposição.

Figura 30 – MAPEs das *wavelets* da família Daubechies.

Fonte: Elaborado pela autora.

A barra cinza, comum em todos os gráficos, representa o MAPE obtido pela ANFIS treinada com os dados originais da microrrede, i.e., os dados brutos. As barras azuis, verdes e laranjadas, das mais escuras para as mais claras, representam os MAPEs obtidos após a aplicação da *db4*, *db10* e *db20* com níveis de decomposição de 1 a 3 respectivamente.


A Figura 31 apresenta o gráfico dos MAPEs obtidos com o treinamento realizado após os dados serem submetidos as *wavelets* da família Symlets: *sym4*, *sym10* e *sym20* em três níveis de decomposição.

Figura 31 – MAPEs das *wavelets* da família Symlets.

Fonte: Elaborado pela autora.

A Figura 32 apresenta o gráfico dos MAPEs obtidos após os dados serem submetidos as *wavelets* da família Coiflets: *coif1*, *coif2* e *coif5*.

Figura 32 – MAPEs das *wavelets* da família Coiflets.




Fonte: Elaborado pela autora.

As barras azuis, verdes e laranjadas, das mais escuras para as mais claras, representam os MAPEs obtidos após a aplicação da *coif1*, *coif2* e *coif5* com níveis de decomposição de 1 a 3 respectivamente.

A Figura 33 apresenta o gráfico dos MAPEs obtidos com o treinamento realizado após os dados serem submetidos a *wavelet Meyer*.

Figura 33 – MAPEs das *wavelets* de Meyer.




Fonte: Elaborado pela autora.

As barras azuis, das mais escuras para as mais claras, representam os MAPEs obtidos após a aplicação da *wavelet Meyer* com níveis de decomposição de 1 ao 3 respectivamente.

A Figura 34 apresenta o gráfico dos MAPEs obtidos com o treinamento realizado após os dados serem submetidos a *wavelet Haar*.

Figura 34 – MAPEs das *wavelets* de Haar.



Fonte: Elaborado pela autora.

As barras azuis, das mais escuras para as mais claras, representam os MAPEs obtidos após a aplicação da *wavelet Haar* com níveis de decomposição de 1 ao 3 respectivamente.

Analisando a performance da ANFIS com os dados submetidos às diferentes *wavelets* por nível de decomposição, temos:

1. Com um nível de decomposição

- Domingo as *wavelets db4, sym4, coif1, coif2* e *Haar*,
- Segunda e terça-feira, todas as *wavelets*,
- Quarta-feira apenas a *Haar*,
- Quinta-feira nenhuma das *wavelets*,
- Sexta-feira *Haar, db4, db10, db20, sym4, sym10, sym20* e *coif5*,
- Sábado *coif1* e *haar*,

apresentaram MAPE mais elevado do que a ANFIS treinada com os dados brutos;

2. Com dois níveis de decomposição:

- Domingo a *wavelet Haar*,
- Segunda, quarta, quinta e sexta-feira nenhuma das *wavelets*,
- Terça-feira a *wavelet Meyer*,
- Sábado a *wavelet Haar* e *db4*

apresentaram MAPE maior do que a ANFIS treinada com dados brutos;

3. Com três níveis de decomposição:

- Todas as *wavelets*, em todos os dias da semana,

apresentaram MAPE menor do que a ANFIS treinada com dados brutos;

É evidente que conforme os níveis de decomposição aumentam o MAPE diminui. E isto ocorre para todas as *wavelets*, pois ao passo que o número de decomposições aumenta, o sinal fica mais suave, com menos detalhes e isto faz com que a ANFIS compreenda melhor o seu comportamento e alcance resultados mais próximos dos dados que foram apresentados à rede no momento do treinamento.

Os dados numéricos dos MAPEs obtidos para a previsão de cada um dos dias da semana são mostrados detalhadamente na Tabela 5 para as previsões com decomposição em um nível de resolução, na Tabela 6 para as previsões com decomposição em dois níveis de resolução e na Tabela 7 para as previsões com decomposição em três níveis de resolução considerando diferentes *wavelets* na filtragem do banco de dados. Na Tabela 8 são apresentados os MAPEs calculados para todos os dias da semana com os três níveis de decomposição.

Tabela 5 – MAPEs para o sistema *wavelet*–ANFIS com a aplicação de diferentes *wavelets* com decomposição nível 1.

Métrica	MAPE										
<i>Wavelet</i>	Meyer	Haar	db4	db10	db20	sym4	sym10	sym20	coif1	coif2	coif5
Domingo	2,1913	4,9472	3,8365	3,2162	2,5544	3,6565	2,9304	2,4652	4,4000	3,6417	2,8883
Segunda-feira	8,4339	8,8851	9,0317	8,9710	8,0287	9,3069	8,4312	8,9169	9,4434	8,9355	8,3542
Terça-feira	7,1602	7,3690	7,1321	7,2707	7,1437	7,2601	7,1391	7,2466	7,1291	7,2251	7,1282
Quarta-feira	6,9746	8,5295	7,0138	7,4742	7,1288	7,5169	7,1926	7,3994	7,3914	7,3631	7,1085
Quinta-feira	8,4751	9,9555	9,4116	9,4116	8,7335	8,8602	8,2578	8,8902	8,6466	8,8063	8,3313
Sexta-feira	6,8080	6,9415	7,6444	7,5000	7,0479	6,6911	6,8834	7,2223	6,6326	6,7015	6,9151
Sábado	2,9675	6,8070	4,1218	3,5232	3,1755	4,3074	3,4995	3,1736	5,0675	4,2064	3,4603

Fonte: Elaborado pela autora.

