



UNIVERSIDADE ESTADUAL PAULISTA
“JÚLIO DE MESQUITA FILHO”
Campus de Ilha Solteira

MONARA PEREIRA DA ROSA CARVALHO

**PREVISÃO DE DEMANDA DE UM PRÉDIO
UNIVERSITÁRIO POR REDES NEURAIS ARTIFICIAIS**

Ilha Solteira
2017

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

MONARA PEREIRA DA ROSA CARVALHO

**PREVISÃO DE DEMANDA DE UM PRÉDIO
UNIVERSITÁRIO POR REDES NEURAIS ARTIFICIAIS**

Dissertação apresentada à Faculdade de Engenharia de Ilha Solteira - UNESP, como parte dos requisitos para obtenção do título de Mestre em Engenharia Elétrica.

Especialidade: Automação

Profa. Dra. Anna Diva Plasencia Lotufo
Orientador

Ilha Solteira
2017



FICHA CATALOGRÁFICA

Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

C331p Carvalho, Monara Pereira da Rosa.
Previsão de demanda de um prédio universitário por redes neurais artificiais / Monara Pereira da Rosa Carvalho. -- Ilha Solteira: [s.n.], 2017
62 f. : il.

Dissertação (mestrado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Automação, 2017

Orientador: Anna Diva Plasencia Lotufo
Inclui bibliografia

1. Previsão de demanda de curto prazo. 2. Redes neurais artificiais. 3. GRNN.
4. Smart grids.

CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: PREVISÃO DE CARGA DE UM PRÉDIO UNIVERSITÁRIO POR REDES NEURAIS ARTIFICIAIS

AUTORA: MONARA PEREIRA DA ROSA CARVALHO

ORIENTADORA: ANNA DIVA PLASENCIA LOTUFO

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



Profa. Dra. ANNA DIVA PLASENCIA LOTUFO
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira



Profa. Dra. LILIAN YULI SODA
Departamento de Matemática / Faculdade de Engenharia de Ilha Solteira



Prof. Dr. EDGAR MANUEL CARREÑO FRANCO
Departamento de Engenharia Elétrica / Universidade Estadual do Oeste do Paraná

Ilha Solteira, 20 de janeiro de 2017

À minha mãe, dedico.

AGRADECIMENTOS

Agradeço a professora Dra. Anna Diva pela confiança, apoio e orientação deste trabalho e por sempre me receber com um sorriso nas incontáveis vezes que fui a sua sala.

Agradeço a todos os colegas do laboratório Sintel pela amizade, paciência, pelos cafés e pelas caronas.

Aos amigos em especial Tania, Natália e Fabricio, por estarem ao meu lado desde o início.

Ao meu namorado Kevin, por sempre me apoiar nas minhas decisões e estar ao meu lado até nos momentos mais difíceis.

A minha mãe pelo amor e carinho, pela confiança e dedicação, por ser uma pessoa maravilhosa.

A Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo suporte financeiro.

*“Fly, on your way
Like an eagle
Fly as high as the sun”*

Bruce Dickinson.

RESUMO

Este trabalho destaca a análise de dados provenientes de locais com níveis de consumo mais desagregados que apresentam dificuldades para previsões de demanda com vários métodos devido à alta variação no consumo de energia elétrica. Apresenta-se resultados de previsões de demanda de curto prazo da energia elétrica consumida em um bloco de uma universidade por meio da rede neural de regressão generalizada (GRNN), utilizando a abordagem de modelagem de dados de baixo para cima e tratamento de ruídos e dados faltantes no banco de dados através da aplicação de um filtro de médias móveis. É apresentado o local que fornece as informações para os estudos e a etapa de pré-processamentos dos dados. Foi possível analisar a assertividade das previsões de acordo com o cálculo do MAPE, mostrando vantagens ao se comparar a outros métodos utilizados para os mesmos fins.

Palavras-chaves: Bottom-up. Previsão de demanda de curto prazo. Redes Neurais Artificiais. Smart Grids. GRNN.

ABSTRACT

This work analysis load data from desegregated levels that presented difficulties to load forecasting with several methods due to variation in electrical energy consumption. The application proposed in this work is short-term load forecasting to a university building by GRNN (General Regression Neural Network) considering the bottom up approach and using a moving average filter to deal with the missing or wrong data. It is presented the system that provides the data as well as the methods used for pre-processing and realize the forecasting. The results are evaluated by MAPE (Mean Absolute Perceptual Error) and are considered good when compared with other methods.

Keywords: Bottom-up. Short-Term Load Forecasting. Artificial Neural Networks. Smart Grids. GRNN.

LISTA DE FIGURAS

Figura 1 - Arquitetura da GRNN.....	17
Figura 2 - Blocos de Transformadores do PTI.....	28
Figura 3 - Segundas-feiras originais medidas.....	29
Figura 4 - Segundas-feiras depois de desconsiderar dias com dados faltantes em excesso.....	30
Figura 5 - Curvas de Demanda: Segundas-feiras.....	30
Figura 6 - Terças-feiras originais medidas.....	31
Figura 7 - Terças-feiras depois de desconsiderar dias com dados faltantes em excesso.....	31
Figura 8 - Curvas de demanda: Curvas de Demanda: Terças-feiras.....	32
Figura 9 - Quartas-feiras originais medidas.....	32
Figura 10 - Quartas-feiras depois de desconsiderar dias com dados faltantes em excesso.....	33
Figura 11 - Curvas de Demanda: Quartas-feiras.....	33
Figura 12 - Quintas-feiras originais medidas.....	34
Figura 13 - Curvas de Demanda: Quintas-feiras.....	34
Figura 14 - Sextas-feiras originais medidas.....	35
Figura 15 - Curvas de Demanda: Sextas-feiras.....	35
Figura 16 - Sábados originais medidas.....	36
Figura 17 - Sábados depois de desconsiderar dias com dados faltantes em excesso.....	36
Figura 18 - Curvas de Demanda: Sábados.....	37
Figura 19 - Domingos originais medidos.....	37
Figura 20 - Domingos depois de desconsiderar dias com dados faltantes em excesso.....	38
Figura 21 - Curvas de Demanda: Domingos.....	38
Figura 22 - Previsão para segunda-feira seguinte.....	42
Figura 23 - Previsão para terça-feira seguinte.....	42
Figura 24 - Previsão para quarta-feira seguinte.....	42
Figura 25 - Previsão para quinta-feira seguinte.....	44
Figura 26 - Previsão para sexta-feira seguinte.....	44

Figura 27 - Previsão para o sábado seguinte.....	45
Figura 28 - Previsão para o domingo seguinte.....	46
Figura 29 - Previsão global.....	46
Figura 30 - Curvas de demanda de segunda-feira original e filtrada.....	48
Figura 31 - Curvas de demanda de terça-feira original e filtrada.....	48
Figura 32 - Curvas de demanda de quarta-feira original e filtrada.....	49
Figura 33 - Curvas de demanda de quinta-feira original e filtrada.....	49
Figura 34 - Curvas de demanda de sexta-feira original e filtrada.....	50
Figura 35 - Curvas de demanda de sábado original e filtrada.....	50
Figura 36 - Curvas de demanda de domingo original e filtrada.....	51
Figura 37 - Previsão para Segunda-feira seguinte com pré-processamento de dados.....	52
Figura 38 - Previsão para Terça-feira seguinte com pré-processamento de dados.....	52
Figura 39 - Previsão para Quarta-feira seguinte com pré-processamento de dados.....	53
Figura 40 - Previsão para Quinta-feira seguinte com pré-processamento de dados.....	54
Figura 41 - Previsão para Sexta-feira seguinte com pré-processamento de dados.....	54
Figura 42 - Previsão para o Sábado seguinte com pré-processamento de dados.....	55
Figura 43 - Previsão para o Domingo seguinte com pré-processamento de dados.....	55

LISTA DE TABELAS

Tabela 1 - Cálculo do MAPE.....	41
Tabela 2 - MAPEs diários mínimos, médios e máximos obtidos na previsão de demanda global.....	55

LISTA DE ABREVIACOES E SIGLAS

ARIMA	Autoregressivo Integrado de Medias Movies
ARTMAP	<i>Adaptive Resonance Theory</i>
EUs	<i>End-Uses</i>
GRNN	Rede Neural de Regresso Generalizada
HVAC	<i>Heating, Ventilation and Air-Conditioning</i>
MAPE	<i>Mean Absolute Percentage Error</i>
MPL	<i>Multilayer Perceptron</i>
PTI	Parque Tecnolgico Itaipu
RL	Regresso Linear
RNAs	Redes Neurais Artificiais
SEE	Sistema de Energia Eltrica
STP	<i>Shielded Twisted Pair</i>
TI	Tecnologia de Informao

SUMÁRIO

1	INTRODUÇÃO	13
1.1	ORGANIZAÇÃO DO TRABALHO	15
2	REDES NEURAIAS ARTIFICIAIS	16
2.1	GRNN (General Regression Neural Network).....	16
3	PREVISÃO DE DEMANDA	19
3.1	PREVISÃO DE DEMANDA ELÉTRICA.....	19
3.1.1	Smart Grids	20
3.1.2	Classificação da Previsão	21
3.2	Previsões por Redes Neurais Artificiais	23
3.2.1	Previsão por GRNN (General Regression Neural Network)	25
3.2.2	Avaliação da Previsão	26
4	CENÁRIO DE ESTUDO	27
4.1	PTI.....	27
4.2	COMPORTAMENTO DA DEMANDA.....	29
4.3	PRÉ-PROCESSAMENTO DOS DADOS.....	39
5	RESULTADOS	41
5.1	RESULTADOS GRÁFICOS DAS PREVISÕES	42
5.2	COMPARAÇÃO DOS DIAS COMUNS E DIAS FILTRADOS.....	47
5.3	RESULTADOS OBTIDOS APÓS O PRÉ-PROCESSAMENTO DOS DADOS.....	51
6	CONSIDERAÇÕES FINAIS	57
	REFERÊNCIAS	58

1 INTRODUÇÃO

O conhecimento do comportamento da demanda é de muita importância para o planejamento da expansão, fluxo de potência, operação econômica, análise e controle de segurança de Sistemas de Energia Elétrica, e saber como a demanda virá a se comportar futuramente exerce um papel significativo nesses setores (ABREU, 2012).

Inúmeros métodos previsores de demanda elétrica são encontrados na literatura, tais como a técnica de regressão linear, modelos ARIMA de Box e Jenkins (1976), métodos de suavização exponencial, filtro de Kalman, entre outros. Para tais métodos serem aplicados, é indispensável efetuar a modelagem da demanda, que se classifica como uma tarefa de identificação de sistemas, onde existe um procedimento que abrange desde a coleta dos dados até a utilização de técnicas de otimização para a determinação dos parâmetros do modelo e sua aplicação (VISCONTI, 2010).

