



Universidade Federal do ABC  
Centro de Engenharia, Modelagem e Ciências Sociais Aplicadas  
Programa de Graduação em Engenharia de Informação

# **Previsão de Cargas Elétricas por meio de Redes Neurais de Regressão Generalizada**

**Vítor Miguel Martins**

**Santo André - SP**

**2021**

Vítor Miguel Martins

# **Previsão de Cargas Elétricas por meio de Redes Neurais de Regressão Generalizada**

Monografia apresentada ao curso de graduação da Universidade Federal do ABC, como requisito parcial para obtenção do grau de Bacharel em Engenharia de Informação

Universidade Federal do ABC – UFABC

Centro de Engenharia, Modelagem e Ciências Sociais Aplicadas

Trabalho de Graduação em Engenharia de Informação

Orientador: Prof. Dr. Kenji Nose Filho

Santo André - SP

2021

---

Vítor Miguel Martins

Previsão de Cargas Elétricas por meio de Redes Neurais de Regressão Generalizada.  
Santo André - SP, 2021- p. :45

Orientador: Prof. Dr. Kenji Nose Filho

Monografia – Universidade Federal do ABC – UFABC  
Centro de Engenharia, Modelagem e Ciências Sociais Aplicadas  
Trabalho de Graduação em Engenharia de Informação, 2021.

1. Redes Elétricas Inteligentes. 2. Inteligência Artificial.  
3.Redes Neurais Artificiais. 4. Previsão de Cargas Elétricas.

---

# Resumo

A previsão de cargas elétricas é uma atividade fundamental para o planejamento das companhias de energia elétrica uma vez que esta garante a eficiência e eficácia do processo de geração e distribuição de energia elétrica. Nos últimos anos, com a geração de uma vasta quantidade de dados oriundos da implementação de redes inteligentes e desenvolvimento de tecnologias de Big Data, tornou-se possível realizar esta previsão de forma desagregada, uma vez que a informação é obtida de maneira cada vez mais granular e discriminada. As técnicas de Inteligência Artificial têm ganhado destaque nesta tarefa visto que são capazes de aprender as relações complexas entre as cargas e as variáveis exógenas. Neste trabalho, serão implementadas duas Redes Neurais de Regressão Generalizada: a convencional e a modificada, a fim de comparar o desempenho de ambas dados as métricas de tempo de processamento e treinamento e acurácia. Os dados utilizados neste trabalho são referentes a um sistema de Energia Elétrica de São Paulo e correspondem aos valores de potência ativa, medidos de cinco em 5 minutos, de janeiro de 2018 a outubro de 2019. De maneira geral, os erros absolutos médios percentuais (**MAPE**, *Mean Absolute Percentage Error*) obtidos na previsão dos perfis Comercial, Poder Público Municipal e Serviço Público de água, esgoto e saneamento foram compatíveis com os resultados encontrados na literatura. Esses MAPEs foram, em média, de 14,50%, 16,12% e 8,53% respectivamente. Os MAPEs obtidos na previsão do perfil residencial, por sua vez, demonstraram que os sistemas previsores não foram capazes de generalizar o comportamento para estas cargas. Os MAPEs obtidos para este perfil foram, em média, de 143,13%.

**Palavras-chaves:** Redes Elétricas Inteligentes, Inteligência Artificial, Redes Neurais Artificiais, Previsão de Cargas Elétricas.

# Abstract

Forecasting electrical loads is a fundamental activity for the planning of electricity companies, as it guarantees the efficiency and effectiveness of the electric energy generation and distribution process. In recent years, with the generation of a vast amount of data from the implementation of smart grids and the development of Big Data technologies, it has become possible to carry out this forecast in a disaggregated way. Artificial Intelligence techniques have gained prominence in this task since they are able to learn the complex relationships between the load and the exogenous variables. In this work, two Generalized Regression Neural Networks will be implemented: the conventional and the modified, in order to compare the performance of both processing time and training and accuracy metrics. The data used in this work refer to an Electric Power system in São Paulo and correspond to the active power values, measured every five minutes, from January 2018 to October 2019. In general, the Mean Absolute Percentage Error (**MAPE**) obtained in the forecast of the Commercial, Municipal Government and Public Service profiles were compatible with the results found in the specialized literature. These MAPEs averaged 14.50%, 16.12% and 8.53% respectively. The MAPEs obtained in the prediction of the residential profile, in turn, demonstrated that the forecasting systems were not able to generalize the behavior for these loads. The MAPE obtained for this profile was, on average, 143.13%.

**Keywords:** Smart Grids, Artificial Intelligence, Artificial Neural Networkd, Electric Power Load Forecast.

# Lista de ilustrações

Figura 1 – Esquema de um SLP . . . . .	6
Figura 2 – Modelo de GRNN . . . . .	7
Figura 3 – Consumo Anual . . . . .	13
Figura 4 – Curvas de carga média para os dia da semana do ano de 2018 para cada perfil de consumo . . . . .	15
Figura 5 – Curvas de carga média para os dia da semana do ano de 2018 para cada perfil de consumo - Com Horário de Verão . . . . .	17
Figura 6 – Curvas de carga média diária por amostra - Perfil Residencial . . . . .	19
Figura 7 – Curvas de carga média diária por amostra - Perfil Comercial . . . . .	20
Figura 8 – Curvas de carga média diária por amostra - Poder Público Municipal . . . . .	21
Figura 9 – Curvas de carga média diária por amostra - Serviço Público . . . . .	22
Figura 10 – Correlação para os valores de cargas média, máxima e mínima do ano de 2018 - Perfil Residencial . . . . .	24
Figura 11 – Correlação para os valores de cargas média, máxima e mínima do ano de 2018 - Perfil Comercial . . . . .	25
Figura 12 – Correlação para os valores de cargas média, máxima e mínima do ano de 2018 - Poder Público Municipal . . . . .	26
Figura 13 – Correlação para os valores de cargas média, máxima e mínima do ano de 2018 - Serviço Público . . . . .	27
Figura 14 – Curva de carga real e predita para o período de validação . . . . .	42
Figura 15 – Curva de carga real e predita para o primeiro período de previsão . . . . .	42
Figura 16 – Curva de carga real e predita para o segundo período de previsão . . . . .	42
Figura 17 – Curva de carga real e predita para o período de validação . . . . .	43
Figura 18 – Curva de carga real e predita para o primeiro período de previsão . . . . .	43
Figura 19 – Curva de carga real e predita para o segundo período de previsão . . . . .	43
Figura 20 – Curva de carga real e predita para o período de validação . . . . .	44
Figura 21 – Curva de carga real e predita para o primeiro período de previsão . . . . .	44
Figura 22 – Curva de carga real e predita para o segundo período de previsão . . . . .	44
Figura 23 – Curva de carga real e predita para o período de validação . . . . .	45
Figura 24 – Curva de carga real e predita para o primeiro período de previsão . . . . .	45
Figura 25 – Curva de carga real e predita para o segundo período de previsão . . . . .	45

# Lista de tabelas

Tabela 1 – Horizontes de Previsão (HONG et al., 2010b) . . . . .	4
Tabela 2 – Separação do Banco de Dados . . . . .	28
Tabela 3 – MAPEs médio e máximo obtidos para os perfis Residencial e Comercial	30
Tabela 4 – MAPEs médio e máximo obtidos para os perfis Poder Público Municipal e Serviço Público de Água, Esgoto e Saneamento . . . . .	30
Tabela 5 – Tempo médio gasto para a validação, treinamento e teste de um dia para os perfis de consumo Residencial e Comercial . . . . .	30
Tabela 6 – Tempo médio gasto para a validação, treinamento e teste de um dia para os perfis de consumo do Poder Público Municipal e Serviço Público de Água, Esgoto e Saneamento . . . . .	31
Tabela 7 – Valores de spread utilizados para a GRNN convencional . . . . .	38
Tabela 8 – Valores de spread utilizados para a GRNN modificada . . . . .	38
Tabela 9 – MAPEs, diários, médios e máximos obtidos para as previsões do período de validação para os perfis de consumo comercial e residencial . . . . .	39
Tabela 10 – MAPEs, diários, médios e máximos obtidos para o primeiro período de previsão para os perfis de consumo comercial e residencial . . . . .	39
Tabela 11 – MAPEs, diários, médios e máximos obtidos para o segundo período de previsão para os perfis de consumo comercial e residencial . . . . .	39
Tabela 12 – MAPEs, diários, médios e máximos obtidos para as previsões do período de validação para os perfis de consumo do Poder Público Municipal e Serviço Público de Água, Esgoto e Saneamento . . . . .	40
Tabela 13 – MAPEs, diários, médios e máximos obtidos para o primeiro período de previsão para os perfis de consumo do Poder Público Municipal e Serviço Público de Água, Esgoto e Saneamento . . . . .	40
Tabela 14 – MAPEs, diários, médios e máximos obtidos para o segundo período de previsão para os perfis de consumo do Poder Público Municipal e Serviço Público de Água, Esgoto e Saneamento . . . . .	40

# Lista de abreviaturas e siglas

<b>ANN</b>	Artificial Neural Networks
<b>ARIMA</b>	Autoregressive Integrated Moving Average
<b>ART</b>	Adaptative Resonance Theory
<b>ELM</b>	Extreme Learning Machines
<b>FL</b>	Fuzzy Logic
<b>GRNN</b>	General Regression Neural Network
<b>MAPE</b>	Mean Absolute Percentage Error
<b>MLP</b>	Multilayer Perceptron
<b>RBF</b>	Radial Basis Function
<b>SLP</b>	Single Layer Perceptron
<b>SVM</b>	Support Vector Machine



# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>1</b>
<b>1.1</b>	<b>Organização do Trabalho</b>	<b>3</b>
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>4</b>
<b>2.1</b>	<b>Previsão de Cargas Elétricas</b>	<b>4</b>
2.1.1	Previsão de cargas elétricas de curto prazo	5
<b>2.2</b>	<b>Redes Neurais Artificiais</b>	<b>6</b>
2.2.1	Rede de Regressão Generalizada	6
2.2.2	Rede de Regressão Generalizada Modificada	9
<b>3</b>	<b>METODOLOGIA</b>	<b>10</b>
<b>3.1</b>	<b>Estudo para elaboração de entradas na GRNN</b>	<b>10</b>
3.1.1	Estudo 1 - Comportamento médio da carga no ano de 2018 e 2019	11
3.1.2	Estudo 2 - Comportamento médio da carga nos dias da semana	14
3.1.3	Estudo 3 - Influência do Horário de verão sobre a carga	16
3.1.4	Estudo 4 - Influência de feriados sobre a carga	18
3.1.5	Estudo 5 - Influência de cargas anteriores sobre a carga	23
<b>3.2</b>	<b>Conclusão</b>	<b>28</b>
<b>4</b>	<b>RESULTADOS E DISCUSSÃO</b>	<b>29</b>
<b>4.1</b>	<b>Introdução</b>	<b>29</b>
<b>4.2</b>	<b>Previsão de Cargas Elétricas</b>	<b>30</b>
4.2.1	Resultados	30
4.2.2	Discussão	31
<b>5</b>	<b>CONCLUSÕES E TRABALHOS FUTUROS</b>	<b>32</b>
<b>5.1</b>	<b>Conclusão</b>	<b>32</b>
<b>5.2</b>	<b>Propostas para Trabalhos Futuros</b>	<b>33</b>
	<b>REFERÊNCIAS</b>	<b>34</b>
	<b>APÊNDICES</b>	<b>37</b>
	<b>APÊNDICE A – PREVISÕES DE CARGA</b>	<b>38</b>
<b>A.1</b>	<b>Spreads utilizados para os sistemas previsores</b>	<b>38</b>
<b>A.2</b>	<b>MAPEs obtidos para os sistemas previsores</b>	<b>39</b>

	<b>APÊNDICE B – CURVAS PREVISTAS DE CARGA</b> . . . . .	<b>41</b>
<b>B.1</b>	<b>Perfil Residencial</b> . . . . .	<b>42</b>
<b>B.2</b>	<b>Perfil Comercial</b> . . . . .	<b>43</b>
<b>B.3</b>	<b>Perfil Poder Público Municipal</b> . . . . .	<b>44</b>
<b>B.4</b>	<b>Perfil Serviço Público de Água, Esgoto e Saneamento</b> . . . . .	<b>45</b>

# 1 Introdução

Nos últimos anos, com o desenvolvimento de tecnologias de Big Data nas áreas de sensores digitais e Internet das coisas (**IoT**, *Internet of things*), comunicações, computação e armazenamento, (EMANI; CULLOT; NICOLLE, 2015) dados estão sendo gerados em massa por meio da atividade humana (ZHANG; HUANG; BOMPARD, 2018).

Um dos setores beneficiados por esses avanços foi a indústria de energia elétrica com a instalação das *redes elétricas inteligentes* (*Smart Grids*). Essa implementação em massa na indústria na última década forneceu uma quantidade de dados com alta granularidade, tanto temporalmente quanto espacialmente (HONG; FAN, 2016).

O desenvolvimento das Smart Grids foram importantes por serem fatores chaves na melhora da confiabilidade dos dados medidos, eficiência da tomada de decisão, resposta a demanda de energia (SIANO, 2014), detecção de falhas (KEZUNOVIC, 2011), redução de perdas e diminuição da inadimplência (LAMIN; CAMARGO, 2013).