Tabela 6 – MAPEs para o sistema *wavelet*–ANFIS com a aplicação de diferentes *wavelets* com decomposição nível 2.

Métrica	MAPE										
<i>Wavelet</i>	Meyer	Haar	db4	db10	db20	sym4	sym10	sym20	coif1	coif2	coif5
Domingo	1,7381	3,8429	2,3182	1,9600	1,7346	2,2311	1,8528	1,8900	2,3972	2,2129	1,9874
Segunda-feira	5,8721	6,0458	5,4570	5,9427	5,5410	5,3856	5,6694	5,9757	5,3460	5,3901	5,7338
Terça-feira	6,8076	5,7824	5,9080	5,3939	6,4550	5,3252	5,8038	5,5336	5,6897	5,7345	5,8997
Quarta-feira	5,7549	6,5678	5,8970	5,9971	6,2830	6,0260	5,9819	5,9175	5,7724	5,7897	5,8106
Quinta-feira	7,1705	7,1751	6,6334	7,4271	7,2907	7,0992	6,6734	7,4559	6,5011	6,6544	7,0563
Sexta-feira	5,5003	5,7776	5,6114	5,1672	6,1504	5,0803	5,8776	4,8940	5,4273	5,4273	5,5780
Sábado	2,6362	6,2093	4,5220	3,3674	3,0613	4,0745	2,7165	2,6274	4,2460	4,3952	3,3986

Fonte: Elaborado pela autora.

Tabela 7 – MAPEs para o sistema *wavelet*–ANFIS com a aplicação de diferentes *wavelets* com decomposição nível 3.

Métrica	MAPE										
<i>Wavelet</i>	Meyer	Haar	db4	db10	db20	sym4	sym10	sym20	coif1	coif2	coif5
Domingo	0,8678	1,5593	1,2655	1,1555	0,9482	0,8419	1,0864	0,9613	1,1613	1,2191	0,8819
Segunda-feira	3,8884	3,1938	3,4410	3,9457	3,6885	3,9268	3,9181	3,7050	3,9509	3,8240	4,2915
Terça-feira	2,7009	3,0590	2,4038	2,6012	2,3409	2,8148	2,3070	2,7056	2,9689	2,4045	2,7716
Quarta-feira	4,5098	5,0997	4,1824	4,5988	4,1794	4,6821	3,7751	4,3455	4,4435	4,3034	4,4347
Quinta-feira	4,9875	5,5476	4,4660	5,4665	4,8501	5,3128	4,4964	4,7736	5,0887	4,8061	4,9817
Sexta-feira	4,7226	3,9447	4,7312	4,8035	4,7496	4,2310	4,5855	4,6351	3,8040	5,2267	4,2890
Sábado	1,9143	3,1495	1,7491	1,8742	1,9806	2,0874	1,9214	1,7189	1,8360	2,1340	2,1770

Fonte: Elaborado pela autora.**Tabela 8** – MAPE para a previsão de todos os dias.

Métrica	MAPE										
<i>Wavelet</i>	Meyer	Haar	db4	db10	db20	sym4	sym10	sym20	coif1	coif2	coif5
Nível 1	5,9056	7,7975	7,2938	6,9455	6,4510	6,7999	6,4781	6,6540	7,1858	6,8921	6,3123
Nível 2	5,2998	5,9924	5,3518	5,2342	5,5189	5,0317	5,0802	5,0799	5,1900	5,2686	5,0663
Nível 3	3,4369	3,7556	3,2440	3,6177	3,3081	3,4138	3,1557	3,3421	3,4381	3,5077	3,4039

Fonte: Elaborado pela autora.

Para um nível de decomposição, a *wavelet* de *Meyer* foi a que obteve melhor resultado com o MAPE de 5,9056%. Outras *wavelets* que obtiveram melhores resultados foram *db20*, *sym10*, *sym20*, e *coif5* com MAPEs menores que 6.66%, uma característica em comum entre essas *wavelets* é que as mesmas possuem um número considerável de momentos nulos, sendo maior ou igual a 10. É considerado na literatura que a *wavelet* de *Meyer* tem número infinito de momentos nulos (MALLAT et al., 2009). Portanto, se for utilizado apenas o primeiro nível de decomposição, *wavelets* com maior número de momentos nulos são mais apropriadas, visto que quanto maior o número de momentos nulos, mais regulares são os respectivos filtros *wavelets*, o que implica em uma filtragem mais seletiva.