Outros métodos como Redes Neurais Artificiais e até mesmo modelos híbridos são utilizados, nestes faz-se uma junção entre modelos como em Lü et al. (2015) o qual fez a junção de um método físico e um método estatístico, em Abreu (2012) que utilizou ARIMA e RNAs ou junção de técnicas como em Alves et al. (2016) que apresentou uma remodelagem da rede neural ARTMAP *Fuzzy* e também a utilização de técnicas de otimização como Yang et al. (2016) que utilizou RNAs com o algoritmo de recozimento simulado, no qual simula o processo de recozimento de metais.

Datta, Tassou e Marriott (2000) afirma que métodos de RNAs mostram melhores desempenhos em comparação aos testes físicos, estatísticos e de regressão. A mesma observação sobre a superioridade das RNAs em relação às técnicas estatísticas é feita em Raza e Khosravi (2015) que analisou várias técnicas que focam a previsão de demanda justificando a eficiência das RNAs na capacidade de mapear as entradas do modelo para as saídas sem fazer formulações matemáticas complexas. Na pesquisa desenvolvida por Patel, Pandya e Aware (2015) foram utilizadas as técnicas Regressão Linear e RNA com o algoritmo de treinamento Levenberg-Marquardt *Backpropagation* para realizar a previsão de demanda de curto prazo de prédios industriais e áreas residenciais, com dados armazenados no mês de

fevereiro do ano de 2015 por um sistema de distribuição de energia indiano. Considerou-se os dados de temperatura, umidade, dia da semana e feriados além dos dados de consumo de energia. Foram obtidos resultados de previsões feitas com a utilização das duas técnicas e considerando ou não os dados climáticos, nestes resultados foi provado que as RNAs obtiveram mais precisão nas suas previsões em dois testes feitos, com e sem dados climáticos, mostrando possuir maior eficiência ao ser comparado com a regressão linear através do MAPE que mostrou menos de 1% de erro. Ferlito et al. (2015) também comprova a eficácia das RNAs em previsão de demanda de energia. Foi utilizado a rede neural autorregressiva não-linear para a previsão de demanda de uma escola em Eboli (Itália) com dados coletados mensalmente e previsões para três, seis e doze meses, teve como entrada da rede apenas a série temporal do consumo de energia.

Smart Grids (Redes Inteligentes) são definidas por uma corrente bidirecional de eletricidade e informações através da agregação do sistema elétrico às tecnologias de informação e comunicação e pelo emprego do gerenciamento da resposta à demanda que é responsável por coordenar os veículos elétricos plugáveis, fontes de energia renováveis e demanda elétrica (DEILAMI et al., 2011; LEITE, 2015). Nesse processo *smart meters* (medidores inteligentes) são inseridos para realizar a medição dos dados que serão coletados pelo sistema de gerenciamento de dados de medição e posteriormente enviados para o local de armazenamento dos dados.

Para o problema de modelagem de demanda de maneira geral, existem duas abordagens genéricas que vêm sendo empregadas como base para o desenvolvimento de modelos de demanda, são elas "*top-down*" que se baseia em um todo com foco em desagregá-lo e "*bottom-up*" que propõe a obtenção de modelos desassociados do todo, considerando cada dispositivo que compõem a demanda analisada (MOTTA, 2005).

Este trabalho propõe o uso da rede neural de regressão generalizada para a realização de previsão de demanda em níveis de consumo menos agregados, onde existem maiores níveis de incertezas na previsão, devido a grandes variações na curva de demanda diária. Medidores inteligentes foram instalados em um campus universitário na cidade de Foz do Iguaçu, Paraná, onde as grandezas elétricas dos blocos da universidade foram medidas e posteriormente enviadas para um servidor

onde ficaram armazenados, são considerados para essas previsões os dados de consumo de energia de um bloco específico, onde se encontram consumidores comerciais do ramo alimentício, além de outros aparelhos elétricos.

1.1 ORGANIZAÇÃO DO TRABALHO

Capítulo 2 – Previsão da demanda: Introdz previsão de demanda em geral e descreve previsões de demanda elétrica fazendo uma breve revisão bibliográfica de trabalhos realizados na área, apresenta o conceito Smart Grids e smart meters, como a previsão pode ser classificada e mostra as previsões por RNAs e por GRNN e por fim o método que foi usado para avaliar a precisão das previsões;

Capítulo 3 – Cenário de Estudo: Faz uma descrição detalhada do local de onde provém as informações que compõem o banco de dados utilizado, mostrando as curvas de demanda diárias obtidas e os fatores que influenciam a demanda, depois é feita a descrição do tratamento pelo qual os dados passaram para que ruídos e dados faltantes fossem corrigidos;

Capítulo 4 – Resultados da Previsão: Apresenta os gráficos feitos a partir dos resultados das previsões com os dados em sua forma original, mostra a comparação dos dados nas curvas diárias antes e depois do pré-processamento, apresenta os resultados das previsões depois que os dados passam pelo tratamento e as comparações dos resultados.

Capítulo 5 – Considerações Finais: Apresenta as principais conclusões tiradas a partir dos resultados obtidos e propostas para trabalhos futuros.

2 REDES NEURAIS ARTIFICIAIS

Neste trabalho foi feito o uso da rede neural de regressão generalizada para realização da previsão de demanda elétrica, em seguida será apresentado conceitos sobre RNAs para o entendimento da rede.

Uma rede neural artificial (RNA) pode ser definida como um aparelho no qual foi programado para imitar o funcionamento do cérebro humano, se adaptando a maneira como o mesmo realiza tarefas específicas, reproduzindo de maneira artificial o comportamento dos nossos neurônios ao processarem os estímulos (HAYKIN, 1994).

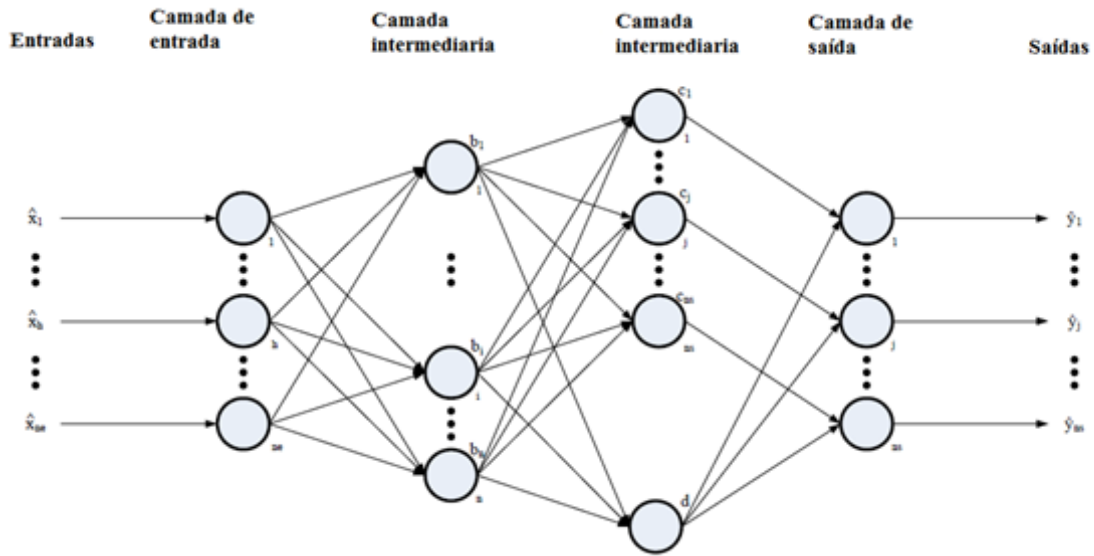
As redes neurais são compostas de neurônios interligados, formando estruturas de processamento de informação, onde os neurônios são as unidades de processamento. As mesmas são capazes de fornecer saídas referentes a entradas lineares ou não-lineares (LOPES, 2005).

2.1 GRNN (*General Regression Neural Network*)

Proposta por Donald Specht (1991), a rede neural de regressão generalizada possui uma estrutura fixa, sendo uma camada de entrada, duas camadas intermediárias e uma camada de saída. O seu treinamento é supervisionado e sua estrutura é do tipo não recorrente, conforme mostra a Figura 1.

Os padrões de treinamentos são apresentados à rede apenas uma vez e a quantidade de neurônios pertencentes a cada camada se dá de acordo com o número de entradas, saídas e amostras do conjunto de dados de treinamento apresentados (NOSE-FILHO, 2011). Esta rede possui treinamento rápido e feito em apenas uma etapa, os padrões de entradas são copiados para a primeira camada escondida e esta memoriza o treinamento das entradas com as saídas, isso faz com que esta camada possua o número de neurônios igual ao número de padrões de treinamento. A função da segunda camada é estimar uma saída de acordo com o histórico armazenado dos cálculos das diferenças entre o padrão de treinamento atual com os padrões anteriores (FREITAS, 2016).

Figura 1: Arquitetura da GRNN.



Fonte: (NOSE-FILHO, 2011).

A GRNN é uma rede apta a calcular variáveis dependentes procedendo de variáveis independentes através de um conjunto de variáveis finito (NOSE-FILHO, 2011). A rede mantém a capacidade de generalização até mesmo com o uso de dados independentes e pelo fato de ser baseada em uma função densidade de probabilidade, as chances de cair em mínimos locais são muito baixas (NIU; WANG; GU, 2005).

As etapas do algoritmo de treinamento e do algoritmo de diagnóstico/previsão são as seguintes (NOSE-FILHO, 2011):

Treinamento:

Leitura das matrizes X e Y e do parâmetro spread.

Diagnóstico/Previsão:

Leitura do padrão desconhecido \hat{X} ;

Cálculo das distâncias euclidianas, a_i dadas por (1);

Cálculo dos níveis de pertinência, b_i dados por (2);

Cálculo das saídas dos neurônios do tipo numerador, c_j dadas por (3), e da saída do neurônio do tipo denominador, d dada por (4);

Cálculo das saídas estimadas, \hat{y}_j dadas por (5);

A saída \hat{Y} é dada por (6).

$$a_i = (\hat{X} - X_i)^T (\hat{X} - X_i), i = 1, \dots, n \quad (1)$$

$$b_i = \exp\left(\frac{-0,8326^2 a_i^2}{\sigma^2}\right), i = 1, \dots, n \quad (2)$$

$$c_j = \sum_{i=1}^n y_{j,i} b_i, j = 1, \dots, ns \quad (3)$$

$$d = \sum_{i=1}^n b_i \quad (4)$$

$$\hat{y}_j = \frac{c_j}{d}, j = 1, \dots, ns \quad (5)$$

$$\hat{Y} = [\hat{y}_1 \dots \hat{y}_j \dots \hat{y}_{ns}]^T \quad (6)$$

Assim que as entradas forem apresentadas as redes o algoritmo é aplicado. Quando as etapas do algoritmo de treinamento forem concluídas, a rede estará apta a realizar previsões, apresentando as saídas.

3 PREVISÃO DE DEMANDA

Atualmente a previsão de demanda está sendo amplamente utilizada, pois essa se caracteriza como uma suposição do que acontecerá com as vendas de produtos ou serviços nas empresas, e, quando essa informação é adquirida por estas empresas, torna-se possível realizar um melhor planejamento para estas atividades.