Com dados históricos em grandes quantidades e cada vez mais confiáveis, a previsão de cargas elétricas desagregadas se tornou uma atividade de extrema importância para as companhias de energia elétrica uma vez que pequenas melhoras nas projeções podem trazer benefícios significativos, diminuindo custos de produção e aumentando as vantagens entre trocas comerciais (CHO et al., 2013).

Nesse sentido, a previsão de cargas elétricas é definida, classicamente, como a demanda elétrica estimada em níveis agregados (HONG; FAN, 2016). Mais recentemente, devido a alta granularidade e alta discriminação dos dados obtidos pelas redes inteligentes, essa previsão tem sido feita de maneira desagregada. Neste nível as demandas de consumo estão entre 1 a 200 kWh e geralmente correspondem ao consumo média de até 20 instalações em uma rede elétrica (SEVLIAN; RAJAGOPAL, 2018).

Prever cargas elétricas em níveis mais desagregados se tornam um desafio, uma vez que o comportamento das curvas de carga sofre influência direta dos usuários inseridos naquele sistema. O consumo de energia elétrica pode variar bastante em menores níveis de agregação por conta da alteração da taxa de ocupação de determinada instalação ou pela quantidade de aparelhos ligados na rede elétrica. De maneira geral, quanto maior a agregação das cargas, menor é a variabilidade no consumo de eletricidade (SEVLIAN; RAJAGOPAL, 2018).

Além disso, por ser um campo de pesquisa relativamente novo, trabalhos abordando a questão de previsão de cargas elétricas em nível desagregados ainda são poucos, se comparados aos trabalhos publicados de previsão em níveis mais agregados (ALVES, 2019). Na literatura, os principais métodos utilizados para realizar a previsão de cargas podem ser divididos essencialmente em duas categorias: métodos analíticos e métodos de aprendizado de máquina (ZOR; TIMUR; TEKE, 2017).

Alguns dos principais métodos analíticos utilizados são: Regressão linear simples e múltipla (PAPALEXOPOULOS; HESTERBERG, 1990; DUDEK, 2016; HONG et al., 2010a), modelo auto-regressivo integrado de médias móveis (ARIMA, *Autoregressive Integrated Moving Average*) de Box e Jenkins (BOX et al., 2015; SADAIEI et al., 2017; DAUT et al., 2017) e filtros de Kalman (ZHENG; GIRGIS; MAKRAM, 2000; AL-HAMADI; SOLIMAN, 2004).

No entanto, os métodos analíticos requerem a modelagem prévia das cargas elétricas, que pode ser uma tarefa complexa, dadas às características não-lineares e não-estacionárias das cargas, sendo diretamente influenciadas por variáveis como dias da semana, condições climáticas e efeitos aleatórios, resultando numa alta imprevisibilidade (CECATI et al., 2015; HAYKIN et al., 2009).

As técnicas de aprendizado de máquina têm se mostrado capazes de aprender essas relações não-lineares através de um processo de treinamento, tornando a abordagem bastante popular (LUTHULI; FOLLY, 2016). Dentre eles, podemos citar: redes neurais artificiais (ANN, *Artificial Neural Networks*) (KUO; HUANG, 2018; FELICE; YAO, 2011; NOSE-FILHO et al., 2011), Máquina de vetores de suporte (SVM, *Support Vector Machine*) (SUYKENS; VANDEWALLE, 1999; CHEN; CHANG et al., 2004; MITCHELL et al., 2017), Lógica Difusa (FL, *Fuzzy Logic*) (RANAWEERA; HUBELE; KARADY, 1996; SONG et al., 2005; ALI et al., 2016), Algoritmos Genéticos (PAI; HONG, 2005; CHEN et al., 2016) e Métodos Híbridos (CHO et al., 2013; GHAYEKHLOO; MENHAJ; GHOFRANI, 2015; ALVES, 2019).

Dentre os vários métodos, as ANNs aparecem como uma alternativa para a resolução do problema de previsão de cargas elétricas. As ANNs são instrumentos capazes de aproximar funções não-lineares podendo ser utilizadas para previsões de séries temporais através de um processo de treinamento utilizando dados históricos (KHOTANZAD et al., 1997; NOSE-FILHO et al., 2011). Elas também possuem vantagens como aprendizagem adaptativa e alta capacidade de generalização (HAYKIN et al., 2009).

Neste trabalho, é feita a implementação de uma ANN para realizar a previsão de cargas elétricas através de uma rede neural de regressão generalizada (GRNN, *General Regression Neural Network*), proposta por SPECHT(1991). Também é implementada a GRNN modificada proposta por NOSE-FILHO et al. (2011).

A GRNN modificada utiliza um processo para reduzir o número de operações nas camadas intermediárias da rede, diminuindo o número de dados processados, bem como o tempo de processamento, viabilizando atingir o mesmo nível de acurácia com menos variáveis (NOSE-FILHO et al., 2011).

Os dados da companhia elétrica utilizados neste trabalho são referentes a um sistema de distribuição de São Paulo, que opera com redes elétricas inteligentes, e correspondem aos valores de potência ativa, medidos de cinco em cinco minutos, de janeiro de 2018 a outubro de 2019.

## 1.1 Organização do Trabalho

Este trabalho foi dividido em 5 seções.

A Seção 1 faz uma apresentação sobre o trabalho, introduzindo os conceitos de previsão de cargas elétricas agregadas e desagregadas, principais metodologias utilizadas na literatura e a abordagem escolhida para resolver o problema de previsão de cargas.

A Seção 2 trata com mais detalhes o problema de previsão indicando a importância de se fazer essa previsão com uma boa acurácia. Também foi feita uma breve revisão bibliográfica da literatura demonstrando os resultados de diferentes metodologias para a previsão de cargas agregadas e desagregadas. Além disso, é apresentado o algoritmo da GRNN e da GRNN modificada.

A Seção 3 apresenta a metodologia adotada neste trabalho. São apresentadas as manipulações realizadas com os dados brutos de carga de um sistema de distribuição de energia elétrica de São Paulo. Também são demonstrados os estudos feitos para elaboração das entradas das redes.

A Seção 4 apresenta e discute os resultados obtidos com a metodologia proposta para 4 perfis de consumo distintos. São eles: Perfil Residencial, Comercial, Poder Público Municipal e Serviço Público de água, esgoto e saneamento.

A Seção 5 faz uma breve conclusão sobre o trabalho e desenvolve algumas propostas para trabalhos futuros.

O Apêndice A contém as tabelas com os dados de spread e erros absolutos médios percentuais (**MAPE**, *Mean Absolute Percentage Error*), diários, médio e máximo obtidos para cada um dos previsores e para cada perfil de consumo estudado.

O Apêndice B contém as curvas de carga preditas para o período de validação, primeiro período de previsão e segundo período de previsão, conforme a Tabela 2, para cada perfil de consumo.

## 2 Fundamentação Teórica

### 2.1 Previsão de Cargas Elétricas

A previsão de cargas elétricas pode ser classificada de acordo com os cenários de previsão, sendo divididas em 4 categorias: muito curto, curto, médio e longo prazo, com horizontes de acordo com a Tabela 1.

<i>Tipo de Previsão</i>	<i>Horizonte de Previsão</i>	<i>Período de Atualização</i>
Muito curto Prazo	Até 24 Horas	De meia em meia hora ou horário
Curto Prazo	Até 2 Semanas	De meia em meia hora ou horário
Médio Prazo	Até 3 Anos	Diária, Semanal ou Mensal
Longo Prazo	Maior que 3 Anos	Mensal ou Anual

Tabela 1 – Horizontes de Previsão (HONG et al., 2010b)

Para o planejamento estratégico e construção de sistemas de energia elétrica, as projeções de médio e longo prazo são de extrema importância, pois estas determinam alguns níveis de referência como: capacidades de geração e transmissão de energia elétrica e programação de manutenções (ZOR; TIMUR; TEKE, 2017) além de nortear a gestão e planejamento da companhia.

Entretanto, os estudos de previsão de cargas têm sido dedicados, em sua grande maioria, às de curto prazo. Este tipo de previsão tem um papel fundamental na definição de políticas de operação de companhias elétricas, para que estas sejam confiáveis, seguras e econômicas (GROSS; GALIANA, 1987).

Estimar a demanda de energia em um prazo diário, com boa acurácia, permite que companhias façam o planejamento ótimo para despacho das usinas, melhorem a logística para compra e venda de matéria prima e calculem preços de energia elétrica de maneira mais eficiente.

### 2.1.1 Previsão de cargas elétricas de curto prazo

No trabalho de [NOSE-FILHO et al. \(2011\)](#), os autores propõem a utilização de uma GRNN Modificada, que implementa um processo de redução de operações nas camadas intermediárias da rede, de modo a diminuir o tempo de previsão. Neste trabalho, foram utilizados dados históricos de cargas de um sistema de energia elétrica da Nova Zelândia, bem como dias da semana e indicadores de feriados e horário de verão. Os MAPEs diários obtidos variam de 2,93% a 3,21%.

No trabalho de [CECATI et al. \(2015\)](#), os autores propõem a utilização de uma ANN do tipo Perceptron multicamada (**MLP**, *Multi Layer Perceptron*) com função de base radial e um algoritmo de correção de erro, retirando o fator aleatório do processo de aprendizado e diminuindo o tamanho da rede. Neste trabalho, foram utilizados dados históricos de carga de um sistema de energia elétrica da Inglaterra, bem como dias da semana, indicadores de feriado e dados de temperatura. Os maiores erros ocorrem para feriados, como o Natal, e para catástrofes naturais, como o Furacão Irene de 2011 em Nova York. Os MAPEs diários obtidos variam de 1,53% a 4,67%.

No trabalho de [FERNÁNDEZ; BORGES; PENYA \(2011\)](#), os autores propõem a utilização de vários modelos para comparação quanto a previsão de cargas de prédios não residenciais. Foram utilizados os seguintes modelos: auto regressivo, polinomial, perceptron multicamada, máquina de vetor de suporte e algoritmo de erro fixo. Para estes métodos são utilizados dados históricos de consumo de energia elétrica da Universidade de Deusto em San Sebastián, Espanha. Os MAPEs diários obtidos variam de 10,97% a 17,11% dentre todos os métodos empregados para a previsão de até 6 dias a frente.

No trabalho de [ALVES \(2019\)](#), os autores propõem a utilização de uma metodologia híbrida composta por ANNs Artmap Fuzzy e o métodos dos mínimos quadrados. Neste trabalho, foram utilizados dados históricos de consumo de energia elétrica de quatro blocos universitários de uma universidade brasileira com variados perfis de cargas. Foram feitas previsões para comparar as redes ARTMAP Fuzzy, o método dos mínimos quadrados e a metodologia híbrida proposta no trabalho. Também foram feitas previsões para entender como os parâmetros da rede e a presença de outliers nos dados interferem nos resultados da previsão. Os MAPEs diários obtidos variam de 11,32% a 16,64% dentre os 4 blocos de estudo.

Para os trabalhos de [NOSE-FILHO et al. \(2011\)](#) e [CECATI et al. \(2015\)](#) foram feitas previsões com cargas agregadas. Já para os trabalhos de [FERNÁNDEZ; BORGES; PENYA \(2011\)](#) e [ALVES \(2019\)](#), foram feitas previsões utilizando dados de cargas desagregadas. De maneira geral, os MAPEs tendem a aumentar com cargas desagregadas, uma vez que estas apresentam maior variabilidade de consumo.

## 2.2 Redes Neurais Artificiais

As ANNs são ferramentas matemáticas e computacionais que simulam o funcionamento de um cérebro humano para processar informações (KUO; HUANG, 2018). Elas são constituídas, essencialmente, por neurônios, a menor unidade de processamento, interconectados entre si por meio de pesos. Os neurônios, também chamados de *perceptrons*, podem simular comportamentos lineares e não lineares.

A soma dos nós da rede calcula uma combinação linear da entrada com os pesos, e incorpora um viés (*bias*) (HAYKIN et al., 2009). Esse *bias* permite que a função de ativação do neurônio seja deslocada para melhor se ajustar aos dados. Desta maneira, o Perceptron de camada única (SLP, *Single Layer Perceptron*) é capaz de diferenciar os estímulos externos, ou *inputs*, aplicados a rede e classificá-los dentro de duas classes pré definidas.




Figura 1 – Esquema de um SLP

As ANNs têm se tornado, cada vez mais, uma abordagem bastante popular, visto que são capazes de aprender relações entre as variáveis de entrada e de saída, sem a necessidade prévia de modelagem de dados, utilizando-se de um processo de treinamento.

Para a previsão de cargas de curto prazo, os padrões de entrada são, normalmente, de dados históricos de cargas e variáveis de influência como temperatura, dia da semana, feriados, entre outros. A saída é composta por valores da carga futura.

### 2.2.1 Rede de Regressão Generalizada

As GRNNs introduzidas por SPECHT (1991) são redes capazes de estimar uma variável dependente  $y$  por meio de um conjunto finito de variáveis  $x_i$ , através de uma regressão. A variável dependente corresponde à saída predita  $\hat{y}$  da rede, e o conjunto de variáveis  $x_i$  correspondem às entradas, que seriam as variáveis de influência do modelo.