Analisando os resultados do segundo nível, pode-se verificar que as *wavelets* que obtiveram melhores resultados, foram: *sym4*, *sym10*, *sym20* e *coif5* com MAPEs < 5,09%. As características comuns entre essas *wavelets* são que as mesmas são aproximadamente simétricas e possuem um número de momentos nulos moderado. A *sym4* foi a *wavelet* que obteve melhor resultado, com MAPE de 5,0317%. Assim, utilizando o segundo nível de decomposição, *wavelets* mais simétricas com um número moderado de momentos nulos são mais apropriadas. Note que a *wavelet* de *Meyer* obteve resultados inferiores as *wavelets* *db10*, *coif1* e *coi2*. Assim, mesmo possuindo simetria, não é interessante utilizar *wavelets* com suporte muito longo no segundo nível. Neste nível, tem-se uma representação bem mais suave do que no primeiro nível. Por isso, não é necessário utilizar *wavelets* com grandes números de momentos nulos para obter bons resultados. Dentre as *wavelets* com os melhores resultados no segundo nível, a *sym4* pode ser a escolha mais eficiente, pois além de ter implicado no melhor resultado, tal *wavelet* possui menor comprimento dos filtros associados.

Em relação aos resultados das *wavelets* no nível três, pode-se dizer que todas foram eficientes, com MAPEs menores que 3.76%, sendo que, a *sym10* obteve o melhor resultado, e a *Haar* o pior resultado. Entretanto, nessa representação, perde-se muita informação do sinal original. Assim, é mais indicado utilizar apenas os dois primeiros níveis de decomposição para a representação dos sinais.

Em geral, a *wavelet* que obteve resultados menos satisfatórios foi a *Haar*, pois ela possui menos momentos nulos e a suavização do sinal acaba sendo de maneira grosseira. Além do mais, note que, utilizando tal *wavelet* tem-se uma representação bem menos apropriada do contexto real.

Para previsões de consumo de energia elétrica de curto prazo em nível desagregado, não existe um consenso em termos do valor ideal do MAPE. Dentre os trabalhos encontrados na literatura, os quais apresentam resultados de previsões de carga a partir de um banco de dados com consumidores de níveis mais desagregados, foram selecionados alguns que permitem a comparação dos resultados, podendo citar Yu, Mirowski e Ho (2016) que


coletaram dados de um medidor doméstico originário de um projeto de análise de dados de *smart grids* em Chattanooga, EUA, em que obtiveram resultados de MAPEs entre 19,79% e 32,55%. Kong et al. (2017a), que obteve MAPEs médios entre 21,99% e 50,20%, utilizando dados coletados durante um ano completo em residências canadenses com intervalo de 30 minutos e fazendo previsões com LSTM. Kim et al. (2019) propuseram um modelo de predictor de carga RICNN (*recurrent inception convolution neural network*) que foi testado em três *smart grids* instaladas em complexos na Coreia do Sul, os resultados apresentaram MAPEs entre 4,167% e 11,088% no método utilizado, valendo lembrar que os locais onde os dados utilizados são originários possuem área de mais de $77m^2$ e foram coletados mais de 500 dias para análise. E também Kong et al. (2017b) utilizaram LSTM em um banco de dados com 69 residências australianas, com dados coletados por três meses com intervalos de 30 minutos, o que permitiu o alcance de MAPEs de 44,06% a 136,49% em previsões individuais e entre 8,58% e 32,54%.

7.4 RESULTADOS GRÁFICOS

Os resultados gráficos são apresentados nesta seção de acordo com os resultados descritos nas tabelas 5, 6, 7 e 8. Primeiramente são apresentados os gráficos dos resultados que obtiveram MAPEs mais baixos em cada dia da semana e em seguida os gráficos da previsão da semana inteira, todos com suas respectivas *wavelets* aplicadas nos dados para que tais resultados fossem alcançados.


7.4.1 Previsões individuais

No gráfico apresentado na Figura 35 estão as curvas que obtiveram um melhor MAPE nas previsões feitas para o domingo nos três níveis de decomposição, sendo que a *wavelet Meyer* obteve o melhor resultado em um nível de decomposição, a *sym4* em dois níveis e a *sym10* em três níveis.

Figura 35 – Previsões de domingo no terceiro nível de decomposição.


Fonte: Elaborado pela autora.

A Figura 36 apresenta as curvas que obtiveram o melhor MAPE nas previsões feitas para segunda-feira nos três níveis de decomposição. A *wavelet db20* obteve o melhor resultado em um nível de decomposição, a *coif1* em dois níveis e a *Haar* em três níveis.

Figura 36 – Previsões segunda-feira no terceiro nível de decomposição.


Fonte: Elaborado pela autora.

Estão ilustradas na Figura 37 as curvas que obtiveram o melhor MAPE nas previsões feitas para terça-feira nos três níveis de decomposição. A *wavelet coif5* obteve o melhor resultado em um nível de decomposição, a *sym4* em dois níveis e a *sym10* em três níveis.

Figura 37 – Previsões terça-feira no terceiro nível de decomposição.


Fonte: Elaborado pela autora.

Na Figura 38 são apresentadas as curvas que obtiveram o melhor MAPE nas previsões feitas para quarta-feira nos três níveis de decomposição. Sendo que a *wavelet Meyer* obteve o melhor resultado em um e dois níveis de decomposição e a *sym10* em três níveis.

Figura 38 – Previsões quarta-feira no terceiro nível de decomposição.


Fonte: Elaborado pela autora.

A Figura 39 apresenta as curvas que obtiveram o melhor MAPE nas previsões feitas para quinta-feira nos três níveis de decomposição. A *wavelet sym10* obteve o melhor resultado em um nível de decomposição, a *coif1* em dois níveis e a *db4* em três níveis.