Estudos sobre previsão de todos os tipos se encontram relevantes em todas as áreas, observando por exemplo estudos como o de Anbazhagan, Kumarappan e Gnanaprakasam (2011) que previu preços, Leng et al. (2013) que previu tráfego urbano, e também Santos et al. (2013) que fez previsão de agitação marítima, cada um utilizando um método diferente.

3.1 PREVISÃO DE DEMANDA ELÉTRICA

É possível encontrar inúmeras pesquisas dentre as realizadas nos últimos anos na qual é explorada a previsão de demanda elétrica, isso se deve a necessidade das previsões para auxiliar no planejamento de sistemas de energia elétrica, nos quais podem ser citados: compra e venda de energia elétrica, planejamento da geração, transmissão e distribuição de energia elétrica.

Pode-se citar alguns trabalhos atuais que tratam de pesquisas de métodos previsores de demanda elétrica como o desenvolvido por Lü et al. (2015) que compôs uma junção de um modelo físico com um modelo estatístico que executa previsão de demanda de curto prazo em um prédio; Rasmussen et al. (2016) apresentou um estudo de modelo de série temporal para prever a demanda elétrica para refrigeração de um supermercado, também com objetivo de prever comportamento de demanda. Escrivá-Escrivá et al. (2011) construiu um modelo de rede neural a partir do MLP baseados em EUs (usos finais) capaz de ajustar uma curva de demanda para uma determinada instalação, tendo como entrada além do consumo de energia, a temperatura e os dias da semana, separando a previsão dos dias regulares dos feriados, mostrando bons resultados comparando com outros métodos.

Para que sejam realizados trabalhos com objetivo de desenvolver um sistema previsor de demanda elétrica, é necessário que exista o conhecimento prévio da demanda em diversos pontos do sistema para que o mesmo opere de modo seguro, econômico e confiável (HANDSCHIN; DÖRNEMANN, 1988; NOSE-FILHO, 2011), bem como fatores que podem ter influência no mesmo. Um estudo feito por Ke, Jiang e Lu (2016) destaca a importância de considerar outras informações ambientais, mostrando como resultado previsões com menos de 1% de erro na precisão, justificando essa precisão não só com a qualidade do método previsor utilizado, mas também destaca os benefícios que existem em utilizar conjuntos de dados de qualidade. Touretzky e Patil (2015) comenta que quanto mais inteligente a rede pode se tornar, melhores dados podem ser fornecidos beneficiando o desenvolvimento do modelo previsor, destacando a importância do conceito de *Smart Grids* para esta linha de pesquisa.

3.1.1 SMART GRIDS

Devido a várias ocorrências de apagões durante as décadas anteriores em diferentes lugares do mundo (GIRI et al., 2009), a busca de melhor qualidade da energia fornecida ao consumidor e o desenvolvimento de fontes renováveis (OLIVEIRA; VIEIRA JUNIOR, 2012) entre outros, estão motivando cada vez mais a busca de soluções que atendam o interesse de produtores de energia elétrica e seus respectivos consumidores. Para atingir a alta qualidade e confiabilidade da energia, minimizar os custos de operação e manutenção do sistema, possuir resistência a ataques cibernéticos, otimizar a utilização dos ativos do sistema elétrico, realizar auto-diagnose e auto-reparação da rede elétrica frente a qualquer problema detectado no circuito elétrico, ser capaz de realizar interconexão de grande variedade de fontes de geração na forma distribuída e opções de armazenamento de energia (BROWN, 2008), foi introduzido o conceito de *smart grid*.

A *Smart Grid* não é apenas um equipamento, deve ser entendida mais como um conceito, de utilização da TI (tecnologia da informação) e da comunicação nos componentes da rede elétrica, que proporciona o desenvolvimento de novas estratégias de controle e otimização de rede mais eficientes do que as que utilizam atualmente (FALCÃO, 2009), se aplicando a todo o sistema elétrico, desde a geração,

transmissão e distribuição de energia até o consumo nas residências, prédios comerciais, complexos industriais (OLIVEIRA; VIEIRA JUNIOR, 2012). Dispositivos inteligentes importantes para a estrutura da *Smart Grid* são inseridos. Os *Smart Meters* são os principais componentes da infraestrutura de medição avançada, pois ajudam no gerenciamento dos aparelhos domésticos e suportam operações de leitura automática (CHO; YAMAZAKI; HAHN, 2009) e armazenamento de tais informações para análises posteriores.

3.1.2 CLASSIFICAÇÃO DA PREVISÃO

As previsões são divididas de acordo com o tempo de previsão que pode fornecer (NOSE-FILHO; LOTUFO; MINUSSI, 2011), podem ser categorizadas como (KHUNTIA; MEIJDEN, 2016):

- Previsão de demanda de curto prazo: o período que abrange a previsão de demanda de curto prazo é de alguns minutos, algumas horas ou um dia a frente até uma semana. Tal tipo de previsão focaliza o despacho econômico.
- Previsão de demanda de médio prazo: essa se dá de um mês a um ano ou dois. Essa visa a programação de manutenção, coordenação de despacho de demanda, e também a liquidação de preços para que a demanda e a geração sejam equilibradas.
- Previsão de demanda de longo prazo: a qual é realizada para períodos de poucos anos até de 10 a 20 anos. A de longo prazo tem como finalidade o planejamento da expansão do sistema, como por exemplo, a geração, transmissão e distribuição. Em alguns casos, também afeta a compra de novas unidades geradoras.

Existe também a previsão de curtíssimo prazo, o seu período de previsão é de poucos segundos até pouco menos de quinze minutos, essa previsão é utilizada para o planejamento de operação on-line e controle (ABREU, 2012).

Uma das tendências atuais tem sido a segmentação da demanda pelo seu tipo, em outras palavras, analisar separadamente grandes blocos, como prédios

públicos, universidades, hospitais, etc. além das residências que já são estudadas separadamente dentro do que se convencionou chamar de previsão de baixo para cima (ANDERSEN; LARSEN; BOOMSMA, 2013), que consiste em determinar modelos individuais para cada equipamento que compõe a demanda total analisada (MOTTA, 2005), também chamada de “*bottom-up*”. No estudo desenvolvido por Debnath, Mourshed e Chew (2015) foi empregada a técnica *bottom-up* para realizar a modelagem da demanda de dados que provêm das residências dos habitantes da área rural de um município de Bangladesh, onde foram considerados como dados de entrada o consumo dos aparelhos eletrodomésticos existentes nas respectivas residências. Outro exemplo da modelagem *bottom-up* é apresentado por Sandels et al. (2016) fazendo uma modelagem de baixo para cima gerando perfis de demanda a partir da conexão dos aspectos comportamentais dos trabalhadores de um escritório localizado no norte da Europa com a representação física do edifício em questão para descrever o consumo de energia dos sistemas HVAC (*heating, ventilation and air-conditioning*).

Existe também a abordagem de cima para baixo, também conhecida como “*top-down*”, onde o todo é focalizado, decompondo-o em suas partes, esta focaliza um modelo que demonstra o comportamento dos componentes do sistema real quando agregado (MOTTA, 2015). A pesquisa de Chin, Tanaka e Abe (2016) demonstra que não há grande diferença entre os dois métodos levando em consideração a precisão da previsão quando essas abordagens são utilizadas, sendo o de baixo para cima ligeiramente mais preciso.

Existem inúmeros métodos propostos por estudiosos da área com fim de prever demanda elétrica, como o desenvolvimento de um algoritmo de suavização exponencial por Lim et al (2013) no qual teve como objetivo a previsão de curto prazo direcionada a institutos de educação, foi feita análise da variação nos padrões de demanda diário, semanal e anual de um campus universitário em Seul (Coreia do Sul) e essas informações foram correlacionadas às temperaturas atingidas no período verificado devido a sensibilidade que a demanda elétrica têm à temperatura, o índice de erro resultante se manteve entre 3 e 4%, calculados através do MAPE.

As RNAs são ferramentas hábeis quando se trata de previsões, isso se deve à sua capacidade de aprendizado e generalização, o que as torna capazes de realizar

a aproximação de funções não-lineares e a previsão de séries temporais a partir de um treinamento adequado, (HAYKIN, 2008). Dentro desta linha elas se destacam como as que atingem os melhores resultados quando comparadas a outros métodos e isso faz com que seja um dos métodos mais utilizados, conforme observa-se a seguir.

3.2 PREVISÃO POR REDES NEURAIS ARTIFICIAIS

No trabalho de Santos et al. (2013) foi desenvolvido um sistema de redes neurais ARTMAP com técnicas de lógica *Fuzzy* para aplicar na previsão de agitações marítimas, no qual os dados utilizados para a pesquisa foram coletados por uma boia-ondógrafo no Porto de Sines, situado na costa oeste de Portugal, no período que compreende os anos de 2010 e 2012. Foram considerados como entrada a altura da onda, o período de onda e a direção de ondas e foi feito mapeamento de erros de cada item considerado para entrada. Os resultados das previsões mostram que para este tipo de estudo é necessário treinar a rede com uma base de dados mais longa, pois mostram MAPEs altos se poucos dados forem introduzidos como entrada.

Bagnasco et al. (2015) desenvolveu um modelo de previsão de demanda utilizando a RNA perceptron de múltiplas camadas com algoritmo de treinamento *backpropagation*, aplicou esse modelo em uma clínica médica em Turim (Itália), após ter os dados divididos em subgrupos sazonais obteve resultados excelentes, e ainda mostrando a importância da segmentação para a previsão, esta subdivisão dos dados foi realizada pela grande diferença entre as curvas de demanda de cada estação do ano, o que interfere diretamente na previsão caso sejam utilizados dados do ano todo para o treinamento da rede como mostra também o presente trabalho.

Foram feitas curvas de demanda de seis edifícios que incluem fábricas e escritórios comerciais (C&I) para realizar uma previsão de demanda em Jetcheva, Majidpour e Chen (2014) no qual também considerou que fatos como feriados, finais de semana e horários fora do pico (8 da noite à 8 da manhã) podem influenciar no resultado final, por isso foram excluídas tais informações do banco de dados para o treinamento da RNA utilizada na pesquisa, que foi feita com a estrutura MLP com algoritmo de treinamento *backpropagation*, que se mostrou flexível em ser utilizada em aplicações onde as demandas se comportam de maneiras diferentes obtendo

resultados superiores a outro método testado no trabalho, o mesmo treinamento foi feito em Massana et al. (2015), o qual realizou a previsão de consumo de energia de uma universidade de Girona (Espanha), onde considerou dados de demanda e dados meteorológicos para treinamento, os dados foram organizados com a utilização do método *bottom-up*, julgando cada componente da universidade para formar a curva de demanda final.