Esta topologia geralmente está atrelada à previsão de séries temporais, como é o caso da previsão de cargas elétricas. A função de transferência dos nós da rede é a chamada função de base radial (**RBF**, *Radial Basis Function*), que é definida em 2.1.

$$b_i = f(d_i) = \exp \frac{-0,8326^2 d_i^2}{\sigma^2} \quad (2.1)$$

O parâmetro  $\sigma$ , denominado *spread*, determina a abertura da função Gaussiana e, por consequência, os padrões de treinamento a serem levados em conta pela rede.

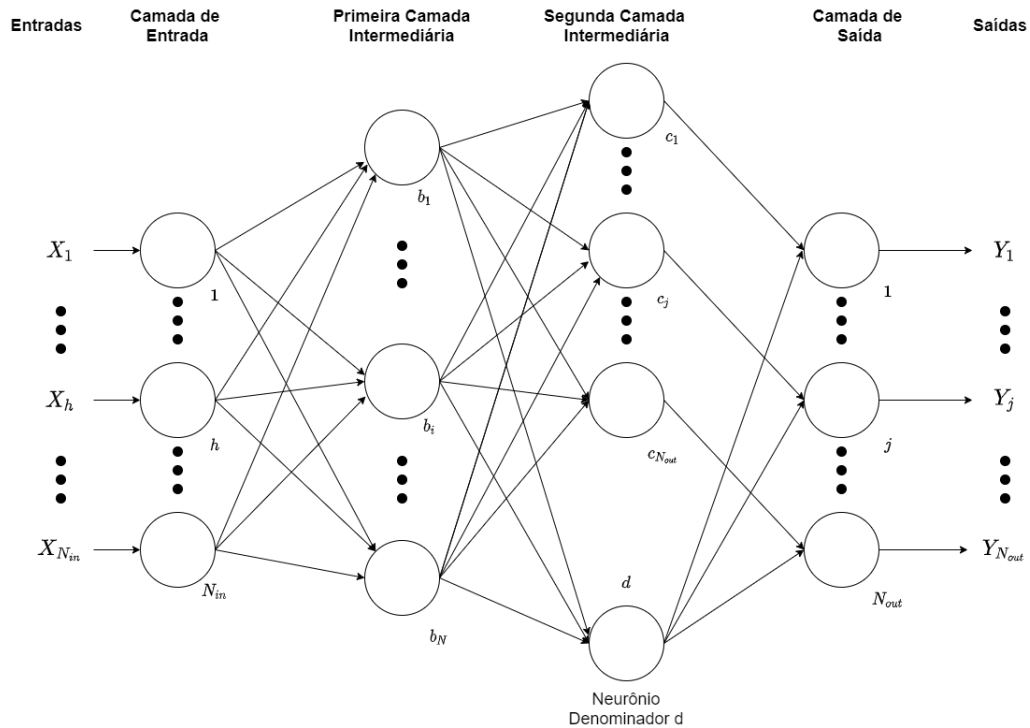


Figura 2 – Modelo de GRNN

Na entrada da rede têm-se  $N_{in}$  neurônios, que são representados por um vetor  $\hat{\mathbf{x}}$ ,  $N_{in}$ -dimensional. Na saída da rede têm-se  $N_{out}$  neurônios, que são representados por um vetor  $\hat{\mathbf{y}}$ ,  $N_{out}$ -dimensional. As camadas intermediárias são totalmente conectadas, sendo que a primeira intermediária é composta por  $N$  neurônios e a segunda intermediária é composta por  $N_{out}$  neurônios do tipo numerador  $c$  e um neurônio do tipo denominador  $d$ .

Dessa maneira, os dados de treinamento podem ser descritos por matrizes  $\mathbf{W}_{N_{in} \times N}$ , contendo as variáveis de entrada, e  $\mathbf{Z}_{N_{out} \times N}$ , contendo as variáveis de saída. O treinamento da rede é realizado pelas leituras das matrizes  $\mathbf{W}_{N_{in} \times N}$  e  $\mathbf{Z}_{N_{out} \times N}$ , além do parâmetro *spread* e as  $N$  amostras.

A previsão é feita através do seguinte algoritmo (NOSE-FILHO et al., 2011):

---

**Algorithm 1** Previsão de Cargas Através da GRNN

---

- 1: **procedure** PREVISAO
  - 2:   Leitura das variáveis de entrada  $\hat{\mathbf{x}}$ ;
  - 3:   Calcular as distâncias euclidianas,  $d_i$ , dadas por 2.2;
  - 4:   Calcular os níveis de pertinência,  $b_i$ , dados por 2.1;
  - 5:   Calcular as saídas  $c_j$  dos neurônios numeradores, dadas por 2.3;
  - 6:   Calcular a saída  $l$  do neurônio denominador, dada por 2.4;
  - 7:   Calcular a saída estimada  $\hat{\mathbf{y}}$ , dada por 2.5;
  - 8:   A saída final é o vetor  $\hat{\mathbf{y}}$ , dado por 2.6.
- 

Distância Euclidiana:

$$d_i = (\hat{X} - X_i)^T (\hat{X} - X_i) \quad i = 1, \dots, N \quad (2.2)$$

Saída do Neurônio Numerador  $c_j$

$$c_j = \sum_{i=1}^N y_{j,i} b_i \quad j = 1, \dots, N_{out} \quad (2.3)$$

Saída do Neurônio Denominador  $l$

$$l = \sum_{i=1}^N b_i \quad (2.4)$$

Saída prevista  $\hat{\mathbf{y}}$ :

$$\hat{\mathbf{y}}_j = \frac{c_j}{l} \quad j = 1, \dots, N_{out} \quad (2.5)$$

Vetor de saídas  $\hat{\mathbf{y}}$ :

$$\hat{\mathbf{y}} = [\hat{y}_1 \cdots \hat{y}_j \cdots y_{N_{out}}]^T \quad (2.6)$$

## 2.2.2 Rede de Regressão Generalizada Modificada

A GRNN modificada proposta por NOSE-FILHO et al. (2011) possui a mesma estrutura descrita em 2.2.1, mas implementa um processo de decisão para diminuir a quantidade de cálculos nas camadas intermediárias da rede. Como o tempo de previsão é diretamente proporcional à quantidade de dados processados, ao diminuir o número de conexões ativas, esse tempo diminui.

O processo consiste em determinar um subconjunto  $K$ , dentro das  $N$  amostras, de modo a limitar o número de conexões ativas da primeira camada intermediária com a segunda. Assim, são considerando apenas os  $N_{m\acute{a}x}$  elementos que possuem a menor distância euclidiana com a entrada.

Esse processo é descrito matematicamente em 2.7

$$b_i = f(d_i) = \begin{cases} \exp \frac{-0,8326^2 d_i^2}{\sigma^2}, & i \in K; \\ 0, & i \notin K; \end{cases} \quad (2.7)$$

Desse modo, as equações 2.3 e 2.4 podem ser reescritas como:

Saída do Neurônio Numerador  $c_j$  - GRNN Modificada

$$c_j = \sum_{i \in K} y_{j,i} b_i \quad j = 1, \dots, N_{out} \quad (2.8)$$

Saída do Neurônio Denominador  $l$  - GRNN Modificada

$$l = \sum_{i \in K} b_i \quad (2.9)$$

# 3 Metodologia

Para realizar a previsão de carga serão utilizadas as GRNNs convencionais e as GRNNs modificadas, aplicadas a padrões de carga de um sistema de distribuição de energia elétrica de São Paulo.

O banco de dados contém os valores de potência ativa, telemídidos de cinco em cinco minutos, data de medição, identificadores de instalação e identificador de classe de consumo para os anos de 2018 e 2019. A partir destes dados, foram extraídos dados de tempo como ano, mês e dia de medição, dia da semana, feriado e horário de verão.

Dado que o horizonte de previsão é de curto prazo, foi feita uma reamostragem dos dados para se obter a carga média por instalação a cada 30 minutos, deste modo, se adequando ao horizonte de previsão proposto para o trabalho, como indicado na Tabela 1.

Após a manipulação dos dados, o banco foi dividido em dados de treinamento, dados de validação e dados de teste. O banco de dados de treinamento contém os padrões de carga que serão utilizados para treinar as RNAs. O de validação contém os padrões de carga que serão utilizados para determinar o parâmetro spread ótimo. O de teste será utilizado para avaliar o desempenho das redes.

Para definir as entradas das RNAs, foram realizados cinco estudos com os valores de carga na Seção 3.1

## 3.1 Estudo para elaboração de entradas na GRNN

Para entender o comportamento da carga, foram realizados 5 estudos para encontrar padrões para a previsão. São eles:

- Estudo 1 - Comportamento médio da carga durante os meses de 2018 e 2019
- Estudo 2 - Comportamento médio da carga nos dias da semana de 2018 e 2019
- Estudo 3 - Influência do horário de verão sobre a carga
- Estudo 4 - Influência de feriados sobre a carga
- Estudo 5 - Influência de cargas passadas sobre a carga

Estes estudos ajudaram a definir as variáveis de entradas da rede, que são compostas por dados de tempo como ano, mês e dia de medição, dia da semana, feriado, horário de verão, e valores de cargas passadas. Deste modo, espera-se obter previsões bastante precisas, sem a necessidade de um estudo estatístico mais aprofundado das cargas.

Os estudos foram realizados para 5 perfis de consumo diferentes: Público Residencial, Industrial, Comercial, Poder Público Municipal e Serviços Públicos de água, esgoto e saneamento.

### 3.1.1 Estudo 1 - Comportamento médio da carga no ano de 2018 e 2019

O Estudo 1 foi realizado para entender o comportamento médio da carga durante os meses dos anos de 2018 e 2019. Para isso, foi gerado o gráfico da Figura 3, que contém as curvas de carga média para 5 perfis de consumo nestes anos.

Por meio deste estudo, observou-se que o comportamento das cargas dos anos de 2018 e de 2019 são bastante diferentes. Os dados de 2019, sobretudo nos 3 primeiros meses, aparentam ter bastante ruído, possuindo oscilações muito maiores tanto da carga mínima quanto da carga máxima. Além disso, os dados de consumo industrial estão incompletos para o ano de 2018.

Para que a previsão de carga de determinado período seja precisa, é necessário que padrões do mesmo período de anos anteriores sejam utilizadas no treinamento, para que a rede consiga identificar as características em comum dos dados.

No entanto, como estes dados se diferem muito, decidiu-se por descartar o período de 2019, bem como os dados de consumo industrial, e treinar, validar e testar a rede apenas com o ano de 2018.

Com este estudo, foi criada a primeira variável de entrada da rede, que indica o mês de referência. A variável foi criada tendo em mente uma função triangular, de modo que o passar dos meses seja contínuo e que a troca do ano ainda mantenha meses seguidos de maneira contínua, como é o caso de janeiro e dezembro.

$$X_1 = \left\{ \begin{array}{ll} 0.8333 & , \text{ Janeiro} \\ 0.6667 & , \text{ Fevereiro} \\ 0.5000 & , \text{ Março} \\ 0.3333 & , \text{ Abril} \\ 0.1667 & , \text{ Maio} \\ 0 & , \text{ Junho} \\ 0.1667 & , \text{ Julho} \\ 0.3333 & , \text{ Agosto} \\ 0.5000 & , \text{ Setembro} \\ 0.6667 & , \text{ Outubro} \\ 0.8333 & , \text{ Novembro} \\ 1 & , \text{ Dezembro} \end{array} \right. \quad (3.1)$$



Figura 3 – Consumo Anual

### 3.1.2 Estudo 2 - Comportamento médio da carga nos dias da semana

O Estudo 2 foi realizado para entender o comportamento médio da carga nos dias da semana do ano de 2018. Para isso, foi gerado o gráfico da Figura 4, que contém as curvas de carga média para 4 perfis de consumo estudados nos dias da semana.