Figura 39 – Previsões quinta-feira no terceiro nível de decomposição.


Fonte: Elaborado pela autora.

A Figura 40 apresenta as curvas que obtiveram o melhor MAPE nas previsões feitas para sexta-feira nos três níveis de decomposição. A *wavelet coif1* obteve o melhor resultado em um e três níveis de decomposição e a *sym20* em dois níveis.

Figura 40 – Previsões sexta-feira no terceiro nível de decomposição.

Fonte: Elaborado pela autora.


Já nas previsões feitas para o sábado nos três níveis de decomposição, as *wavelet* que se destacaram estão ilustradas na Figura 41, sendo a *wavelet Meyer*, que obteve o melhor resultado em um nível de decomposição e a *sym20* em dois e três níveis.

Figura 41 – Previsões de sábado no terceiro nível de decomposição.

Fonte: Elaborado pela autora.

7.4.2 Previsões semanais


A semana prevista é constituída pelos dias 13 a 19 de março de 2013, sendo que dia 13 é uma quarta-feira e dia 19 é uma terça-feira. As *wavelets* que obtiveram melhores MAPEs nas previsões realizadas na semana toda serão apresentadas graficamente a seguir, sendo que a Figura 42 apresenta a previsão da semana seguinte feita pela ANFIS sem aplicação de TWR.

Figura 42 – Previsão da semana seguinte sem a aplicação da TWR.

Fonte: Elaborado pela autora.

A *wavelet* que obteve o melhor desempenho na previsão da semana toda com um nível de decomposição foi a de *Meyer* e o gráfico da performance desta previsão está ilustrado na Figura 43.


Figura 43 – Previsão da semana seguinte com a *wavelet* de Meyer no primeiro nível de decomposição.



Fonte: Elaborado pela autora.

A *wavelet* que obteve o melhor desempenho na previsão da semana toda com dois níveis de decomposição foi a *sym4* e o gráfico da performance desta previsão está ilustrado na Figura 44.


Figura 44 – Previsão da semana seguinte com a *wavelet* *sym20* no segundo nível de decomposição.



Fonte: Elaborado pela autora.

A *wavelet* que obteve o melhor desempenho na previsão da semana toda com três níveis de decomposição foi a *sym5* e o gráfico da performance desta previsão está ilustrado na Figura 45.

Figura 45 – Previsão da semana seguinte com a *wavelet sym4* no terceiro nível de decomposição.




Fonte: Elaborado pela autora.

A utilização da TWR para remoção de ruídos nos dados de consumo de energia elétrica permitiu que a ANFIS atingisse melhores resultados preditivos em todos os níveis de decomposição, porém quanto maior o nível de decomposição, mais os dados históricos perdem a sua identidade, pois ficam excessivamente suaves.

O gráfico apresentado na Figura 46 ilustra as previsões da ANFIS com os dados submetidos às *wavelets* que se destacaram em cada nível de decomposição em relação à curva de consumo real.

Figura 46 – Previsão das melhores wavelets em relação à curva de consumo real.



Fonte: Elaborado pela autora.

Considerando as previsões de dias individuais, a ANFIS treinada com os dados brutos alcançou melhor resultado na segunda e na terça-feira, comparando com as submetidas à TWR em um nível de decomposição, mostrando que pode realizar previsões razoáveis mesmo com dados inconsistentes. Este comportamento também pode ter sido

influenciado pela quantidade de dados de treinamento, pois estes são os dias que possuem menos padrões de entrada. E nos dias que possuem mais padrões de entrada, i.e., quarta, quinta e sexta-feira, a ANFIS obteve MAPEs mais elevados.

Como a identidade dos dados é importante, o terceiro nível de decomposição não é o ideal, mesmo alcançando MAPEs tão baixos, pois neste caso é possível que informações importantes tenham sido perdidas, i.e., as curvas dos dias da semana se tornaram cada vez mais baixas, e cada vez mais semelhantes, enquanto que as dos finais de semana ficam praticamente sem alterações. Por isso, utilizando a metodologia proposta aplicada, deve-se utilizar apenas o primeiro e o segundo nível de decomposição para a representação mais suave dos dados.

8 CONCLUSÕES

A proposta deste trabalho é construir um modelo que faça previsões de carga em curto prazo para locais de níveis de consumo desagregado, e que apresente resultados satisfatórios para este tipo de problema.

Primeiramente, os dados foram obtidos de um *smart meter* instalado em um bloco dentro de um polo tecnológico. Este bloco apresenta atividades que influenciam diretamente o consumo de energia em todos os dias da semana, fazendo com que a curva de consumo tenha presença de ruídos em locais aleatórios, o que aumenta a dificuldade de realizazr previsões. Os dados de consumo de energia foram separados em dias da semana e estações do ano, sendo excluídos os dias com demasiados dados faltantes, devidos a falhas do dispositivo. Feito isso, foi realizada a previsão de consumo com a rede ANFIS, a qual já apresentou resultados satisfatórios ao levar em consideração o cenário estudado e os trabalhos que fazem previsões considerando o mesmo tipo de consumidor.