No estudo feito por Penya et al. (2011) é considerada a influência do clima sobre a demanda, que foi coletada de imóveis não residenciais como escolas, faculdades, prédios públicos e instalações empresariais que possuem ar condicionado, realizou-se testes com quatro modelos diferentes de previsão: o modelo autorregressivo, o modelo ARIMA (Autoregressivo Integrado de Médias Móveis), modelos bayesianos, e as RNAs, que nesse caso não obteve melhor desempenho, mas foi destacado que esta possui menor alteração nos resultados quando existem dados ruidosos. A mesma consideração foi feita na pesquisa de Gulin et al. (2014), utilizando também dados meteorológicos obtidos referentes aos anos de 2011 a 2013 como entrada para realizar previsão de demanda de curto prazo de universidade da Croácia por meio de RNA, desenvolveu-se uma MLP que mostrou ótima performance nesse tipo de previsão apresentando um maior índice de erros apenas no verão durante as férias dos funcionários, que se fosse considerado como entrada poderia não ter tido aumento no índice de erro nesse período, pois estes também são considerados fatores que influenciam na curva de demanda.

Müller e Franco (2014) trabalhou com algoritmos de clusterização de dados para realizar previsões com o método de dias similares, dividindo todas as curvas de demanda obtidas, as quais provém de um nível de consumo menos agregado se tratando de um consumidor comercial do ramo alimentício referentes ao inverno dos anos de 2012 e 2013, entre os dias da semana e agrupando-as de acordo com a estação do ano. Devido a problemas técnicos, existiam dados faltantes e aberrantes, no qual foram substituídos pelo cálculo da média do vizinho anterior com o vizinho posterior ou desconsiderados quando era uma sequência de valores faltantes. Os resultados mostraram porcentagens que variam de 9,28% em uma terça-feira e 26,11% em um sábado representados pelo cálculo do MAPE, que foi o critério de avaliação escolhido, assim como em Alves et al. (2016), que apresentou resultados superiores com a utilização de RNA para realizar tal tipo de previsão, obteve

resultados como 15,51% e 13,68%, utilizando a RNA ARTMAP *Fuzzy (Adaptive Resonance Theory)* tradicional e a ARTMAP *Fuzzy* remodelada para realizar as previsões. Ambos consideraram trabalhar com previsões em locais de consumos mais desagregados, o que também é mencionado por Ke, Jiang e Lu (2015) como proposta para trabalhos futuros.

3.2.1 PREVISÃO POR GRNN (*General Regression Neural Network*)

Quando se trata de desenvolver algoritmos previsores de séries temporais em geral, como visto anteriormente as RNA são muito utilizadas e a GRNN é uma das que mostram resultados mais satisfatórios, principalmente quando se trata de previsões de curto prazo, isso se deve as baixas chances de se cair em mínimos locais por ser baseada em uma função densidade de probabilidade e também a sua grande capacidade de generalização. Como exemplo, podemos citar o trabalho de Leng et al. (2013) que foi desenvolvido na China com uma GRNN utilizada para a previsão de curto prazo de tráfego urbano, mostrando superioridade na previsão ao se comparar com as redes neurais *backpropagation* e função de base radial. Já em Anbazhagan, Kumarappan e Gnanaprakasam (2011) foi feita a previsão do preço da energia elétrica para o mercado nacional de eletricidade de Singapura, neste a GRNN mostrou melhor resultado na previsão quando foi adicionado informações sobre o final de semana.

Em Nose-Filho (2011) realizou-se uma previsão de demanda multinodal utilizando a GRNN, pois esta mostrou perfeita adaptabilidade ao dado problema devido a sua capacidade de generalização. Os resultados foram satisfatórios e mostrou-se capaz de prever demanda globais dos dias convencionais e de feriados com a mesma precisão.

O presente trabalho tem como objetivo principal utilizar a GRNN para realizar a previsão de demanda de curto prazo de um local de um nível de consumo mais desagregado, isto é, trata-se de um único bloco de uma universidade onde se encontram instalados diferentes comerciantes do setor de alimentos, o que ocasiona maiores oscilações no consumo da energia elétrica, em consequência disso para avaliar a assertividade das previsões, as mesmas serão avaliadas pelo cálculo MAPE.

3.2.2 AVALIAÇÃO DA PREVISÃO

Na avaliação da assertividade das previsões do presente trabalho será calculado o erro percentual absoluto médio.

Este índice é considerado por concessionárias de energia elétrica como uma forma padronizada para avaliar o desempenho de predições de demanda (MÜLLER, 2014), o que conseqüentemente o torna um dos métodos mais utilizado para a realização do cálculo da precisão das previsões como vimos nos trabalhos citados anteriormente.

O MAPE é calculado de acordo com a Equação (7):

$$MAPE = \frac{100\%}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \quad (7)$$

Em que, A_t representa o valor da demanda real, F_t é o valor da demanda prevista e n é o tamanho da série temporal. Quanto mais baixo o valor do MAPE, significa maior precisão na previsão.

4 CENÁRIO DE ESTUDO

Neste capítulo será detalhado o funcionamento do local onde os dados utilizados neste trabalho são provenientes, mostrando os fatores que influenciam o comportamento da demanda.

4.1 PTI


O PTI (Parque Tecnológico Itaipu) é um centro de ensino e pesquisa em educação, ciência e tecnologia criado em 2003 pela Itaipu Binacional com o objetivo de estimular o progresso das regiões das adjacências da usina e atender às necessidades de modernização das instalações da hidrelétrica. Foi instalado nos galpões que serviram de alojamento para os operários que construíram a usina de Itaipu, na cidade de Foz do Iguaçu – PR, local situado a 180 metros acima do nível do mar, com clima subtropical temperado superúmido. O PTI trabalha a educação nos níveis essenciais para o desenvolvimento social da população, desde a alfabetização até pós-graduação e capacitação tecnológica, onde se encontram ativas por volta de 2 mil pessoas, contando com funcionários, pesquisadores, professores, empresários, etc. e somando todos seus blocos, ocupa a área de 50 mil metros quadrados. Nesse cenário foi inserida uma microrrede inteligente de onde vêm os dados utilizados para o estudo.

O consumo da energia do bloco é calculado com intervalos de quinze minutos, de tal modo que noventa e seis registros determinam uma curva de demanda diária (MÜLLER, 2014). Tais dados foram coletados a partir da instalação de *smart meters* na rede, os quais são programáveis, podendo medir, calcular e visualizar os principais parâmetros das redes elétricas. São coletados dados desde a segunda metade do ano de 2012 e transportados através de uma rede dedicada de par trançado blindado (*Shielded Twisted Pair – STP*) para um servidor onde ficaram armazenados.

O banco de dados utilizado no presente trabalho contém informações como data e hora de cada medição, valores da energia ativa consumida e a temperatura extraídos do medidor instalado no local que se encontra destacado na Figura 1, onde se encontram o restaurante do PTI, uma agência bancária e uma agência dos correios de pequeno porte e um café. Foram acrescentados no banco de dados informações

sobre as estações do ano e dias da semana de acordo com as datas fornecidas pelo medidor.

Figura 2: Blocos de Transformadores do PTI



Fonte: (MÜLLER, 2014).

No restaurante do PTI são servidas em torno de 800 refeições diariamente, variando nos dias em que são realizados eventos no parque e nas férias universitárias, os pratos utilizados são limpos em lava-louças elétrico e o restante da louça é lavada manualmente, o atendimento do restaurante tem início às 11:30h e se encerra as 14:00h, funcionando diariamente incluindo finais de semana, a área do restaurante destinada aos consumidores é superior a 1200 metros quadrados e é climatizada no verão. Existem de 30 a 40 funcionários fixos trabalhando no restaurante, dentre cozinheiros, auxiliares administrativo, caixas, equipe de limpeza, entre outros, no qual seu expediente inicia entre as 8:00h e 8:30h, finalizando entre as 17:30h e 18:00h. Junto ao bloco do restaurante existe uma agência bancária de porte pequeno com quatro funcionários aproximadamente e com expediente entre as 10:00h e 15:00h, uma agência dos correios com dois funcionários e horário de atendimento ao cliente entre as 8:00h e 17:30h, fechando para almoço entre 12:00h e 13:30h e ainda um café com horário de atendimento entre as 8:00h e 18:00h (MÜLLER, 2014).


4.1 COMPORTAMENTO DA DEMANDA

A verificação e validação dos dados que serão utilizados em previsões de qualquer natureza, é uma tarefa importante a ser realizada antes que a previsão em si seja feita, o que possibilita que os dados sejam facilmente interpretados através de informações gráficas, identificando se eles seguem algum padrão ou não e também permitindo que dados anormais sejam identificados.

As curvas de demanda diárias foram agrupadas de acordo com as estações do ano e os dias da semana, considerando apenas as que envolvem o verão dos anos de 2012 e 2013. Valores faltantes foram alterados pela média do valor anterior com o valor posterior e os dias que possuem dados faltantes em excesso devidos a problemas técnicos nos medidores foram desconsiderados.


O comportamento das curvas de demanda é apresentado pelos gráficos exibidos pelas Figuras 3 a 21.

Figura 3: Segundas-feiras originais medidas.




Fonte: Elaboração da própria autora.

Figura 4: Segundas-feiras depois de desconsiderar dias com dados faltantes em excesso.



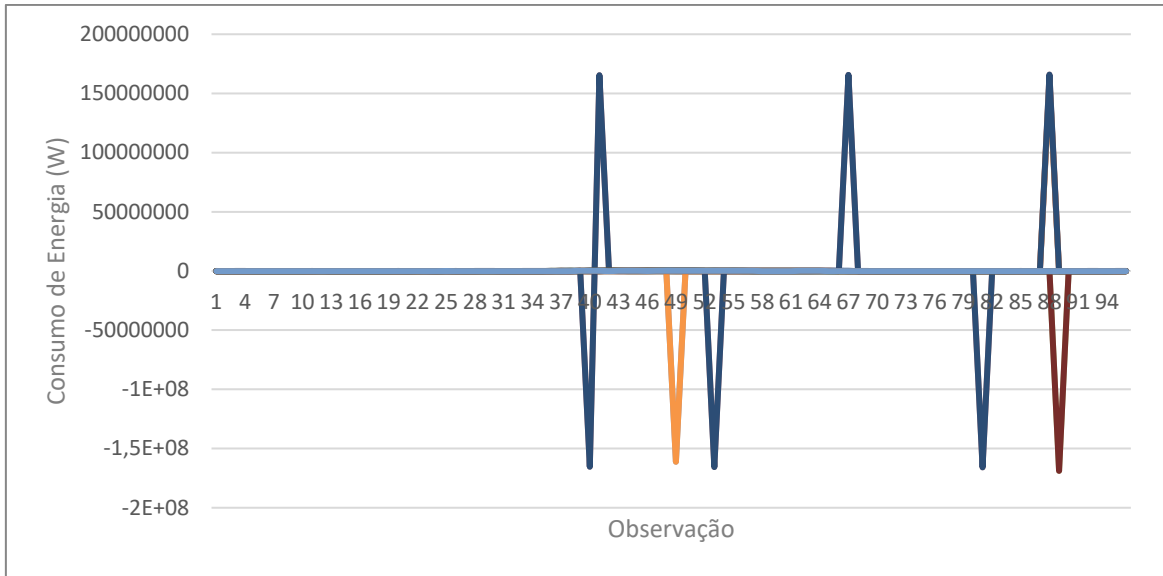
Fonte: Elaboração da própria autora.