É possível observar que as curvas de carga dos dias da semana se diferem, principalmente para o perfil residencial. A intenção do trabalho é estruturar uma RNA que seja capaz de prever a carga para todos os dias. Para isso, é necessário diferenciar essas entradas. Com essa ideia, criou-se a segunda variável  $I_2$  de entrada da rede que indica os dias da semana.

$$X_2 = \begin{cases} [1 0 0 0 0 0 0]^T & , \text{Segundas - Feiras} \\ [0 1 0 0 0 0 0]^T & , \text{Terças - Feiras} \\ [0 0 1 0 0 0 0]^T & , \text{Quartas - Feiras} \\ [0 0 0 1 0 0 0]^T & , \text{Quintas - Feiras} \\ [0 0 0 0 1 0 0]^T & , \text{Sextas - Feiras} \\ [0 0 0 0 0 1 0]^T & , \text{Sábados} \\ [0 0 0 0 0 0 1]^T & , \text{Domingos} \end{cases} \quad (3.2)$$



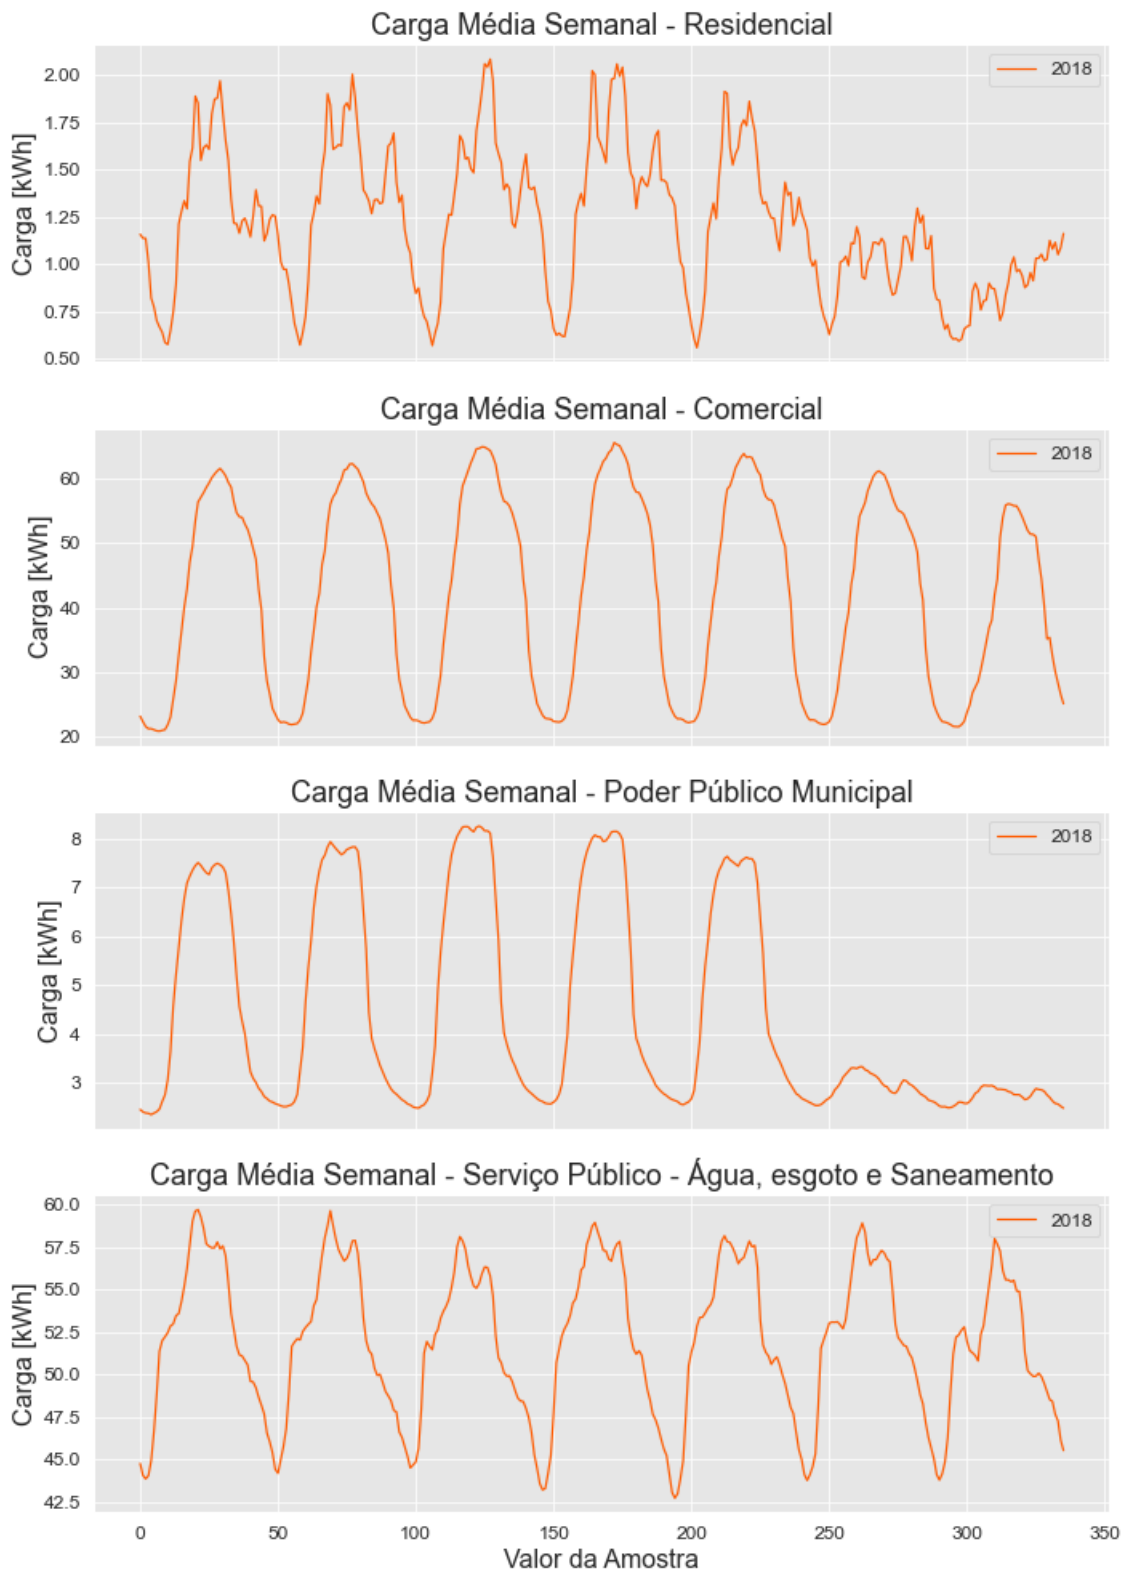


Figura 4 – Curvas de carga média para os dia da semana do ano de 2018 para cada perfil de consumo

### 3.1.3 Estudo 3 - Influência do Horário de verão sobre a carga

O Estudo 3 foi realizado para entender o comportamento médio da carga com e sem o horário de verão nos dias da semana do ano de 2018. Para isso, foi gerado o gráfico da Figura 5, que contém as curvas de carga média para 4 perfis de consumo nos dias da semana.

Para os perfis de consumo do Poder Público Municipal e de serviços públicos, houve uma redução dos valores do pico quando em horário de verão.

Já para o perfil comercial, o efeito foi o contrário. O consumo observado apresentou um ligeiro aumento em todos os dias, incluindo os finais de semana.

O Perfil residencial, por sua vez, teve um deslocamento do pico de consumo para o final do dia. Além disso, entre quarta-feira e domingo, teve um aumento significativo da carga máxima observada.

Portanto, para todos os perfis, é possível observar que o horário de verão tem sua influência nas curvas de carga média. Deste modo, é necessário diferenciar cargas no horário de verão das cargas habituais. Para isso foi criada a terceira variável de entrada da rede, que indica se a carga a ser prevista pertence ao horário de verão ou não.

$$X_3 = \begin{cases} 1 & , \text{Horário de Verão} \\ 0 & , \text{Sem Horário de Verão} \end{cases} \quad (3.3)$$

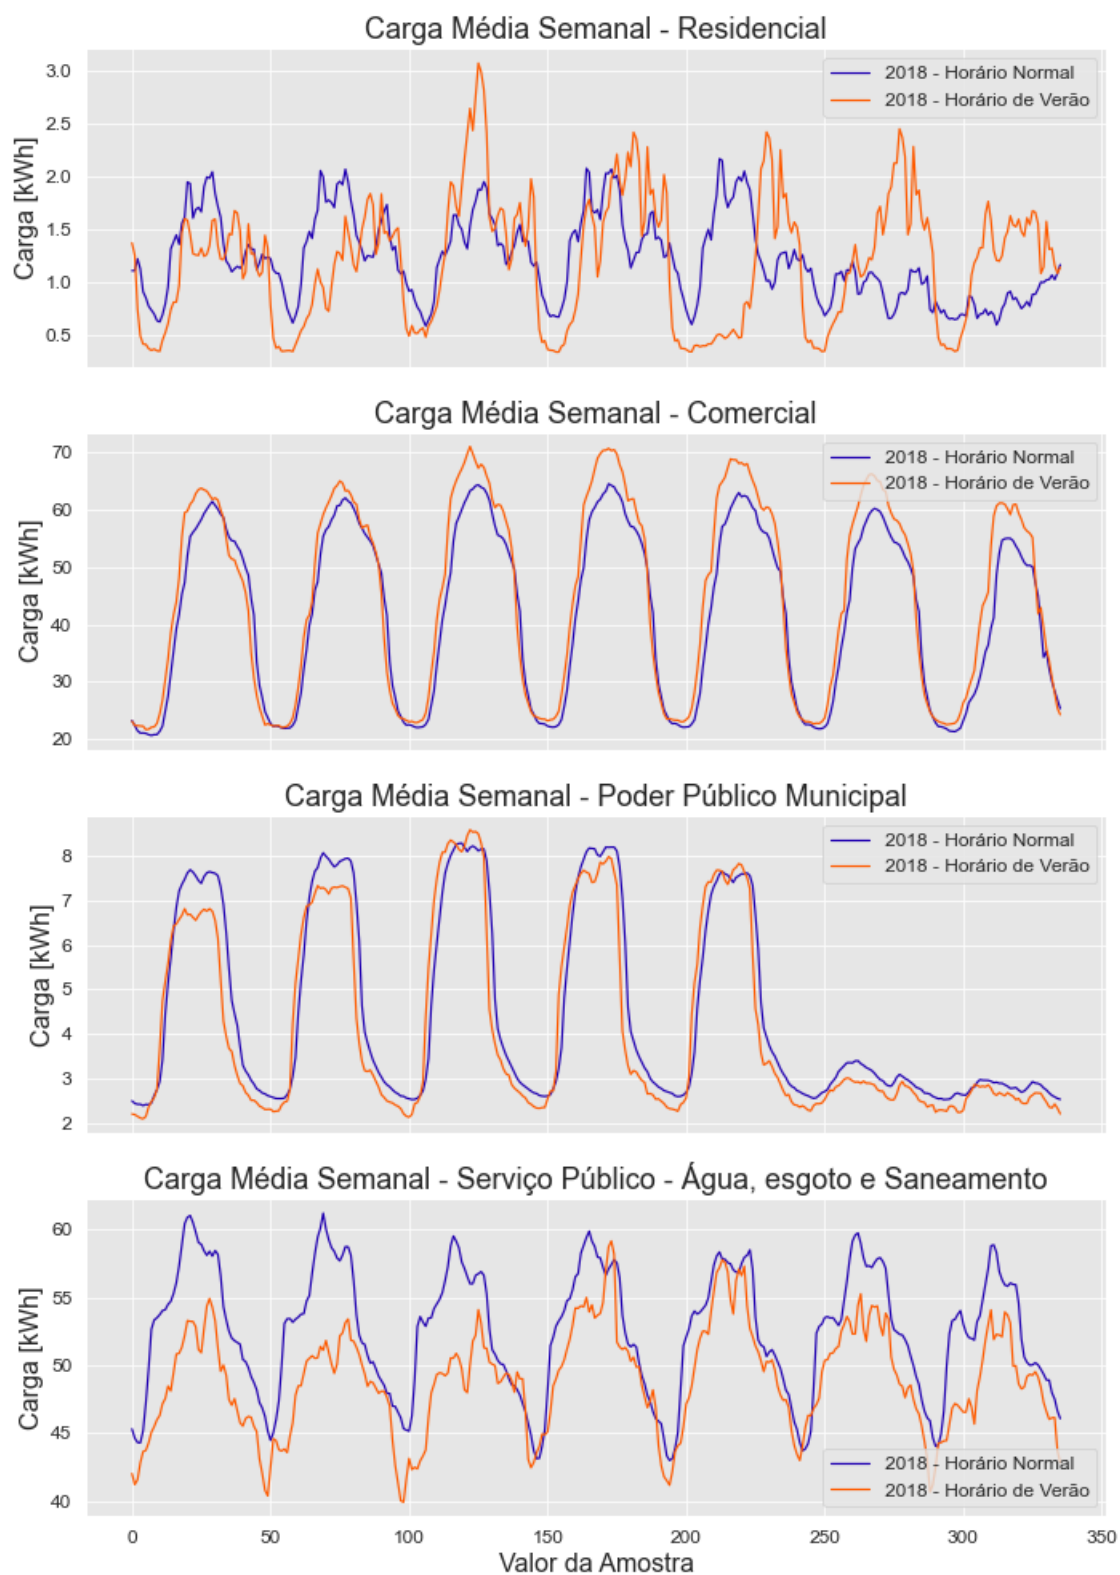


Figura 5 – Curvas de carga média para os dias da semana do ano de 2018 para cada perfil de consumo - Com Horário de Verão

### 3.1.4 Estudo 4 - Influência de feriados sobre a carga

O Estudo 4, de maneira similar ao Estudo 3, foi realizado para entender o comportamento médio da carga quando há feriado nos dias da semana do ano de 2018. Para isso, foram gerados os gráficos das Figuras 6, 7, 8 e 9 que contém as curvas de carga média diárias para 4 perfis de consumo dos dias da semana.

A região sombreada das curvas indica a variação da curva média de carga, isto é, os valores que a carga admite naquele dia levando em consideração todos os dados de 2018. Com isso, é possível observar que para o mesmo dia, o consumo pode variar bastante ao longo do ano.