Em seguida, os dados de consumo passaram por uma remoção de ruído usando a TWR, submetendo-os a diferentes *wavelets* com objetivo de suavizar as curvas de consumo sem que suas características essenciais fossem perdidas. As amostras foram decompostas em três níveis de resolução e os mesmos foram reconstruídos para não modificar o comprimento do sinal e para não perder integridade. Com os resultados obtidos após a remoção dos ruídos foi observado que a utilização da TWR permitiu melhora nos MAPEs alcançados.

Foi observado que a *wavelet Meyer* se destacou na decomposição em um nível de resolução. Porém, com um nível de decomposição os dados ainda mostram bastante transições bruscas, principalmente nos dias de semana, prejudicando no resultado da previsão. E a previsão em três níveis perde muita informação, modificando a curva de consumo de maneira que ela perca sua identidade. Então, pode-se concluir que a decomposição em dois níveis de resolução é a ideal para este caso, sendo a *sym4* o destaque neste nível.

A predição do modelo proposto foi realizada em um conjunto de dados reais, coletados com intervalo de 15 minutos, onde a ocupação do local em questão é variada, a temperatura também sofre variação de quase 20°C no decorrer de um único dia, fatores estes que influenciam diretamente no comportamento da carga e, como consequência, interferem na previsão.

É importante melhorar a previsões de carga também em níveis desagregados, pois o nível de agregação influencia diretamente os previsores. E desenvolver um método eficiente que atue neste nível específico é um desafio. Este trabalho mostra a eficiência do modelo proposto baseado na ANFIS juntamente com a TWR nesse tipo de problema. A TWR se mostra eficiente, pois permite retirar os ruídos dos dados sem perder informações

importantes no primeiro e no segundo nível de decomposição, e a ANFIS obtém melhora nos resultados após a aplicação.

8.1 TRABALHOS FUTUROS

É muito importante que o sistema utilizado na previsão de carga reconheça dias atípicos ou dados exógenos, pois, quanto melhor o sistema se sair nesta etapa da previsão, melhor será o resultado obtido.

A ANFIS apresenta resultados satisfatórios sem a utilização de remoção de ruídos. Porém os resultados sempre podem ser melhorados. Um exemplo disso foi a utilização da AMR na suavização das curvas de consumo. Neste sentido, apresentam-se a seguir algumas sugestões para trabalhos futuros:

- Utilizar um banco de dados proveniente de níveis de consumo desagregado mais completo para o treinamento da ANFIS;
- Além de utilizar a TWR, pode-se aplicar a SWT (*Stationary Wavelet Transform*) aos dados de consumo de energia antes de submeter os dados ao treinamento. A SWT preserva o tamanho do sinal original no domínio da decomposição. Desta forma, não será necessário utilizar o processo de dizimação, diminuindo assim, o número de operações da metodologia proposta;
- Utilizar a rede neural LSTM (*Long Short-Term Memory*) na previsão de carga de níveis de consumo desagregado. A LSTM é uma rede neural recorrente que pode guardar valores de entradas em intervalos arbitrários, o que impacta na saída da rede e pode ser adequada para prever séries temporais com duração de tempo desconhecida.

REFERÊNCIAS

- ASGHAR, M. R.; DÁN, G.; MIORANDI, D.; CHLAMTAC, I. Smart meter data privacy: A survey. *IEEE Communications Surveys & Tutorials*, Piscataway, v. 19, n. 4, p. 2820–2835, 2017.
- AVANCINI, D. B.; RODRIGUES, J. J.; MARTINS, S. G.; RABÊLO, R. A.; AL-MUHTADI, J.; SOLIC, P. Energy meters evolution in smart grids: A review. *Journal of cleaner production*, Amsterdam, v. 217, p. 702–715, 2019.
- BEDI, J.; TOSHNIWAL, D. Deep learning framework to forecast electricity demand. *Applied energy*, Kidlington, v. 238, p. 1312–1326, 2019.
- BENTO, P.; POMBO, J.; CALADO, M.; MARIANO, S. Optimization of neural network with wavelet transform and improved data selection using bat algorithm for short-term load forecasting. *Neurocomputing*, Amsterdam, v. 358, p. 53–71, 2019.
- BOX, G. E.; JENKINS, G. M.; REINSEL, G. C.; LJUNG, G. M. *Time series analysis: forecasting and control*. New Jersey: John Wiley & Sons, 2015.
- CALDERÓN, A. Intermediate spaces and interpolation: the complex method. *Studia Mathematica*, v. 24, n. 2, p. 113–190, 1964.
- CHITALIA, G.; PIPATTANASOMPORN, M.; GARG, V.; RAHMAN, S. Robust short-term electrical load forecasting framework for commercial buildings using deep recurrent neural networks. *Applied Energy*, v. 278, p. 115410, 2020.
- DASGUPTA, D. *Artificial immune systems and their applications*. Memphis: Springer Science & Business Media, 2012.
- DAUBECHIES, I. Orthonormal bases of compactly supported wavelets. *Communications on Pure and Applied Mathematics*, New Jersey, v. 41, n. 7, p. 909–996, 1988.
- DAUBECHIES, I. *Ten lectures on wavelets*. Philadelphia: SIAM, 1992. v. 61.
- DAUBECHIES, I. Orthonormal bases of compactly supported wavelets ii. variations on a theme. *SIAM Journal on Mathematical Analysis*, Philadelphia, v. 24, n. 2, p. 499–519, 1993.
- DILEEP, G. A survey on smart grid technologies and applications. *Renewable Energy*, Kidlington, v. 146, p. 2589–2625, 2020.
- EL-HENDAWI, M.; WANG, Z. An ensemble method of full wavelet packet transform and neural network for short term electrical load forecasting. *Electric Power Systems Research*, Amsterdam, v. 182, p. 106265, 2020.
- ELZINGA, D.; HEINEN, S. *Technology Roadmap: smart grids*. Paris: International Energy Agency, 2011.
- FAN, G.-F.; PENG, L.-L.; HONG, W.-C. Short term load forecasting based on phase space reconstruction algorithm and bi-square kernel regression model. *Applied Energy*, Kidlington, v. 224, p. 13–33, 2018.