Figura 5: Curvas de Demanda: Segundas-feiras.




Fonte: Elaboração da própria autora.

Figura 6: Terças-feiras originais medidas.




Fonte: Elaboração da própria autora.

Figura 7: Terças-feiras depois de desconsiderar dias com dados faltantes em excesso.




Fonte: Elaboração da própria autora.

Figura 8: Curvas de demanda: Curvas de Demanda: Terças-feiras




Fonte: Elaborado pela própria autora.

Figura 9: Quartas-feiras originais medidas.




Fonte: Elaboração da própria autora.

Figura 10: Quartas-feiras depois de desconsiderar dias com dados faltantes em excesso.




Fonte: Elaboração da própria autora.

Figura 11: Curvas de Demanda: Quartas-feiras




Fonte: Elaboração da própria autora.

Figura 12: Quintas-feiras originais medidas.




Fonte: Elaboração da própria autora.

Figura 13: Curvas de Demanda: Quintas-feiras



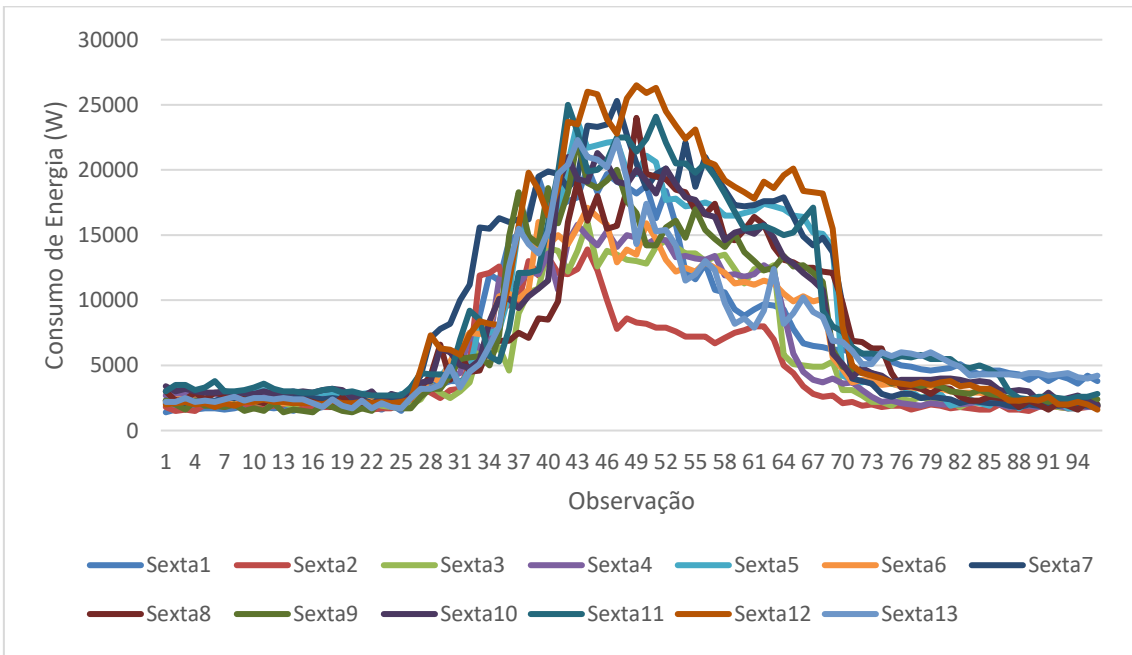
Fonte: Elaboração da própria autora.

Figura 14: Sextas-feiras originais medidas.




Fonte: Elaboração da própria autora.

Figura 15: Curvas de Demanda: Sextas-feiras




Fonte: Elaboração da própria autora.

Figura 16: Sábados originais medidas.




Fonte: Elaboração da própria autora.

Figura 17: Sábados depois de desconsiderar dias com dados faltantes em excesso.




Fonte: Elaboração da própria autora.

Figura 18: Curvas de Demanda: Sábados




Fonte: Elaboração da própria autora.

Figura 19: Domingos originais medidos.




Fonte: Elaboração da própria autora.

Figura 20: Domingos depois de desconsiderar dias com dados faltantes em excesso.



Fonte: Elaboração da própria autora.

Figura 21: Curvas de Demanda: Domingos



Fonte: Elaboração da própria autora.

Analisando o comportamento das curvas de demanda obtidas, nota-se que qualquer evento incomum em um determinado dia da semana, como a mudança

imprevista de temperatura, feriados, eventos festivos, entre outros é capaz de provocar alterações notáveis no comportamento das curvas de demanda.

É importante ainda observar que o local onde foi instalada a microrrede manifesta temperatura inconstante, variando quase 20°C ao decorrer de um único dia do verão em questão, mostrando 34°C de manhã e chegando a medir 53,4°C na parte da tarde. O medidor está localizado em ambiente externo, logo, o mesmo se encontrava exposto ao tempo, o que faz com que o calor e o frio sejam absorvidos pelo mesmo com facilidade e o material no qual foi fabricado a caixa onde o medidor se encontra é o metal, esses fatos fazem com que medições realizadas podem ser contaminadas.

4.3 PRÉ-PROCESSAMENTO DOS DADOS

Como observado por Ke, Jiang e Lu (2016), a qualidade dos dados é importante e é indispensável levar isto em consideração quando o objetivo é obter resultados precisos e confiáveis na previsão.

A microrrede inteligente inserida no PTI é de boa qualidade e é apta a coletar dados com precisão e rapidez devido à alta tecnologia que possui. Ainda assim é provável que falhas ocorram em qualquer ponto do sistema, resultando em ruídos e dados faltantes. Isso faz com que o comportamento original da demanda é comprometido, prejudicando assim a capacidade de generalização das RNAs (KIARTZIS et al., 1996) que por sua vez mostram previsões equivocadas em pontos inesperados.

Para isso foi utilizado um filtro de médias móveis com o propósito de diminuir ruídos e dados anormais e recuperar os dados faltantes para que exista maior exatidão nas previsões feitas pela RNA. O único parâmetro a ser controlado é o valor da janela α , que é o que define o número de amostras que será utilizado para o cálculo da janela móvel. A média móvel é calculada por meio da equação (8) e a correção do valor que é atrasado do valor original é feito através da equação (9), desde que seja um número ímpar (NOSE-FILHO, 2011).

$$\overline{FL1}_i = \frac{1}{n} \sum_{j=i-\alpha+1}^i FL1_j \quad (8)$$

$$FL2_i = \overline{FL1}_{(t+0.5\alpha-0.5)} \quad (9)$$

Ao utilizar este filtro as curvas de demanda serão suavizadas e os dados faltantes serão completados e os ruídos corrigidos. Isto será observado no capítulo de resultados.

Foram testados para a janela α os valores 1, 3 e 5. O valor 3 foi escolhido pelo fato de que o valor 1 não mostrava diferença significativa depois que a rede foi treinada com os valores resultantes do filtro com o uso dessa janela pois eram parecidos aos originais. Já o valor 5 proporcionou uma grande suavização nas curvas diárias, o que foi considerado um pouco fora da realidade, sendo o valor 3 a melhor opção.

5 RESULTADOS

Este capítulo apresenta os resultados obtidos pelo método proposto, rede neural de regressão generalizada, nas previsões de demanda elétrica de locais de consumo menos agregados.

Foram realizadas previsões de demanda diária, de cada dia da semana separadamente, realizando o treinamento da rede com o banco de dados que possui as informações que foram coletadas pela microrrede sem passar por um pré-processamento como é apresentado na seção 3.2 deste trabalho e também a previsão global com o mesmo banco de dados de treinamento, porém incluindo todos os dias que compreendem o verão em questão para o treinamento, excluindo o último dia que será o dia previsto, resultando em um total de 80 dias para o treinamento, prevendo o próximo. Depois foi realizado o treinamento da mesma rede com a apresentação dos dados após sua passagem pelo filtro. Para avaliar o desempenho da RNA utilizada nas previsões foi aplicado o índice de erro percentual absoluto médio (MAPE).

A Tabela 1 apresenta os valores do MAPE para as previsões de cada dia da semana mostrando a porcentagem de erro das previsões no período de 24 horas sem a aplicação do pré-processamento dos dados e depois da aplicação.

Tabela 1: Cálculo do MAPE

Dia da Semana	Cálculo do MAPE (%)	
	Sem pré-processamento	Com pré-processamento
Segunda-feira	15,08	7,63
Terça-feira	15,30	7
Quarta-feira	12,67	7,71
Quinta-feira	20,15	7,79
Sexta-feira	14,51	6,21
Sábado	13,20	6,77
Domingo	14,54	5,52


Fonte: Elaboração da própria autora.

Em seguida serão apresentados os resultados de forma gráfica dos resultados das previsões para melhor visualização e compreensão dos índices de erro obtidos.

5.1 RESULTADOS GRÁFICOS DAS PREVISÕES

A Figura 22 apresenta a previsão realizada para uma segunda-feira a frente das outras utilizadas no treinamento. Como mostrado no Capítulo 3, existem onze segundas-feiras, sendo dez delas utilizadas para o treinamento da rede, que previu uma a frente, apresentando um percentual de erro médio de 15,08% da segunda-feira real, que é representada pela linha vermelha no gráfico. A demanda prevista é representada pelas linhas azuis.


Figura 22: Previsão para segunda-feira seguinte



Fonte: Elaboração da própria autora.

Já na Figura 23 é mostrada a previsão realizada para as terças-feiras, onde dez delas foram utilizadas para treinar a rede e uma para a comparação da previsão, mostrando também um percentual de erro médio de 15,30%.


Figura 23: Previsão para terça-feira seguinte



Fonte: Elaboração da própria autora.

A previsão realizada para a quarta-feira seguinte mostrou um resultado melhor ao se comparar aos anteriores, como vemos na Figura 24, sendo de 12,67% o erro médio obtido ao ser comparado a real. Foram utilizadas doze quartas-feiras no treinamento da rede, para prever a décima terceira quarta-feira.


Figura 24: Previsão para quarta-feira seguinte



Fonte: Elaboração da própria autora.

Já para as quintas-feiras foi obtido um erro percentual médio de 20,15%, o que é uma porcentagem muito grande ao se comparar com as anteriores. Neste foram utilizadas onze semanas para a entrada da rede e a previsão foi realizada para a quinta-feira seguinte, mostrada pela Figura 25.