Para os perfis de consumo do Poder Público Municipal e de serviços públicos, ilustrados nas Figuras 8 e 9 respectivamente, a carga média tende a ser mais baixa em feriados, com exceção do domingo que apresenta uma carga significativamente mais alta.

Já para o perfil comercial, ilustrado na Figura 7, também há uma ligeira queda no consumo para os dias úteis da semana, mas há um aumento significativo do pico de consumo no período da tarde até a noite.

O Perfil residencial, ilustrado na Figura 6, por sua vez, não apresenta um padrão muito bem definido. Segundas e quartas apresentam uma carga média bem abaixo do habitual quando há feriados e nos outros dias há uma grande variação tanto da média de consumo quanto dos picos.

No entanto, para todos os perfis, é possível observar que feriados tem sua influência nas curvas de carga. Sendo assim, também é necessário diferenciar cargas de feriados das cargas habituais. Para isto criou-se a quarta variável de entrada da rede que indica se a carga a ser prevista é de um feriado ou não.

$$X_4 = \begin{cases} 1 & , \text{Feriado} \\ 0 & , \text{Sem Feriado} \end{cases} \quad (3.4)$$

### Carga Média Diária - Residencial

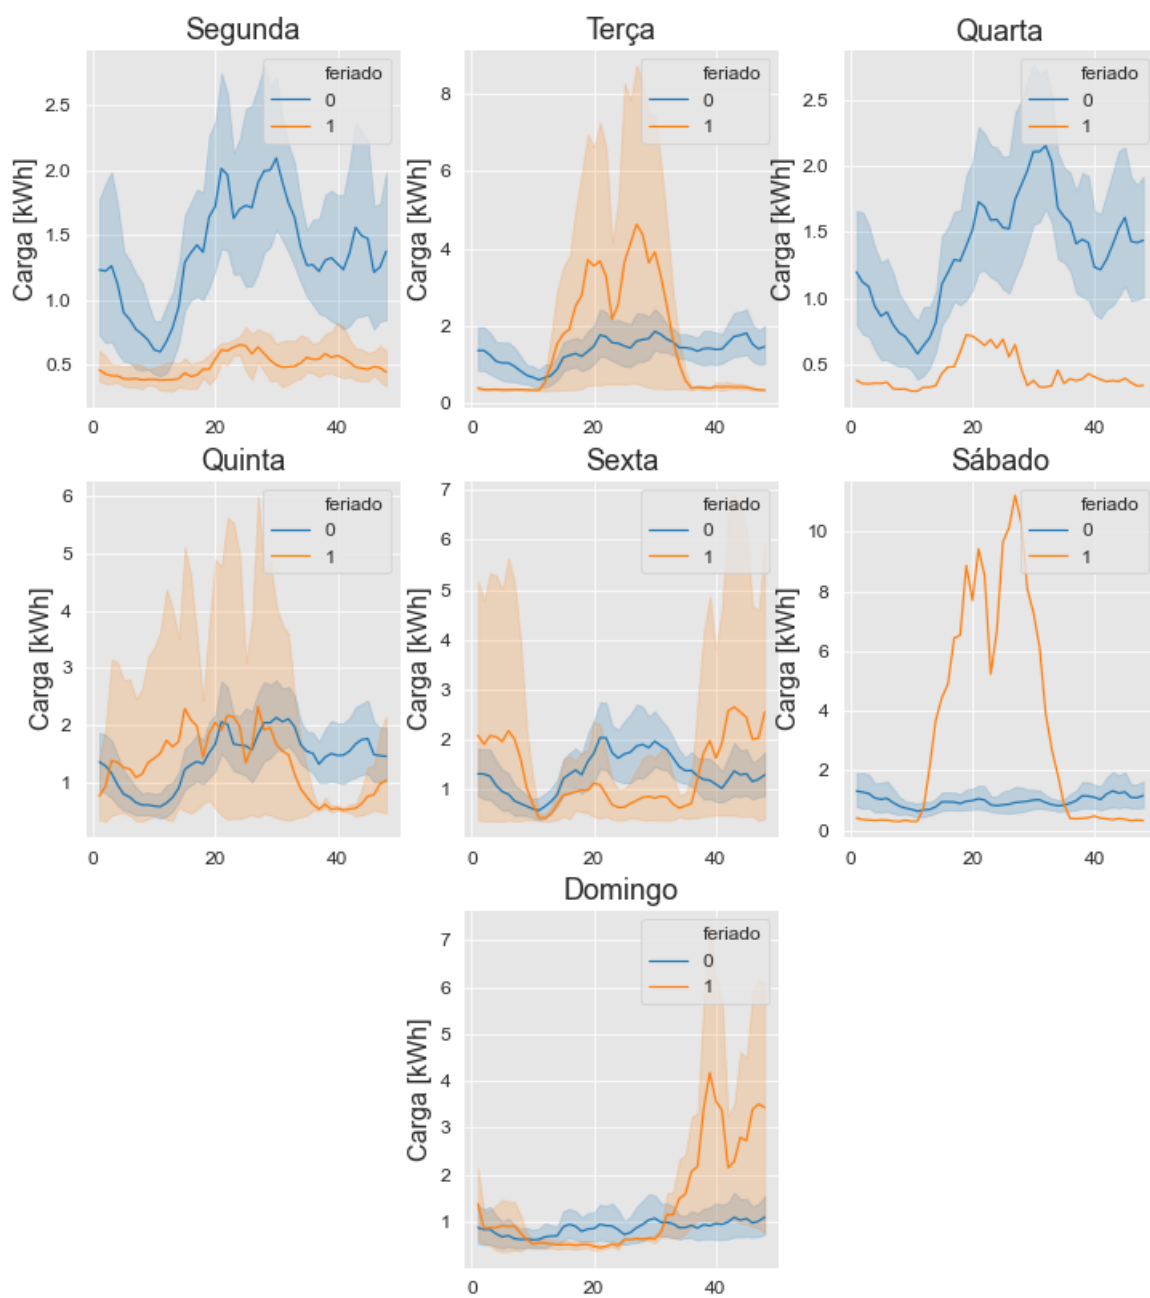


Figura 6 – Curvas de carga média diária por amostra - Perfil Residencial

## Carga Média Diária - Comercial

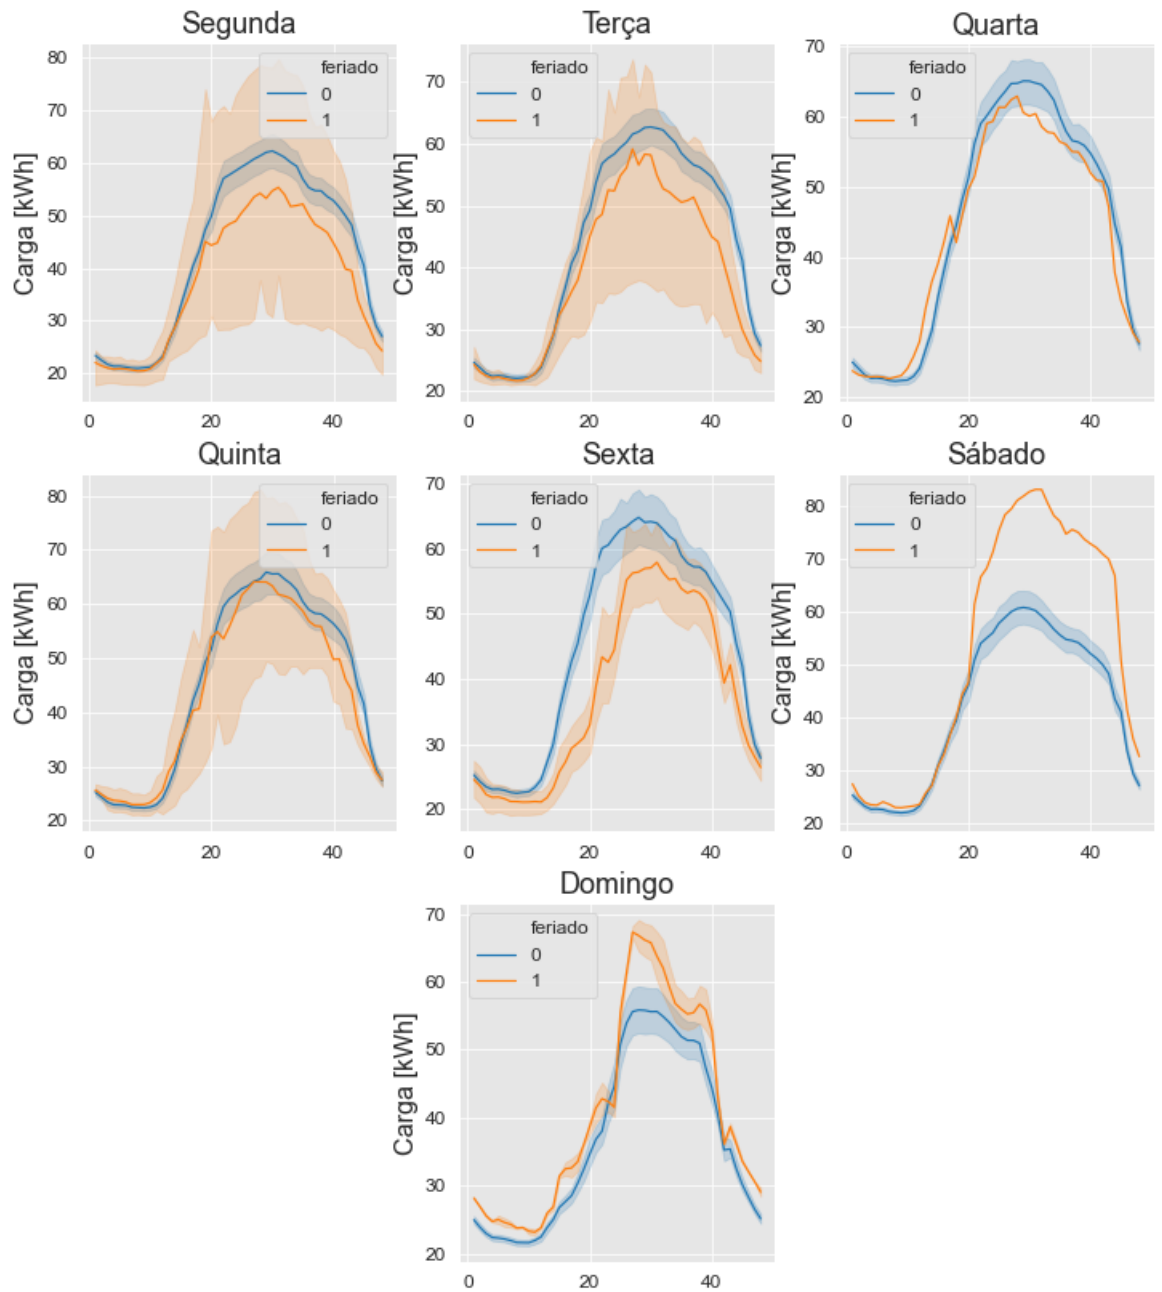


Figura 7 – Curvas de carga média diária por amostra - Perfil Comercial

### Carga Média Diária - Poder Público Municipal

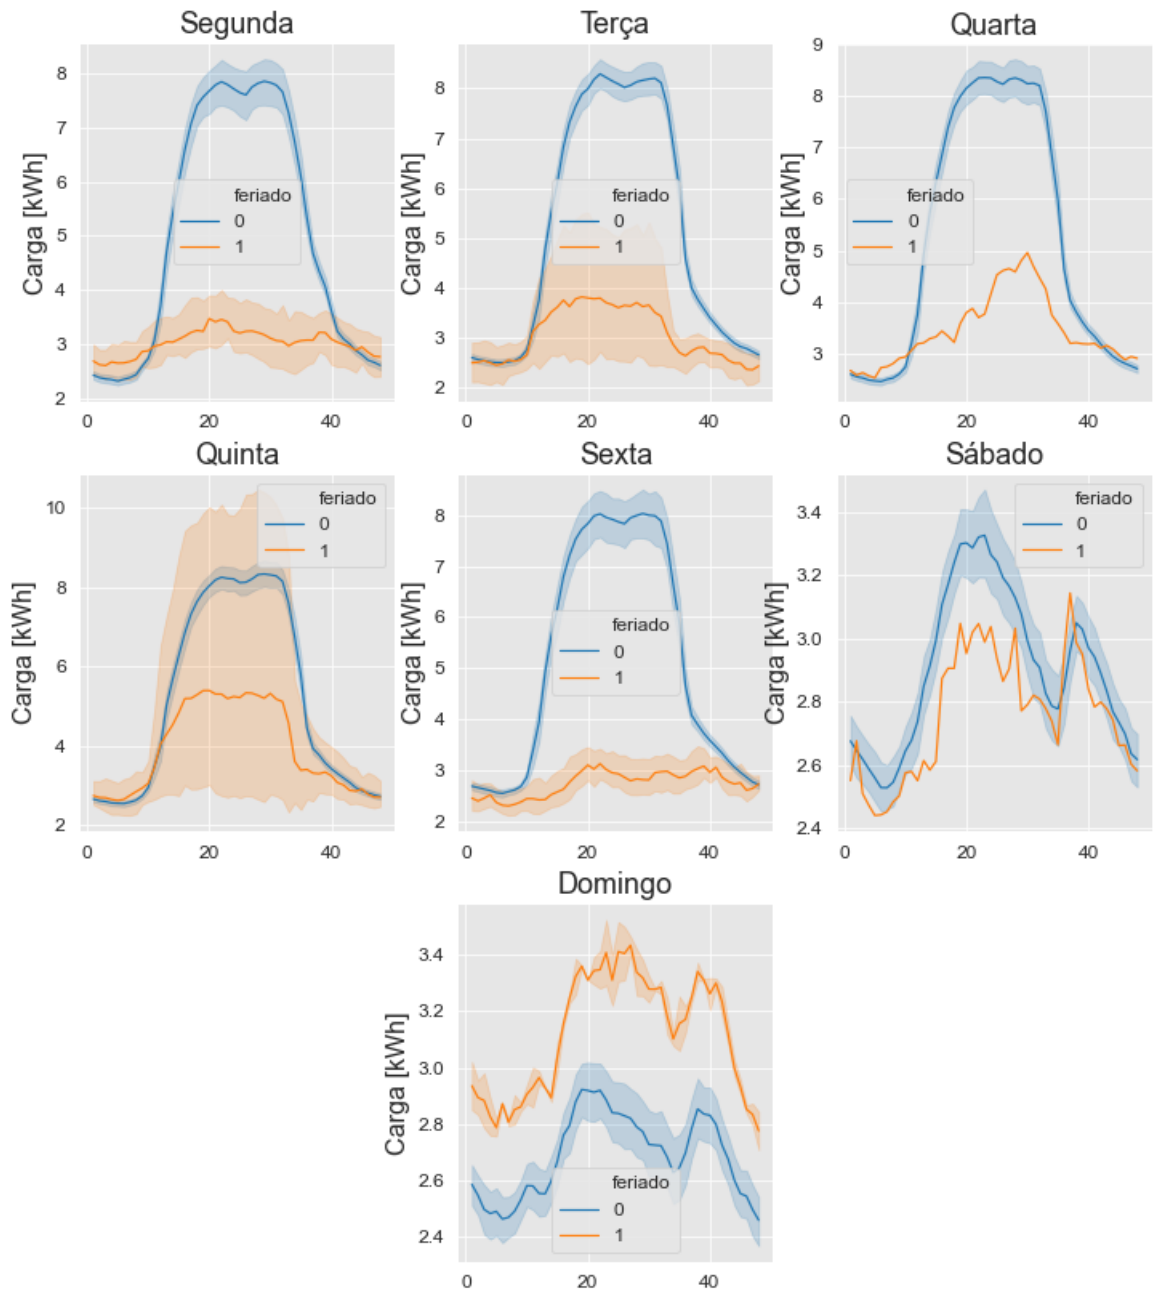


Figura 8 – Curvas de carga média diária por amostra - Poder Público Municipal

### Carga Média Diária - Serviço Público

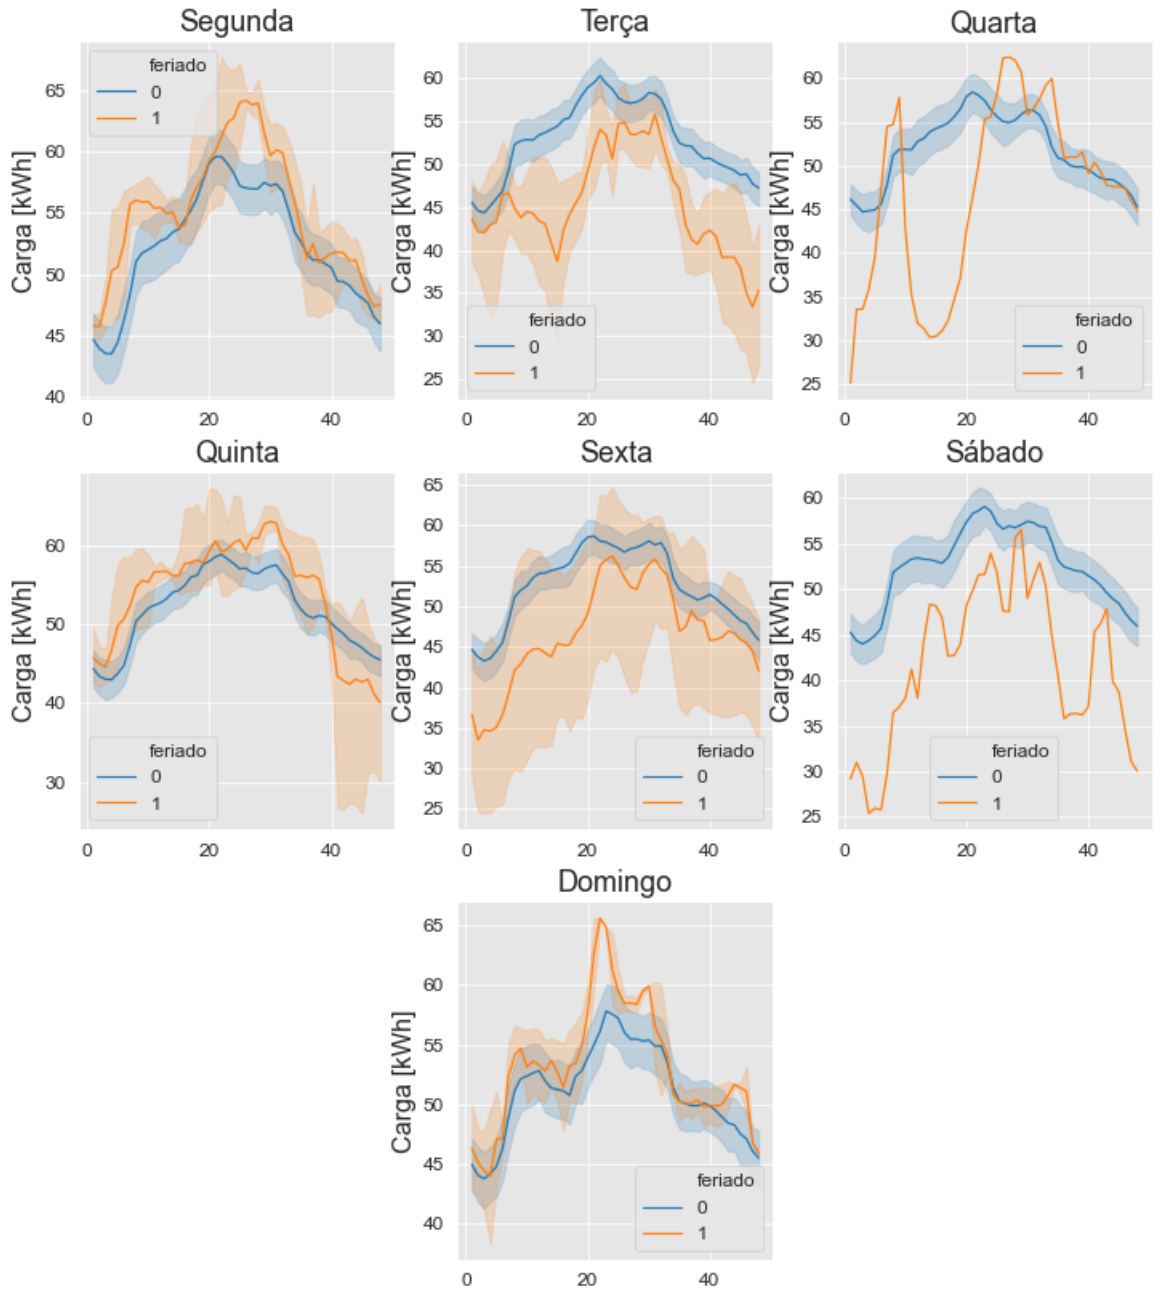


Figura 9 – Curvas de carga média diária por amostra - Serviço Público



### 3.1.5 Estudo 5 - Influência de cargas anteriores sobre a carga

O quinto, e último Estudo, foi realizado para analisar a influência de cargas passadas na carga do dia atual. Para isso, foram gerados os gráficos das Figuras 10, 11, 12 e 13 que contém a correlação entre essas cargas para 4 perfis de consumo.

Para os perfis de consumo comercial e de serviços públicos, ilustrados nas Figuras 11 e 13 respectivamente, é possível observar uma forte correlação entre as cargas médias e máximas em  $d - 1$  com as cargas médias e máximas do dia atual  $d$ . Para as cargas mínimas, a correlação é um pouco mais fraca, mas o comportamento é semelhante.