- GARDNER JR, E. S. Exponential smoothing: The state of the art. *Journal of forecasting*, Kidlington, v. 4, n. 1, p. 1–28, 1985.
- GOMES, J.; VELHO, L. *From Fourier analysis to wavelets*. Switzerland: Springer, 2015. v. 3.
- GRAPS, A. An introduction to wavelets. *IEEE computational science and engineering*, Los Alamitos, v. 2, n. 2, p. 50–61, 1995.
- GROSS, G.; GALIANA, F. D. Short-term load forecasting. *Proceedings of the IEEE*, New York, v. 75, n. 12, p. 1558–1573, 1987.
- GROSSMANN, A.; MORLET, J. Decomposition of hardy functions into square integrable wavelets of constant shape. *Journal on Mathematical Analysis*, Philadelphia, v. 15, n. 4, p. 723–736, 1984.
- HAAR, A.; KÁRMÁN, T. v. Zur theorie der spannungszustände in plastischen und sandartigen medien. *Nachrichten von der Gesellschaft der Wissenschaften zu Göttingen, Mathematisch-Physikalische Klasse*, Göttingen, v. 1909, p. 204–218, 1909.
- HAGAN, M. T.; BEHR, S. M. The time series approach to short term load forecasting. *IEEE transactions on power systems*, IEEE, Piscataway, v. 2, n. 3, p. 785–791, 1987.
- HAYKIN, S. *Redes neurais:: princípios e prática*. 2. ed. Porto Alegre: Bookman, 2001. 900 f.
- HE, Y.; LIU, R.; LI, H.; WANG, S.; LU, X. Short-term power load probability density forecasting method using kernel-based support vector quantile regression and copula theory. *Applied energy*, Kidlington, v. 185, p. 254–266, 2017.
- HU, Y.; YE, C.; DING, Y.; XU, C. Short-term load forecasting utilizing wavelet transform and time series considering accuracy feedback. *International Transactions on Electrical Energy Systems*, Kidlington, v. 30, p. e12455, 2020.
- JANG, J.-S. Anfis: adaptive-network-based fuzzy inference system. *IEEE transactions on systems, man, and cybernetics*, Piscataway, v. 23, n. 3, p. 665–685, 1993.
- JANG, J. S. Neuro-fuzzy and soft computing: A computational approach to learning and machine intelligence. *Prentice-Hall, Inc., Simon & Schuster/A Viacom Company*, Upper Saddle River, v. 7458, p. 23, 1997.
- JESUS, P. D. O.-D.; ANTUNES, C. H. Economic valuation of smart grid investments on electricity markets. *Sustainable Energy, Grids and Networks*, Kidlington, v. 16, p. 70–90, 2018.
- KARTALOPOULOS, S. V. *Understanding neural networks and fuzzy logic: Basic concepts and applications*. Piscataway: Wiley-IEEE, 1997.
- KASABOV, N. K. Foundations of neural networks, fuzzy systems, and knowledge engineering. *A Bradford Book*, London, v. 2, 1998.
- KIM, J.; MOON, J.; HWANG, E.; KANG, P. Recurrent inception convolution neural network for multi short-term load forecasting. *Energy and Buildings*, Amsterdam, v. 194, p. 328–341, 2019.