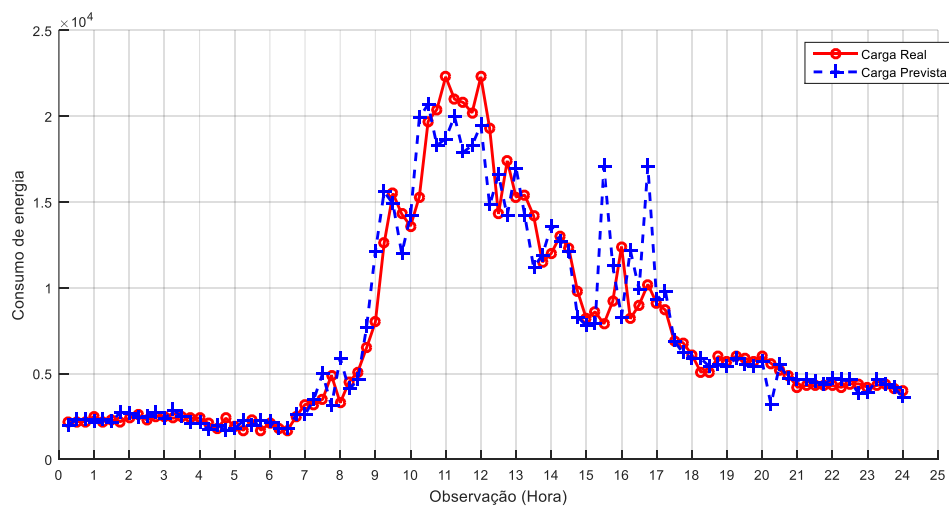
Figura 25: Previsão para quinta-feira seguinte



Fonte: Elaboração da própria autora.

Nas sextas-feiras foi obtido o erro percentual médio de 14,51%, onde foram utilizadas doze semanas para o treinamento da rede e a seguinte foi prevista, pode-se observar a previsão apresentada pelas curvas da Figura 26.


Figura 26: Previsão para sexta-feira seguinte



Fonte: Elaboração da própria autora.

A Figura 27 apresenta a previsão feita para o sábado seguinte, sendo utilizada para o treinamento da rede nove sábados, prevendo o seguinte. Nesta previsão foi obtido um erro percentual médio de 13,20%. Nota-se que as curvas de demanda dos finais de semana se comportam de maneira diferente das outras, isto ocorre devido ao número de pessoas que utilizam o bloco em questão nesses dias, que, embora sejam finais de semana e não exista atividades escolares, o comércio existente no mesmo ainda funciona.


Figura 27: Previsão para o sábado seguinte



Fonte: Elaboração da própria autora.

Na previsão feita para o domingo seguinte é apresentada pela Figura 28, onde foi obtido um percentual de erro médio de 14,54%, utilizando dez domingos para o treinamento e o seguinte para comparação da previsão.


Figura 28: Previsão para o domingo seguinte



Fonte: Elaboração da própria autora.

Na Figura 29 é apresentada a previsão global do bloco em questão, tendo como entrada além das noventa e seis medições diárias, os dias da semana. Foram considerados oitenta dias para o treinamento da rede e o próximo para realizar a comparação com o resultado obtido pela previsão, resultando em 12,33% no cálculo do erro percentual médio.

Figura 29: Previsão global



Fonte: Elaboração da própria autora.

Foram computados dados de oitenta e nove dias referentes ao verão em questão, mas oito deles foram desconsiderados por possuírem dados faltantes ou aberrantes em excesso, o que poderia ser confundido na previsão feita pela rede.

Os resultados mostram uma média de aproximadamente 15% dos MAPEs obtidos quando a rede foi treinada para cada dia da semana específico, e quando foram inseridos na rede dados de todos os dias considerados, mostrou um resultado de 12,33%. Levando em consideração que o dia seguinte é uma quarta-feira, os resultados da previsão foram muito parecidos ao se comparar com os resultados obtidos das quartas-feiras treinadas separadamente, e um pouco mais otimistas, embora a curva se comporte um pouco diferente em alguns pontos.


Observando os presentes resultados é fundamental levar em consideração o local de onde os dados analisados são provenientes, pois por ser um bloco onde se encontram comércios do ramo alimentício, apresenta grande variação de consumo de energia elétrica no decorrer do dia, e o fato de que a microrrede é armazenada em uma caixa cujo material é o metal faz com que a temperatura também varie absurdamente em apenas um dia, o que afeta diretamente nas previsões, pois a RNA aprende o comportamento da demanda analisada e quando ela sofre esse tipo de interferência, é registrado no aprendizado da rede e conseqüentemente pode resultar em uma previsão equivocada. Com objetivo de melhorar os resultados das previsões, os mesmos dados utilizados anteriormente passaram pelo filtro de médias móveis e depois foi feita a previsão com os resultados obtidos do filtro.

5.2 COMPARAÇÃO DOS DIAS COMUNS E DIAS FILTRADOS

Toda a demanda utilizada para treinamento e para previsão anteriormente passou pelo filtro, inclusive aquelas que foram retiradas para estas previsões, que foram os dias nos quais existiam dados faltantes em excesso. Foram selecionados sete dias para fins comparativos, que são todos os dias da semana seguinte, ou seja, a semana selecionada para a previsão. Nas Figuras 30 a 36 são apresentadas graficamente as curvas de demanda diárias antes e depois de passarem pelo filtro para fins comparativos, onde a linha vermelha de cada figura representa a demanda real, estas são as mesmas linhas vermelhas dos gráficos anteriores mostrados nas Figuras 22 a 28, as quais indicam a Saída Real que foi utilizada para comparar as


saídas das previsões feitas pela rede antes do filtro, e novamente nas Figuras 30 a 36, a linha azul de cada figura indica a curva resultante da saída do filtro, que são as linhas utilizadas para comparar com os dias previstos pela rede depois de ser treinada com os dados processados, os resultados das previsões são apresentados nas Figuras 24 a 30 pela linha vermelha de cada figura como Demanda Real.

Figura 30: Curvas de demanda de segunda-feira original e filtrada



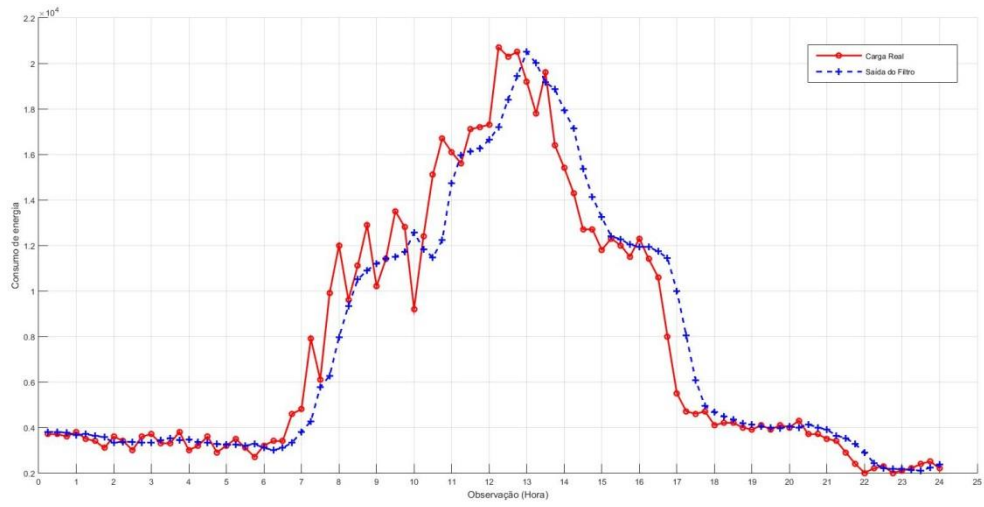
Fonte: Elaboração da própria autora.

Figura 31: Curvas de demanda de terça-feira original e filtrada




Fonte: Elaboração da própria autora.

Figura 32: Curvas de demanda de quarta-feira original e filtrada




Fonte: Elaboração da própria autora.

Figura 33: Curvas de demanda de quinta-feira original e filtrada




Fonte: Elaboração da própria autora.

Figura 34: Curvas de demanda de sexta-feira original e filtrada




Fonte: Elaboração da própria autora.

Figura 35: Curvas de demanda de sábado original e filtrada



Fonte: Elaboração da própria autora.

Figura 36: Curvas de demanda de domingo original e filtrada



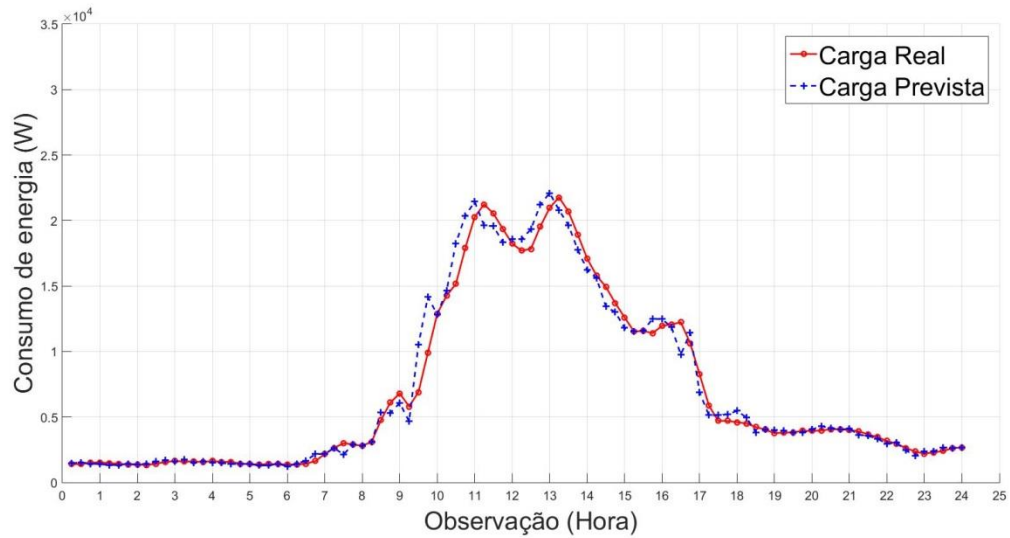
Fonte: Elaboração da própria autora.

5.3 RESULTADOS OBTIDOS APÓS O PRÉ-PROCESSAMENTO DOS DADOS

Depois da utilização do filtro de médias móveis na execução do pré-processamento dos dados fornecidos pelo medidor foram levados em consideração para o treinamento da rede com o banco de dados completo do verão em questão, incluindo todos os dados dos dias retirados anteriormente por dados faltantes em excesso, com isso a rede alcançou um melhor conjunto de resultados, que serão mostrados a seguir.

A Figura 37 apresenta a previsão da segunda-feira seguinte, ao se comparar com a previsão anterior para a mesma segunda-feira observa-se a considerável diminuição dos picos na previsão, o que resultou em um MAPE de 7,63%.


Figura 37: Previsão para Segunda-feira seguinte com pré-processamento de dados



Fonte: Elaboração da própria autora.

A previsão para a terça-feira seguinte apresentada pela Figura 38 mostra a linha de demanda prevista acompanhando a linha de demanda real com maior facilidade levando em consideração a quantidade de resultados equivocados que a rede apresentou anteriormente, isso reduziu o índice de erro percentual para 7%.