O Perfil residencial, ilustrado na Figura 10, por sua vez, apresenta uma correlação mais dispersa entre as cargas médias, máximas e mínimas em  $d - 1$  com as cargas médias, máximas e mínimas do dia atual  $d$ . Isso indica que o poder de previsão dessas cargas provavelmente será mais fraco quando comparado aos outros perfis.

Já para o perfil do Poder Público Municipal, ilustrado na Figura 12, há uma forte correlação entre as cargas mínimas em  $d - 1$  com as cargas mínimas do dia atual  $d$ . As cargas máxima e média, são agrupadas em 4 regiões, todas fortemente correlacionadas. Essas 4 regiões surgem da correlação entre dias úteis e dias do final de semana. Dias úteis tendem a ser mais correlacionados entre si por possuírem um perfil de carga semelhante. O mesmo efeito ocorre para os dias do final de semana. No entanto, quando são comparadas as cargas dos dias úteis com os dias do final de semana, a correlação tende a ser um pouco mais fraca, resultando numa discontinuidade da figura.

No entanto, para todos os perfis é possível observar uma correlação entre as cargas no dia  $d - 1$  e no dia atual  $d$ . Deste modo criou-se uma quinta variável de entrada da rede contendo os valores de cargas média, máxima e mínima do dia  $d - 1$ .

$$X_5 = \begin{cases} [\text{Carga média em } d - 1] \\ [\text{Carga Máxima em } d - 1] \\ [\text{Carga Mínima em } d - 1] \end{cases} \quad (3.5)$$

### Estadísticas de Carga - Residencial



Figura 10 – Correlação para os valores de cargas média, máxima e mínima do ano de 2018 - Perfil Residencial

### Estadísticas de Carga - Comercial



Figura 11 – Correlação para os valores de cargas média, máxima e mínima do ano de 2018 - Perfil Comercial

### Estadísticas de Carga - Poder Público Municipal




Figura 12 – Correlação para os valores de cargas média, máxima e mínima do ano de 2018 - Poder Público Municipal

Carga Média Semanal - Serviço Público - Água, esgoto e Saneamento

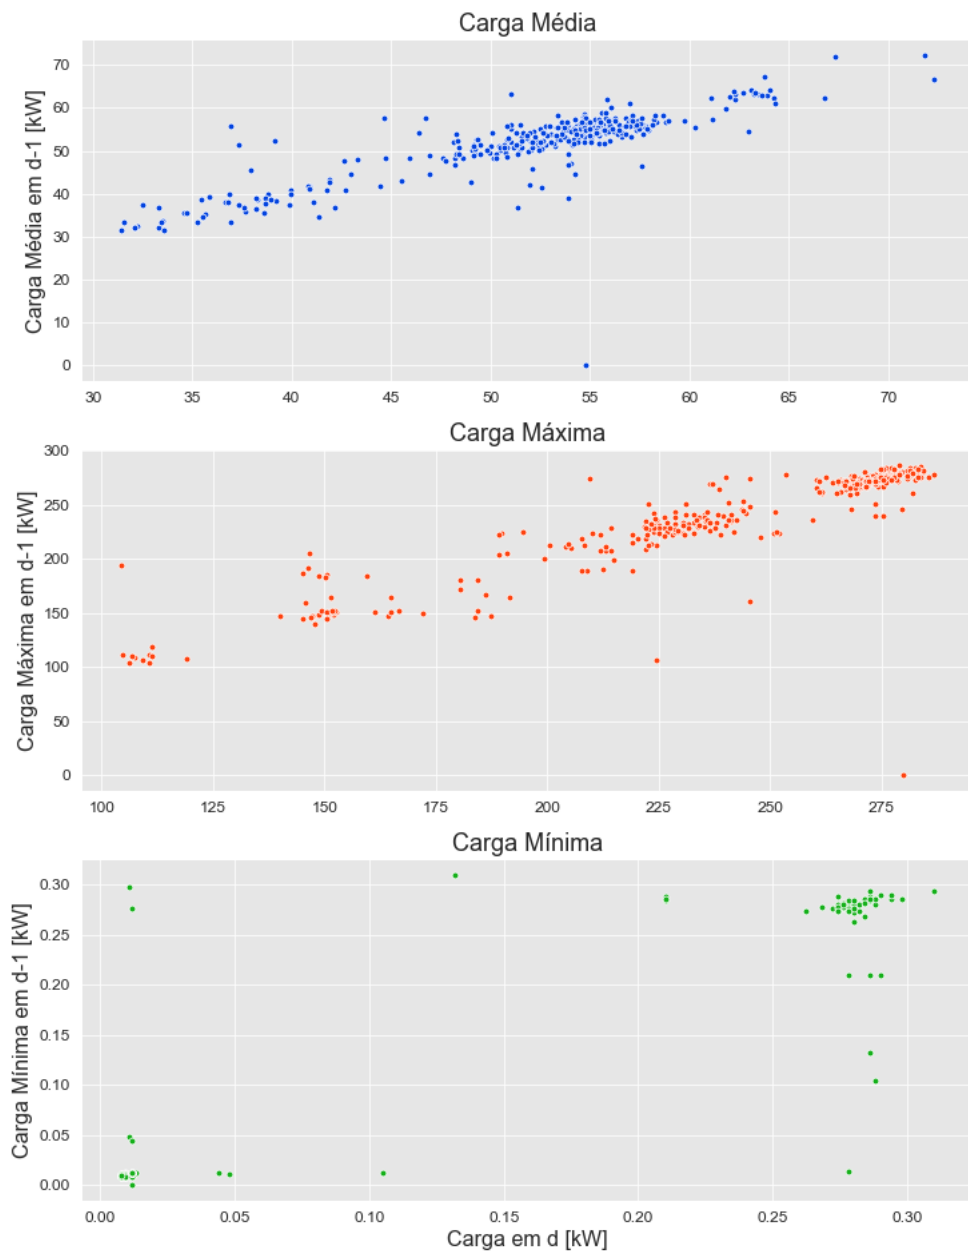


Figura 13 – Correlação para os valores de cargas média, máxima e mínima do ano de 2018 - Serviço Público

## 3.2 Conclusão

Por meio dos estudos realizados na seção 3.1 foi possível elaborar um modelo de previsão de cargas, de curto prazo, genérico. Este modelo pôde ser elaborado a partir de estudos realizados somente com a carga elétrica, sem a necessidade de um estudo mais aprofundado das relações estatísticas entre as cargas e variáveis exógenas, diminuindo de maneira significativa a complexidade do problema de previsão.