- KONG, W.; DONG, Z. Y.; HILL, D. J.; LUO, F.; XU, Y. Short-term residential load forecasting based on resident behaviour learning. *IEEE Transactions on Power Systems*, Piscataway, v. 33, n. 1, p. 1087–1088, 2017.
- KONG, W.; DONG, Z. Y.; JIA, Y.; HILL, D. J.; XU, Y.; ZHANG, Y. Short-term residential load forecasting based on lstm recurrent neural network. *IEEE Transactions on Smart Grid*, Piscataway, v. 10, n. 1, p. 841–851, 2017.
- KOSKO, B. *Neural networks and fuzzy systems: a dynamical systems approach to machine intelligence*. New Jersey: Prentice-Hall, 1992.
- LEBOTSA, M. E.; SIGAUKE, C.; BERE, A.; FILDES, R.; BOYLAN, J. E. Short term electricity demand forecasting using partially linear additive quantile regression with an application to the unit commitment problem. *Applied Energy*, Kidlington, v. 222, p. 104–118, 2018.
- LI, L.; OTA, K.; DONG, M. When weather matters: Iot-based electrical load forecasting for smart grid. *IEEE Communications Magazine*, Piscataway, v. 55, n. 10, p. 46–51, 2017.
- LI, W.; YANG, X.; LI, H.; SU, L. Hybrid forecasting approach based on grnn neural network and svr machine for electricity demand forecasting. *Energies*, Basel, v. 10, n. 1, p. 44, 2017.
- LIANG, Y.; NIU, D.; HONG, W.-C. Short term load forecasting based on feature extraction and improved general regression neural network model. *Energy*, London, v. 166, p. 653–663, 2019.
- LIPSCHUTZ, S.; LIPSON, M. *Algebra Linear:: Coleção schaum*. Porto Alegre: Bookman, 2009.
- LLORET, J.; TOMAS, J.; CANOVAS, A.; PARRA, L. An integrated iot architecture for smart metering. *IEEE Communications Magazine*, Piscataway, v. 54, n. 12, p. 50–57, 2016.
- LUSIS, P.; KHALILPOUR, K. R.; ANDREW, L.; LIEBMAN, A. Short-term residential load forecasting: Impact of calendar effects and forecast granularity. *Applied Energy*, Kidlington, v. 205, p. 654–669, 2017.
- MADRIGAL, L. *Statistics for anthropology*. Cambridge: Cambridge University, 2012.
- MALLAT, S. et al. *A Wavelet Tour of Signal Processing: The sparse way*. 3. ed. Burlington: Elsevier, 2009.
- MALLAT, S. G. A theory for multiresolution signal decomposition: the wavelet representation. *IEEE transactions on pattern analysis and machine intelligence*, Piscataway, v. 11, n. 7, p. 674–693, 1989.
- MENDEL, J. M. Fuzzy logic systems for engineering: a tutorial. *Proceedings of the IEEE*, Piscataway, v. 83, n. 3, p. 345–377, 1995.
- MEYER, Y. Principe d’incertitude, bases hilbertiennes et algebres d’operateurs. *Séminaire Bourbaki*, Marseille, v. 662, p. 1985–1986, 1985.

- MEYER, Y. Orthonormal wavelets. In: *Wavelets*. New York: Springer, 1989. p. 21–37.
- MEYER, Y. Ondelettes et opérateurs. *I: Ondelettes*, Hermann, Paris, 1990.
- MEYER, Y. Wavelets: Algorithms & applications. *Society for Industrial and Applied Mathematics*, Philadelphia, v. 1, p. 133, 1993.
- MICHIE, D. “memo” functions and machine learning. *Nature*, London, v. 218, n. 5136, p. 19–22, 1968.
- MOHAN, N.; SOMAN, K.; KUMAR, S. S. A data-driven strategy for short-term electric load forecasting using dynamic mode decomposition model. *Applied energy*, Kidlington, v. 232, p. 229–244, 2018.
- MÜLLER, M. R. *Análise de desempenho da rede neural artificial ARTMAP fuzzy aplicada para previsão multi-step de cargas elétricas em diferentes níveis de agregação*. 97 f. Tese (Doutorado em Engenharia Elétrica) — Universidade Estadual Paulista (UNESP), Ilha Solteira, 2018.
- NEGNEVITSKY, M. *Artificial intelligence: a guide to intelligent systems*. Edinburgh: Pearson Education Limited, 2005.
- OURAHOU, M.; AYRIR, W.; HASSOUNI, B. E.; HADDI, A. Review on smart grid control and reliability in presence of renewable energies: Challenges and prospects. *Mathematics and Computers in Simulation*, Amsterdam, v. 167, p. 19–31, 2020.
- PARK, D. C.; EL-SHARKAWI, M.; MARKS, R.; ATLAS, L.; DAMBORG, M. Electric load forecasting using an artificial neural network. *IEEE transactions on Power Systems*, Piscataway, v. 6, n. 2, p. 442–449, 1991.
- PAU, M.; PATTI, E.; BARBIERATO, L.; ESTEBSARI, A.; PONS, E.; PONCI, F.; MONTI, A. A cloud-based smart metering infrastructure for distribution grid services and automation. *Sustainable Energy, Grids and Networks*, Kidlington, v. 15, p. 14–25, 2018.
- QUILUMBA, F. L.; LEE, W.-J.; HUANG, H.; WANG, D. Y.; SZABADOS, R. L. Using smart meter data to improve the accuracy of intraday load forecasting considering customer behavior similarities. *IEEE Transactions on Smart Grid*, Piscataway, v. 6, n. 2, p. 911–918, 2014.
- RIBACIONKA, F. Sistemas computacionais baseados em lógica fuzzy. *Mestrado em Engenharia Elétrica*, Universidade Presbiteriana Mackenzie, Brasil, 1999.
- SADAEI, H. J.; SILVA, P. C. d. L. e; GUIMARÃES, F. G.; LEE, M. H. Short-term load forecasting by using a combined method of convolutional neural networks and fuzzy time series. *Energy*, London, v. 175, p. 365–377, 2019.
- SHI, H.; XU, M.; LI, R. Deep learning for household load forecasting – a novel pooling deep rnn. *IEEE Transactions on Smart Grid*, Piscataway, v. 9, n. 5, p. 5271–5280, 2017.
- SINGH, P.; DWIVEDI, P. Integration of new evolutionary approach with artificial neural network for solving short term load forecast problem. *Applied energy*, Kidlington, v. 217, p. 537–549, 2018.