Figura 38: Previsão para Terça-feira seguinte com pré-processamento de dados



Fonte: Elaboração da própria autora.

O erro produzido pela previsão da quarta-feira seguinte foi de 7,71%. Ao observar o gráfico ilustrado na Figura 39, percebe-se ainda a presença de alguns picos na previsão, isso se deve ao fato de que, de acordo com a observação do comportamento da demanda feita anteriormente, nas quartas-feiras as curvas têm maior variação no decorrer do dia e apresenta alguns picos fora do comum.

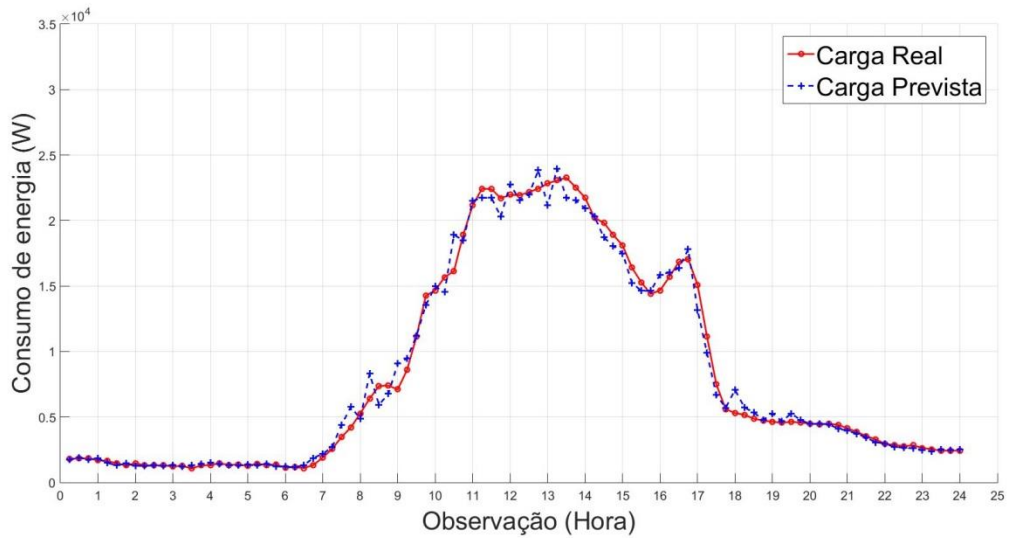
Figura 39: Previsão para Quarta-feira seguinte com pré-processamento de dados



Fonte: Elaboração da própria autora.

A previsão para a quinta-feira seguinte foi a que atingiu o aumento de precisão mais significativo na previsão, a curva é ilustrada na Figura 40 e apresenta a queda do índice de erro percentual de 20,15% para 7,79%.


Figura 40: Previsão para Quinta-feira seguinte com pré-processamento de dados



Fonte: Elaboração da própria autora.

Na previsão da sexta-feira seguinte foi obtido um erro percentual médio de 6,21%, observa-se as curvas de demanda na Figura 41.

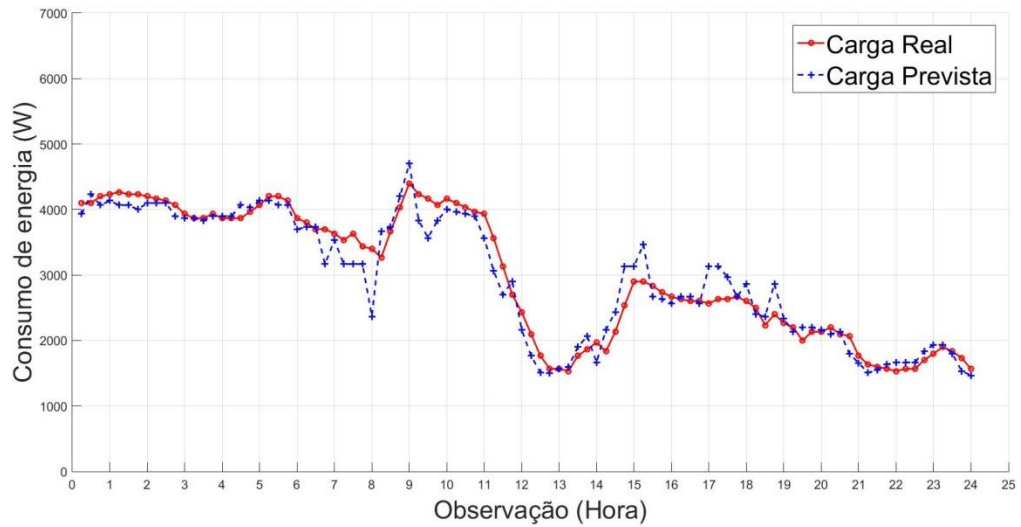
Figura 41: Previsão para Sexta-feira seguinte com pré-processamento de dados



Fonte: Elaboração da própria autora.

A Figura 42 mostra a previsão para o sábado seguinte apresentando um erro percentual médio de 6,77%.


Figura 42: Previsão para o Sábado seguinte com pré-processamento de dados



Fonte: Elaboração da própria autora.

A previsão realizada para o domingo seguinte mostrada pela Figura 43, mesmo com a apresentação de alguns picos é a que teve maior precisão, apresentando um MAPE de 5,52%.

Figura 43: Previsão para o Domingo seguinte com pré-processamento de dados



Fonte: Elaboração da própria autora.

Aplicando o pré-processamento no banco de dados dessa forma, os resultados melhoraram significativamente como pode ser observado nos MAPEs apresentados na Tabela 2.

Tabela 2: MAPEs diários mínimos, médios e máximos obtidos na previsão de demanda global

Dia da Semana	Cálculo do MAPE (%)	
	Sem pré-processamento	Com pré-processamento
Mínimo	12,67	5,52
Médio	15,06	6,94
Máximo	20,15	7,79

Fonte: Elaboração da própria autora.

Os MAPEs obtidos na previsão sem a aplicação do filtro obtiveram alguns resultados que ainda mostram superioridade ao se comparar com alguns trabalhos científicos onde fazem previsões de locais desagregados. Depois da aplicação do filtro, foi obtido resultados melhores que ao se comparar com trabalhos encontrados na literatura especializada se mostram compatíveis e ainda podem ser melhorados.

6 CONSIDERAÇÕES FINAIS

Neste trabalho foram apresentados resultados de previsão de demanda por RNAs. Utilizou-se a GRNN para este problema pelo fato de os dados serem proveniente de um local de nível menos agregado, e por essa rede ser baseada em uma função de densidade de probabilidade possui baixas chances de cair em mínimos locais, mostrando resultados muito melhores ao se comparar a outras redes testadas anteriormente no mesmo problema.

O filtro utilizado se mostrou muito eficiente na redução de ruídos e substituição dos dados faltantes.

Mesmo antes do pré-processamento dos dados a rede apresentou resultados melhores do que os apresentados por outros trabalhos na mesma linha como Müller e Franco (2014) alcançou a média percentual de precisão nas previsões diárias entre 9,28% e 29,99 utilizando diferentes métodos, Yu, Mirowski e Ho (2016) alcançou MAPEs entre 19,79% e 32,55% e também em Alves et al. (2016) que apresentou erros percentuais médios entre 13,68% e 15,51%. Na literatura se encontra previsões de demanda com MAPEs diários compatíveis com os apresentados neste trabalho após o tratamento dos dados, que possuem médias menores de 7%.

Já foram feitas previsões utilizando a mesma rede em outros trabalhos, no qual foram obtidos índices de erros percentuais quase nulos, o que torna a previsão de demanda de níveis de consumo mais desagregados um desafio para pesquisadores da área.

Sendo assim pode ser feita uma proposta para trabalho futuro como: previsão de demanda elétrica de dados provenientes dos níveis mais desagregados considerando o desenvolvimento e utilização de outras técnicas de tratamento dos dados para previsão com a consideração de arquiteturas híbridas baseadas na GRNN, ou outras arquiteturas de redes neurais e posterior comparação com os resultados obtidos no presente trabalho.

REFERÊNCIAS

- ABREU, T. A. S. **Previsão de demanda elétrica através de um modelo híbrido de regressão com redes neurais**. 62 f. 2012. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Estadual Paulista – UNESP, Ilha Solteira, 2012.
- ALVES, M. F.; MÜLLER, M. R., LOTUFO; A. D. P.; LOPES, M. L. M. Aplicação de redes neurais artificiais baseadas na teoria da ressonância adaptativa na previsão de curtíssimo prazo em níveis menos agregados. In: CONGRESSO BRASILEIRO DE AUTOMÁTICA - CBA, 2016, Vitória. **Anais...** Vitória: [s. n.], 2016. p.924-929.
- ANDERSEN, F.M.; LARSEN, H.V.; BOOMSMA, T.K. Long-term forecasting of hourly electricity load: Identification of consumption profiles and segmentation of customers, **Energy Conversion and Management**, London, v. 68, p. 244-252, 2013.
- ANBAZHAGAN, S.; KUMARAPPAN, N.; GNANAPRAKASAM, A. Temporal input based day-ahead price forecasting in asia's first liberalized electricity market using GRNN. In: CHENNAI AND DR. MGR UNIVERSITY SECOND INTERNATIONAL CONFERENCE ON SUSTAINABLE ENERGY AND INTELLIGENT SYSTEM (SEISCON 2011), 2011, Tamil Nadu - India. **Anais...** Chennai: IET, 2011. p. 42-46.
- BAGNASCO, A.; FRESI, F.; SAVIOZZI, M.; SILVESTRO, F.; VINCI, A. Electrical consumption forecasting in hospital facilities: an application case. **Energy and Buildings**, Amsterdam, v. 103, p. 261-270, 2015.
- BOX, G. E.; JENKINS, G. M. **Times series analysis: forecasting and control**. San Francisco: Holden-Day, 1976.
- BROWN, R. E. Impact of Smart Grid on Distribution System Design. **IEEE Power Engineering Society General Meeting**, Piscataway, p. 1-4, 2008.
- CHIN, H.; TANAKA, K.; ABE, R. An analytical evaluation of Top-Down versus Bottom-Up forecast in the electricity demand. In: IEEE INTERNATIONAL CONFERENCE ON CONSUMER ELECTRONICS-TAIWAN (ICCE-TW), 2016, Taiwan.. **Anais...** Nantou: IEEE, 2016. p. 1-2.
- CHO, H. S.; YAMAZAKI, T.; HAHN, M. Determining location of appliances from multi-hop tree structures of power strip type smart meters. **IEEE Transactions on Consumer Electronics**, New York, v. 55, n. 4, p. 2314-2322, 2009.
- DATTA, D.; TASSOU, S. A.; MARRIOTT, D. **Application of neural networks for the prediction of the energy consumption in a supermarket**. Middlesex: Brunel University Uxbridge, 2000. p. 1-10.