A entrada das RNAs será composta por 5 variáveis com 13 elementos de entrada para todos os perfis. A saída da RNA é dada por 48 elementos, indicando os valores de carga de 30 em 30 minutos do dia  $d$  previsto. As entradas correspondem a dados de dia da semana, mês de referência, horário de verão, feriado e os dados de carga média, máxima e mínima do dia anterior, representado por  $d - 1$ .

Todos os valores de carga foram normalizados, dividindo-se os valores das amostras pela carga máxima presente nos respectivos bancos de dados. Já os dados de tempo não precisam ser normalizados porque estão definidos como entradas binárias para a rede.

Além disso, o banco de dados foi dividido em dados de treinamento, dados de validação e dados de teste, conforme a Tabela 2.

Para todos os segmentos foram obtidos resultados com o banco de dados de teste. Esses resultados são ilustrados na Seção 4. Tanto a GRNN convencional quando a GRNN modificada foram programadas em Python. Para as GRNNs modificadas foi utilizado  $N_{máx} = 50$ .

<b>Banco de Dados</b>	<b>Período</b>
<b>Treinamento</b>	01/01/2018 a 30/11/2018
<b>Validação</b>	01/12/2018 a 07/12/2018
<b>Teste</b>	08/12/2018 a 14/12/2018
	22/12/2018 a 28/12/2018

Tabela 2 – Separação do Banco de Dados

# 4 Resultados e Discussão

## 4.1 Introdução

Para avaliar o desempenho das redes, será considerado o erro absoluto médio percentual (**MAPE**, *Mean Absolute Percentage Error*) das previsões como principal métrica de avaliação. O MAPE pode ser definido como:

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100 \quad (4.1)$$

onde:

$y_i$  é o valor da carga real

$\hat{y}_i$  é o valor da carga prevista

$N$  é o número de amostras

Foram realizadas previsões de cargas desagregadas para 4 perfis de consumo distintos. São eles: Perfil Residencial, Comercial, Poder Público Municipal e Serviço Público de água, esgoto e saneamento. As previsões correspondem ao período dos dias 08 a 14 de dezembro de 2018 e 22 a 28 de dezembro de 2018, totalizando 14 dias.

Para todos os perfis de consumo foram obtidos os MAPEs diários, médio e máximo, da previsão das cargas locais dos 14 dias, e o tempo médio gasto para o treinamento, a validação e a previsão por sistema previsor.

As tabelas com os valores de MAPEs diários obtidos para as previsões se encontra no apêndice [A](#). Neste apêndice também são encontrados os valores utilizados para o parâmetro spread para cada rede utilizada.

As curvas de carga, real e preditas, obtidas para o treinamento e previsões obtidas pelos previsores podem ser encontradas no apêndice [B](#).

## 4.2 Previsão de Cargas Elétricas

### 4.2.1 Resultados

As Tabelas 3 e 4 são referente aos MAPEs diários, médio e máximo, previstos para os períodos de teste da Tabela 2 para os 4 perfis de consumo estudados.

Perfis	Residencial		Comercial	
	GRNN	GRNN - M	GRNN	GRNN - M
Médio Previsão 1	112,28	112,21	14.88	14.35
Máximo Previsão 1	132,09	122,46	37.54	37.64
Médio Previsão 2	168,57	179,46	14.63	14.15
Máximo Previsão 2	337,68	278,39	33.43	34.33

Tabela 3 – MAPEs médio e máximo obtidos para os perfis Residencial e Comercial

Perfis	Poder Público Municipal		Serviço Público Água, Esgoto e Saneamento	
	GRNN	GRNN - M	GRNN	GRNN - M
Médio Previsão 1	14.90	13.34	7.68	7.56
Máximo Previsão 1	27.39	21.84	11.70	11.58
Médio Previsão 2	17.06	19.17	8.54	10.35
Máximo Previsão 2	56.83	60.41	12.86	20.97

Tabela 4 – MAPEs médio e máximo obtidos para os perfis Poder Público Municipal e Serviço Público de Água, Esgoto e Saneamento

As Tabelas 5 e 6 são referentes ao tempo médio gasto para o treinamento, validação e previsão diários para os 4 perfis de consumo estudados.

Perfis	Residencial		Comercial	
	GRNN	GRNN - M	GRNN	GRNN - M
Tempo médio gasto (ms)				
Treinamento	18	18	18	16
Validação	15847	4777	7900	2367
Previsão	116	73	115	71

Tabela 5 – Tempo médio gasto para a validação, treinamento e teste de um dia para os perfis de consumo Residencial e Comercial



Perfis	Poder Público Municipal		Serviço Público Água, Esgoto e Saneamento	
	GRNN	GRNN - M	GRNN	GRNN - M
Tempo médio gasto (ms)				
Treinamento	16	17	17	16
Previsão 1	7846	2322	15700	4722
Previsão 2	116	74	115	71

Tabela 6 – Tempo médio gasto para a validação, treinamento e teste de um dia para os perfis de consumo do Poder Público Municipal e Serviço Público de Água, Esgoto e Saneamento

#### 4.2.2 Discussão

Para todos os perfis de consumo, foram utilizados os valores médios de carga de 10 instalações de um sistema de distribuição de energia elétrica de São Paulo para realizar as previsões.

De maneira geral, os MAPEs obtidos na previsão dos perfis Comercial, Poder Público Municipal e Serviço Público de água, esgoto e saneamento são compatíveis com os resultados encontrados na literatura. Estes sistemas foram capazes de realizar a previsão de carga elétricas desagregadas de dias convencionais e feriados com uma boa precisão.

A GRNN modificada foi capaz de fornecer, na maioria dos casos, menores MAPEs diários médios e menores tempos de treinamento quando comparada com a GRNN convencional.

Os resultados ficaram dentro do esperado, dado o estudo da Seção 3.1.5. Os melhores resultados foram obtidos para os perfis Comercial e Serviço Público de água, esgoto e saneamento, dado que foram aqueles que apresentaram maior autocorrelação entre a carga no dia  $d$  e a carga no dia  $d - 1$ .

O perfil de consumo do Poder Público Municipal apresentou MAPEs relativamente mais altos por conta da correlação mais fraca entre dias da semana e finais de semana.

Os MAPEs obtidos na previsão do perfil residencial, por sua vez, demonstraram que os sistemas previsores não foram capazes de generalizar o comportamento destas cargas. Isto ocorre principalmente por que as cargas medidas apresentaram uma autocorrelação bastante fraca e dispersa, diminuindo assim significativamente o poder de predição da rede.

# 5 Conclusões e Trabalhos Futuros

## 5.1 Conclusão

A implementação de *Smart Grids* nos sistemas de distribuição de energia elétrica têm fornecido, cada vez mais, dados com baixa granularidade e em grandes quantidades. Estes dados em grandes quantidades formam históricos cada vez mais robustos, auxiliando no processo de previsão.

Nesse sentido, a previsão de cargas elétricas é uma atividade essencial para as companhias de energia elétrica uma vez que pequenas melhoras nas projeções podem trazer benefícios significativos na gestão, planejamento e manutenção dos sistemas de energia elétrica.

O trabalho de previsão é feito, normalmente, utilizando-se cargas agregadas, uma vez que estas apresentam menor variabilidade. Prever cargas elétricas em níveis mais desagregados, como instalações residenciais ou prédios comerciais se tornam um desafio, uma vez que o comportamento das curvas de carga sofrem influência direta da atividade humana, apresentando uma maior variabilidade.

Neste trabalho, foram implementados dois sistemas previsores, a GRNN e a GRNN modificada, para realizar a previsão de demanda de consumo para 4 perfis distintos. São eles: Perfil Residencial, Comercial, Poder Público Municipal e Serviço Público de água, esgoto e saneamento.

A GRNN é uma rede que vem sendo bastante utilizada para esse tipo de previsão devido a sua grande capacidade de generalização e ao baixo tempo de treinamento e previsão. A GRNN modificada apresenta a mesma capacidade de generalização, produzindo resultados muito semelhantes, ou até melhores, com menor tempo de treinamento.

Para definir as entradas das redes, foram realizados os estudos do Capítulo 3, sobretudo na Seção 3.1.5, para tentar definir as principais variáveis de influência. Estes estudos possibilitaram a modelagem de um sistema previsor de cargas elétricas genérico de curto prazo. Assim, foi possível realizar a previsão sem a necessidade de uma modelagem estatística mais aprofundado nas carga, reduzindo a complexidade do problema.

Para todos os perfis de consumo, foram utilizados os valores médios de carga de 10 instalações de um sistema de distribuição de energia elétrica de São Paulo para realizar as previsões.

De maneira geral, os MAPEs obtidos na previsão dos perfis Comercial, Poder Público Municipal e Serviço Público de água, esgoto e saneamento são compatíveis com os resultados encontrados na literatura. Esses MAPEs foram, em média, de 14,50%, 16,12% e 8,53% respectivamente.

Por fim, os MAPEs obtidos na previsão do perfil residencial, bem como as curvas de cargas previstas dispostas no Apêndice B, demonstraram que os sistemas previsores não foram capazes de generalizar o comportamento para estas cargas. Os MAPEs obtidos para este perfil foram, em média, de 143,13%.

## 5.2 Propostas para Trabalhos Futuros

Algumas possíveis sugestões de trabalhos futuros incluem:

- Implementar filtros para remover outliers e completar dados faltantes, sobretudo para os dados do perfil industrial;
- Elaborar testes para outros perfis de consumo de energia elétrica que não foram explorados neste trabalho;
- Introdução de variáveis exógenas nos sistemas previsores, como dados de umidade, temperatura e dados climáticos de maneira geral;
- Utilização de outras metodologias para comparação de resultados da previsão de cargas elétricas desagregadas no curto prazo.

# Referências

- AL-HAMADI, H.; SOLIMAN, S. Short-term electric load forecasting based on kalman filtering algorithm with moving window weather and load model. *Electric power systems research*, Elsevier, v. 68, n. 1, p. 47–59, 2004. Citado na página 2.
- ALI, D. et al. Long-term load forecast modelling using a fuzzy logic approach. *Pacific Science Review A: Natural Science and Engineering*, Elsevier, v. 18, n. 2, p. 123–127, 2016. Citado na página 2.
- ALVES, M. F. Previsão de cargas não residenciais mistas por redes neurais artmap fuzzy. Universidade Estadual Paulista (UNESP), 2019. Citado 2 vezes nas páginas 2 e 5.
- BOX, G. E. et al. *Time series analysis: forecasting and control*. [S.l.]: John Wiley & Sons, 2015. Citado na página 2.
- CECATI, C. et al. A novel rbf training algorithm for short-term electric load forecasting and comparative studies. *IEEE Transactions on industrial Electronics*, IEEE, v. 62, n. 10, p. 6519–6529, 2015. Citado 2 vezes nas páginas 2 e 5.
- CHEN, B.-J.; CHANG, M.-W. et al. Load forecasting using support vector machines: A study on eunite competition 2001. *IEEE transactions on power systems*, IEEE, v. 19, n. 4, p. 1821–1830, 2004. Citado na página 2.
- CHEN, L.-G. et al. Group-based chaos genetic algorithm and non-linear ensemble of neural networks for short-term load forecasting. *IET Generation, Transmission & Distribution*, IET, v. 10, n. 6, p. 1440–1447, 2016. Citado na página 2.
- CHO, H. et al. Modeling and forecasting daily electricity load curves: a hybrid approach. *Journal of the American Statistical Association*, Taylor & Francis Group, v. 108, n. 501, p. 7–21, 2013. Citado 2 vezes nas páginas 1 e 2.
- DAUT, M. A. M. et al. Building electrical energy consumption forecasting analysis using conventional and artificial intelligence methods: A review. *Renewable and Sustainable Energy Reviews*, Elsevier, v. 70, p. 1108–1118, 2017. Citado na página 2.
- DUDEK, G. Pattern-based local linear regression models for short-term load forecasting. *Electric Power Systems Research*, Elsevier, v. 130, p. 139–147, 2016. Citado na página 2.
- EMANI, C. K.; CULLOT, N.; NICOLLE, C. Understandable big data: a survey. *Computer science review*, Elsevier, v. 17, p. 70–81, 2015. Citado na página 1.
- FELICE, M. D.; YAO, X. Short-term load forecasting with neural network ensembles: A comparative study [application notes]. *IEEE Computational Intelligence Magazine*, IEEE, v. 6, n. 3, p. 47–56, 2011. Citado na página 2.
- FERNÁNDEZ, I.; BORGES, C. E.; PENYA, Y. K. Efficient building load forecasting. In: IEEE. *ETFA2011*. [S.l.], 2011. p. 1–8. Citado na página 5.