- SPECHT, D. F. A general regression neural network. *IEEE transactions on neural networks*, Citeseer, v. 2, n. 6, p. 568–576, 1991.
- STRANG, G.; NGUYEN, T. *Wavelets and filter banks*. Wisconsin: SIAM, 1996.
- SUN, Q.; LI, H.; MA, Z.; WANG, C.; CAMPILLO, J.; ZHANG, Q.; WALLIN, F.; GUO, J. A comprehensive review of smart energy meters in intelligent energy networks. *IEEE Internet of Things Journal*, v. 3, n. 4, p. 464–479, 2015.
- TAKAGI, T.; SUGENO, M. Fuzzy identification of systems and its applications to modeling and control. *IEEE transactions on systems, man, and cybernetics*, n. 1, p. 116–132, 1985.
- TAVASSOLI-HOJATI, Z.; GHADERI, S.; IRANMANESH, H.; HILBER, P.; SHAYESTEH, E. A self-partitioning local neuro fuzzy model for short-term load forecasting in smart grids. *Energy*, London, p. 117514, 2020.
- TONELLI-NETO, M. S.; DECANINI, J. G. M.; LOTUFO, A. D. P.; MINUSSI, C. R. Fuzzy based methodologies comparison for high-impedance fault diagnosis in radial distribution feeders. *IET Generation, Transmission & Distribution*, v. 11, n. 6, p. 1557–1565, 2017.
- VETTERLI, M.; HERLEY, C. Wavelets and filter banks: Theory and design. *IEEE transactions on signal processing*, IEEE, Piscataway, v. 40, n. ARTICLE, p. 2207–2232, 1992.
- VETTERLI, M.; KOVACEVIC, J. *Wavelets and subband coding*. New Jersey: Prentice-Hall, 1995.
- VOSS, M.; BENDER-SAEBELKAMPF, C.; ALBAYRAK, S. Residential short-term load forecasting using convolutional neural networks. 2018 IEEE INTERNATIONAL CONFERENCE ON COMMUNICATIONS, CONTROL, AND COMPUTING TECHNOLOGIES FOR SMART GRIDS, Aalborg, Denmark, p. 1–6, 2018.
- WANG, Y.; GAN, D.; SUN, M.; ZHANG, N.; LU, Z.; KANG, C. Probabilistic individual load forecasting using pinball loss guided lstm. *Applied Energy*, Kidlington, v. 235, p. 10–20, 2019.
- WERBOS, P. J. *Beyond regression: New tools for prediction and analysis in the behavioral sciences*. 452 p. Thesis (Ph. D.) — Harvard University, Cambridge, Massachusetts, 1974.
- WIDROW, B.; LEHR, M. A. 30 years of adaptive neural networks: perceptron, madaline, and backpropagation. *Proceedings of the IEEE*, New York, v. 78, n. 9, p. 1415–1442, 1990.
- WORIGHI, I.; MAACH, A.; HAFID, A.; HEGAZY, O.; MIERLO, J. V. Integrating renewable energy in smart grid system: Architecture, virtualization and analysis. *Sustainable Energy, Grids and Networks*, Kidlington, v. 18, p. 100226, 2019.
- XIAO, L.; SHAO, W.; YU, M.; MA, J.; JIN, C. Research and application of a hybrid wavelet neural network model with the improved cuckoo search algorithm for electrical power system forecasting. *Applied energy*, Kidlington, v. 198, p. 203–222, 2017.

- XIE, K.; YI, H.; HU, G.; LI, L.; FAN, Z. Short-term power load forecasting based on elman neural network with particle swarm optimization. *Neurocomputing*, Amsterdam, 2019.
- XU, L.; WANG, S.; TANG, R. Probabilistic load forecasting for buildings considering weather forecasting uncertainty and uncertain peak load. *Applied energy*, Kidlington, v. 237, p. 180–195, 2019.
- XUE, P.; JIANG, Y.; ZHOU, Z.; CHEN, X.; FANG, X.; LIU, J. Multi-step ahead forecasting of heat load in district heating systems using machine learning algorithms. *Energy*, London, v. 188, p. 116085, 2019.
- YU, C.-N.; MIROWSKI, P.; HO, T. K. A sparse coding approach to household electricity demand forecasting in smart grids. *IEEE Transactions on Smart Grid*, v. 8, n. 2, p. 738–748, 2016.
- ZADEH, L. A. Fuzzy sets. *Information and control*, v. 8, n. 3, p. 338–353, 1965.
- ZADEH, L. A. Fuzzy logic. *Computer*, IEEE, v. 21, n. 4, p. 83–93, 1988.
- ZENG, A.; LIU, S.; YU, Y. Comparative study of data driven methods in building electricity use prediction. *Energy and Buildings*, Amsterdam, v. 194, p. 289–300, 2019.
- ZHANG, J.; WEI, Y.-M.; LI, D.; TAN, Z.; ZHOU, J. Short term electricity load forecasting using a hybrid model. *Energy*, London, v. 158, p. 774–781, 2018.
- ZHENG, Z.; CHEN, H.; LUO, X. A kalman filter-based bottom-up approach for household short-term load forecast. *Applied Energy*, Kidlington, v. 250, p. 882–894, 2019.