- DEILAMI, S.; MASOUM, A. S.; MOSES, P. S.; MASOUM, M. A. S. Real-time coordination of plug-in electric vehicle charging in smart grid to minimize power losses and improve voltage profile. **IEEE Transactions on Smart Grid**, Piscataway, v. 2, n. 3, p. 456-467, 2011.
- DEBNATH, K. B.; MOURSHED, M.; CHEW, S. P. K. Modeling and forecasting energy demand in rural households of Bangladesh. **Energy Procedia**, Amsterdam, n. 75, p. 2731-2737, 2015.
- ESCRIVÁ-ESCRIVÁ, G.; ÁLVAREZ-BEL, C.; ROLDÁN-BLAY, C.; ALCÁZAR-ORTEGA, M. New artificial neural network prediction method for electrical consumption forecasting based on building end-uses. **Applied Energy**, Amsterdam, v. 144, p. 3112-3119, 2011.
- FALCÃO, D. M. Smart grid e microredes: o futuro já é presente. In: SIMPÓSIO DE AUTOMAÇÃO E SISTEMAS ELÉTRICOS, 8., 2009, Rio de Janeiro. **Anais...** Rio de Janeiro: [s. n.], 2009. p. 1-11.
- FERLITO, S.; ATRIGNA, M.; GRADITI, G.; DE VITO, S.; SALVATO, M. BUONANNO, A.; DI FRANCIA, G. Predictive models for building's energy consumption: an Artificial Neural Network (ANN) approach. In: AISEM ANNUAL CONFERENCE, 18., 2015, Trento - Italy. **Proceedings...** New York: IEEE, 2015. p. 1-4.
- FREITAS, L. P. S. **Previsão da variabilidade da emissão de co2 do solo em áreas de cana-de-açúcar utilizando redes neurais artificiais**. 2016. Tese (Doutorado) –Faculdade de Engenharia, Universidade Estadual Paulista “Júlio de Mesquita Filho” – UNESP, 2016.
- GIRI, J.; SUN, D.; AVILA-ROSALES, R. WANTED: a more intelligent grid. **IEEE Power & Energy Magazine**, Piscataway, v. 7, n. 2, p. 34-40, 2009.
- GROSS, G.; GALIANA, F. D. Short-Term load forecasting. **Proceedings of the IEEE**, New York, v. 75, n. 12, p. 1558-1573, 1987.
- GULIN, M.; VASAK, M.; BANJAC, G.; TOMISA, T. Load forecast of a university building for application in microgrid power flow optimization. In: ENERGYCON, 2014, cidade de realização. **Pocceedings...** New York: IEEE, 2014. p. 13-16.
- HANDSCHIN E.; DÖRNEMANN, C. H. Bus load modeling and forecasting. **IEEE Transactions on Power Systems**, New York, v. 3, n. 2, p. 627-633, 1988.
- HANI, A.; KOIV, T-A. Energy Consumption monitoring analysis for residential, educational and public buildings. **Smart Grid and Renewable Energy**, Irvine, n. 3, p. 231-238, 2012.
- HAYKIN, S. **Neural networks and learning machines**. 3. ed. New Jersey: Prentice-Hall, 2008.

HAYKIN, S. **Neural networks: a comprehensive foundation**. Upper Saddle River: Prentice-Hall, 1994.

JECHEVA, J. G.; MAJIDPOUR, M.; CHEN, W.P. Neural network model ensembles for building-level electricity load forecasts. **Energy and Buildings**, Amsterdam, p. 214-223, 2014.

KE, X.; JIANG, A.; LU, N. Load profile analysis and short-term building load forecast for a university campus. In: POWER AND ENERGY SOCIETY GENERAL MEETING (PESGM), 2016, Boston – MA – USA. **Proceedings...** Piscataway: IEEE, 2016.

KHUNTIA, S. R.; van der MEIJDEN, M. A. M. M. Neural network-based load forecasting and error implication for short-term horizon. In: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS (IJCNN), 2016, Vancouver - Canada. **Proceedings...** Piscataway: IEEE, 2016. p. 4970-4975.

KIARTZIS, S. J.; ZOUMAS, C.E.; BAKIRTZIS, A.G.; PETRIDIS, V. Data pre-processing for short-term load forecasting in an autonomous power system using artificial neural networks. In: IEEE INTERNATIONAL CONFERENCE ON ELECTRONICS, CIRCUITS, AND SYSTEMS – ICECS, 3., 1996, New York. **Proceeding...** Piscataway: IEEE, 1996. v. 2, p. 1021-1024.

LEITE, J.B. **Desenvolvimento de um Sistema de Gerenciamento de Energia (EMS – Energy Management System) para a Rede Elétrica Inteligente (Smart Grid)**. 2015. 168 f. Tese (Doutorado em Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista - UNESP, Ilha Solteira, 2015.

LENG, L.; GAO, J.; QIN, Y.; LIU, X.; YIN, J. Short-term forecasting model of traffic flow based on GRNN. In: CONTROL AND DECISION CONFERENCE (CCDC), 25., 2013, Guiyang. **Proceedings...** Piscataway: IEEE, 2013. p. 3816-3820.

LIM, J. H.; KWON O. S.; SONG, K. B.; PARK, J. D. Short-term load forecasting for educational buildings with temperature correlation. In: INTERNATIONAL CONFERENCE ON POWER ENGINEERING, 4., 2013, Istanbul. **Proceedings...** Piscataway: IEEE, 2013. p. 405-408.

LÜ, X.; LU, T.; KIBERT, C. J.; VILJANEN, M. Modeling and forecasting energy consumption for heterogeneous buildings using a physical–statistical approach, **Applied Energy**, Kidlington, v. 144, p. 261-275, 2015.

MASSANA, J.; POUS, C.; BURGAS, L.; MELENDEZ, J.; COLOMER, J. Short-term load forecasting in a non-residential building contrasting models and attributes. **Energy and Buildings**, Amsterdam, v. 92, p. 322-330, 2015.

MOTTA, L.T. M. **Métodos de previsão do comportamento da demanda na recomposição de sistemas de energia elétrica**. 2005. 183. Tese (Doutorado) - Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas -UNICAMP, Campinas, 2005.

MÜLLER, M. R.; FRANCO, E. M. C. Clusterização de curvas de demanda para o método de dias similares. In: SIMPÓSIO BRASILEIRO DE SISTEMAS ELÉTRICOS – SBSE, 2014, Foz do Iguaçu/PR. **Proceedings...** Foz do Iguaçu/PR: Anais do V Simpósio Brasileiro de Sistemas Elétricos,, 2014. p. 1-6.

MÜLLER, M. R. Agrupamento de curvas de demanda para redução de bases de dados utilizadas na previsão de demanda de curto prazo. 2014. 78 f. Dissertação (Mestrado) – Universidade Estadual do Oeste do Paraná, Foz do Iguaçu/PR, 2014.

NIU, D. X.; WANG, H. Q.; GU, Z. H. Short-term load forecasting using general regression neural network. In: INTERNATIONAL CONFERENCE ON MACHINE LEARNING AND CYBERNETICS, 2005, Guangzhou. **Proceedings...** Piscataway: IEEE, 2005. v. 7, p. 4076-4082.

NOSE-FILHO, K.; LOTUFO, A. D. P.; MINUSSI C. R. Processing data for short-term load forecasting with a general regression neural network and a moving average filter. In: IEEE TRONDHEIM POWERTECH, 2011, Trondheim. **Proceedings...** Piscataway: IEEE, 2011. p. 1-7.

NOSE-FILHO, K. **Previsão de demanda multinodal utilizando redes neurais de regressão generalizada**. 2011. 90 f. Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista - UNESP, Ilha Solteira, 2011.

OLIVEIRA, R. D.; VIEIRA JÚNIOR, J. C. M. Benefícios e desafios de redes inteligentes. **Revista Eletrônica de Energia**, Salvador, v. 2, n. 1, p. 3-14, Universidade de Salvador, Salvador, 2012.

PATEL, H.; PANDYA, M.; AWARE, M. Short term load forecasting of indian system using linear regression and artificial neural network. IN: NIRMA INTERNATIONAL CONFERENCE ON ENGINEERING (NUICONE), 5., 2015, Ahmedabad. **Proceedings...** Piscataway: IEEE, 2015. p. 1-5.

PENYA, Y. K.; BORGES, C. E.; AGOTE, D.; FERNÁNDEZ, I. Short-term Load Forecasting in Air-Conditioned Non-Residential Buildings, IEEE, p. 1359-1364, 2011.

RASMUSSEN, L. B.; BACHER, P.; MADSEN, H.; NIELSEN, H. A. HEERUP, C.; GREEN, T. Load forecasting of supermarket refrigeration. **Applied Energy**, Kidlington, v. 163, p. 32-40, 2016.

RAZA, Q. M.; KHOSRAVI, A. A review on artificial intelligence based load demand forecasting techniques for smart grid and buildings. **Renewable and Sustainable Energy Reviews**, v. 50, p. 1352–1372, 2015.

SANDELS, C.; BRODÉN, D.; WIDÉN, J.; NORDSTRÖM, L.; ANDERSSON, E. Modeling office building consumer load with a combined physical and behavioral approach: simulation and validation. **Applied Energy**, Kidlington, v. 162, p. 472-485, 2016.

SANTOS, F. L.; LOTUFO, A. D. P.; MACIEL, G. F.; REIS, M. T.; FORTES, C. J. Rede ARTMAP nebulosa aplicada ao estudo de agitação marítima no porto de sines/portugal. In: CONGRESSO BRASILEIRO DE INTELIGÊNCIA COMPUTACIONAL, 11., 2013, Porto de Galinhas. **Proceedings...** Porto de Galinhas: BRICS-CCI & CBIC, 2013. p. 1-6.

SPECHT, D. F. A generalized regression neural network, **IEEE Transactions on Neural Networks**, New York, v. 2, p. 568-576, 1991.

TOURETZKY, C. R.; PATIL, R. Building-level power demand forecasting framework using building specific inputs: development and applications. **Applied Energy**, Kidlington, v. 147, p. 466-477, 2015.

VISCONTI, I. F. **Modelos de demanda baseados em medições para simulações dinâmicas em sistemas elétricos de potência**. 2010. 125 f. Dissertação (Mestrado em Engenharia Elétrica) - Pontifícia Universidade Católica - PUC-Rio, Rio de Janeiro, 2010.

WERBOS, P. J. Beyond regression: new tools for prediction and analysis in the behavioral sciences. 1974. 906 f. Thesis (PhD) - Harvard University, Cambridge, 1974.

YANG, H-P.; WANG, H.; YAN, F-F.; ZHANG, L. Short-term load forecasting based on data mining. **EEE INTERNATIONAL CONFERENCE ON COMPUTER SUPPORTED COOPERATIVE WORK IN DESIGN**, 20., **Proceedings...** Piscataway: IEEE, 2016. p. 170-173.

YU, C. N.; MIROWSKI, P.; HO, T. K. A sparse coding approach to households electricity demand forecasting in smart grids. **IEEE Transactions on Smart Grid**, Piscataway, v. PP, n. 99, p. 1-11, 2016.