- GHAYEKHLOO, M.; MENHAJ, M.; GHOFRANI, M. A hybrid short-term load forecasting with a new data preprocessing framework. *Electric Power Systems Research*, Elsevier, v. 119, p. 138–148, 2015. Citado na página 2.
- GROSS, G.; GALIANA, F. D. Short-term load forecasting. *Proceedings of the IEEE*, IEEE, v. 75, n. 12, p. 1558–1573, 1987. Citado na página 4.
- HAYKIN, S. S. et al. *Neural networks and learning machines/Simon Haykin*. [S.l.]: New York: Prentice Hall,, 2009. Citado 2 vezes nas páginas 2 e 6.
- HONG, T.; FAN, S. Probabilistic electric load forecasting: A tutorial review. *International Journal of Forecasting*, Elsevier, v. 32, n. 3, p. 914–938, 2016. Citado na página 1.
- HONG, T. et al. Modeling and forecasting hourly electric load by multiple linear regression with interactions. In: IEEE. *IEEE PES General Meeting*. [S.l.], 2010. p. 1–8. Citado na página 2.
- HONG, T. et al. Short term electric load forecasting. 2010. Citado 2 vezes nas páginas 6 e 4.
- KEZUNOVIC, M. Smart fault location for smart grids. *IEEE transactions on smart grid*, IEEE, v. 2, n. 1, p. 11–22, 2011. Citado na página 1.
- KHOTANZAD, A. et al. Annstlf-a neural-network-based electric load forecasting system. *IEEE Transactions on Neural networks*, IEEE, v. 8, n. 4, p. 835–846, 1997. Citado na página 2.
- KUO, P.-H.; HUANG, C.-J. A high precision artificial neural networks model for short-term energy load forecasting. *Energies*, Multidisciplinary Digital Publishing Institute, v. 11, n. 1, p. 213, 2018. Citado 2 vezes nas páginas 2 e 6.
- LAMIN, H.; CAMARGO, I. M. de T. Smart grids deployment in brazil: A study from the perspective of a regulatory impact analysis. In: IEEE. *2013 IEEE PES Conference on Innovative Smart Grid Technologies (ISGT Latin America)*. [S.l.], 2013. p. 1–8. Citado na página 1.
- LUTHULI, Q. W.; FOLLY, K. A. Short term load forecasting using artificial intelligence. In: IEEE. *2016 IEEE PES PowerAfrica*. [S.l.], 2016. p. 129–133. Citado na página 2.
- MITCHELL, G. et al. A comparison of artificial neural networks and support vector machines for short-term load forecasting using various load types. In: IEEE. *2017 IEEE Manchester PowerTech*. [S.l.], 2017. p. 1–4. Citado na página 2.
- NOSE-FILHO, K. et al. Short-term multinodal load forecasting using a modified general regression neural network. *IEEE transactions on power delivery*, IEEE, v. 26, n. 4, p. 2862–2869, 2011. Citado 5 vezes nas páginas 2, 3, 5, 8 e 9.
- PAI, P.-F.; HONG, W.-C. Forecasting regional electricity load based on recurrent support vector machines with genetic algorithms. *Electric Power Systems Research*, Elsevier, v. 74, n. 3, p. 417–425, 2005. Citado na página 2.
- PAPALEXOPOULOS, A. D.; HESTERBERG, T. C. A regression-based approach to short-term system load forecasting. *IEEE Transactions on Power Systems*, IEEE, v. 5, n. 4, p. 1535–1547, 1990. Citado na página 2.

- RANAWEERA, D.; HUBELE, N.; KARADY, G. Fuzzy logic for short term load forecasting. *International journal of electrical power & energy systems*, Elsevier, v. 18, n. 4, p. 215–222, 1996. Citado na página 2.
- SADAEI, H. J. et al. Short-term load forecasting method based on fuzzy time series, seasonality and long memory process. *International Journal of Approximate Reasoning*, Elsevier, v. 83, p. 196–217, 2017. Citado na página 2.
- SEVLIAN, R.; RAJAGOPAL, R. A scaling law for short term load forecasting on varying levels of aggregation. *International Journal of Electrical Power & Energy Systems*, Elsevier, v. 98, p. 350–361, 2018. Citado na página 1.
- SIANO, P. Demand response and smart grids—a survey. *Renewable and sustainable energy reviews*, Elsevier, v. 30, p. 461–478, 2014. Citado na página 1.
- SONG, K.-B. et al. Short-term load forecasting for the holidays using fuzzy linear regression method. *IEEE transactions on power systems*, IEEE, v. 20, n. 1, p. 96–101, 2005. Citado na página 2.
- SPECHT, D. A general regression neural network. *IEEE transactions on neural networks*, v. 2, n. 6, p. 568–576, 1991. Citado 2 vezes nas páginas 2 e 6.
- SUYKENS, J. A.; VANDEWALLE, J. Least squares support vector machine classifiers. *Neural processing letters*, Springer, v. 9, n. 3, p. 293–300, 1999. Citado na página 2.
- ZHANG, Y.; HUANG, T.; BOMPARD, E. F. Big data analytics in smart grids: a review. *Energy Informatics*, Springer, v. 1, n. 1, p. 8, 2018. Citado na página 1.
- ZHENG, T.; GIRGIS, A. A.; MAKRAM, E. B. A hybrid wavelet-kalman filter method for load forecasting. *Electric power systems research*, Elsevier, v. 54, n. 1, p. 11–17, 2000. Citado na página 2.
- ZOR, K.; TIMUR, O.; TEKE, A. A state-of-the-art review of artificial intelligence techniques for short-term electric load forecasting. In: IEEE. *2017 6th International Youth Conference on Energy (IYCE)*. [S.l.], 2017. p. 1–7. Citado 2 vezes nas páginas 2 e 4.

# Apêndices

# APÊNDICE A – Previsões de carga

A Seção A.1 apresenta as tabelas com os spreads utilizados para as redes. A seção A.2 apresenta as tabelas com os resultados das previsões de carga para os quatro perfis de consumo estudados. As previsões foram feitas para o período dos dias 08 a 14 de dezembro de 2018 e 22 a 28 de dezembro de 2018, totalizando 14 dias previstos.

## A.1 Spreads utilizados para os sistemas previsores

Perfil	Comercial	Residencial	Poder Público Municipal	Serviço Público Água, Esgoto e Saneamento
Spread	0.695	0.935	0.435	0.705

Tabela 7 – Valores de spread utilizados para a GRNN convencional

Perfil	Comercial	Residencial	Poder Público Municipal	Serviço Público Água, Esgoto e Saneamento
Spread	0.495	0.995	0.445	0.71

Tabela 8 – Valores de spread utilizados para a GRNN modificada



## A.2 MAPEs obtidos para os sistemas previsores

Perfil	Residencial		Comercial	
	GRNN	GRNN - M	GRNN	GRNN - M
<b>Dia</b>				
<b>01/12/2018</b>	126,93	106,36	9,92	9,36
<b>02/12/2018</b>	136,19	105,57	7,89	12,1
<b>03/12/2018</b>	154,91	160,19	14,55	15,33
<b>04/12/2018</b>	105,43	115,61	4,83	3,98
<b>05/12/2018</b>	173,91	155,29	6,1	5,5
<b>06/12/2018</b>	115,17	120,45	8,54	10,89
<b>07/12/2018</b>	93,79	116,24	23,83	29,76
<b>Médio</b>	129,48	125,67	10,81	12,42
<b>Máximo</b>	173,91	160,19	23,83	29,76

Tabela 9 – MAPEs, diários, médios e máximos obtidos para as previsões do período de validação para os perfis de consumo comercial e residencial

Perfil	Residencial		Comercial	
	GRNN	GRNN - M	GRNN	GRNN - M
<b>Dia</b>				
<b>08/12/2018</b>	112,04	118,74	16,68	12,24
<b>09/12/2018</b>	110,43	107,75	37,54	37,64
<b>10/12/2018</b>	132,09	120,33	11,79	12,8
<b>11/12/2018</b>	100,07	122,46	8,00	8,03
<b>12/12/2018</b>	131,86	110,71	9,67	9,55
<b>13/12/2018</b>	125,1	117,48	9,72	9,49
<b>14/12/2018</b>	74,36	88,03	10,77	10,68
<b>Médio</b>	112,28	112,21	14,88	14,35
<b>Máximo</b>	132,09	122,46	37,54	37,64

Tabela 10 – MAPEs, diários, médios e máximos obtidos para o primeiro período de previsão para os perfis de consumo comercial e residencial

Perfil	Residencial		Comercial	
	GRNN	GRNN - M	GRNN	GRNN - M
<b>Dia</b>				
<b>22/12/2018</b>	130,4	154,68	4,32	4,24
<b>23/12/2018</b>	117,79	139,39	14,9	15,08
<b>24/12/2018</b>	84,35	135,64	33,43	34,33
<b>25/12/2018</b>	337,68	278,39	9,13	9,13
<b>26/12/2018</b>	199,07	237,20	14,15	8,95
<b>27/12/2018</b>	199,07	179,89	14,15	14,68
<b>28/12/2018</b>	111,63	131,00	12,32	12,64
<b>Médio</b>	168,57	179,46	14,63	14,15
<b>Máximo</b>	337,68	278,39	33,43	34,33

Tabela 11 – MAPEs, diários, médios e máximos obtidos para o segundo período de previsão para os perfis de consumo comercial e residencial

Perfil	Poder Público Municipal		Serviço Público Água, Esgoto e Saneamento	
	GRNN	GRNN - M	GRNN	GRNN - M
<b>Dia</b>				
<b>01/12/2018</b>	14,48	5,74	6,70	7,06
<b>02/12/2018</b>	12,66	6,12	5,26	5,16
<b>03/12/2018</b>	8,86	6,53	4,28	4,36
<b>04/12/2018</b>	9,43	8,22	4,46	4,35
<b>05/12/2018</b>	11,37	9,32	34,61	34,91
<b>06/12/2018</b>	8,00	6,15	6,41	6,47
<b>07/12/2018</b>	10,27	8,68	6,64	6,38
<b>Médio</b>	10,72	7,25	9,77	9,81
<b>Máximo</b>	14,48	9,32	34,61	34,91

Tabela 12 – MAPEs, diários, médios e máximos obtidos para as previsões do período de validação para os perfis de consumo do Poder Público Municipal e Serviço Público de Água, Esgoto e Saneamento

Perfil	Poder Público Municipal		Serviço Público Água, Esgoto e Saneamento	
	GRNN	GRNN - M	GRNN	GRNN - M
<b>Dia</b>				
<b>08/12/2018</b>	27,39	19,31	4,50	4,49
<b>09/12/2018</b>	17,45	14,12	8,24	8,02
<b>10/12/2018</b>	7,42	7,35	7,71	7,57
<b>11/12/2018</b>	7,15	6,03	6,56	6,42
<b>12/12/2018</b>	12,42	11,97	7,05	6,96
<b>13/12/2018</b>	14,15	12,77	8,00	7,86
<b>14/12/2018</b>	18,34	21,84	11,70	11,58
<b>Médio</b>	14,90	13,34	7,68	7,56
<b>Máximo</b>	27,39	21,84	11,70	11,58

Tabela 13 – MAPEs, diários, médios e máximos obtidos para o primeiro período de previsão para os perfis de consumo do Poder Público Municipal e Serviço Público de Água, Esgoto e Saneamento

Perfil	Poder Público Municipal		Serviço Público Água, Esgoto e Saneamento	
	GRNN	GRNN - M	GRNN	GRNN - M
<b>Dia</b>				
<b>22/12/2018</b>	5,96	10,29	8,02	8,02
<b>23/12/2018</b>	9,48	14,20	12,86	12,65
<b>24/12/2018</b>	20,42	20,74	8,71	8,60
<b>25/12/2018</b>	56,83	60,41	7,77	7,74
<b>26/12/2018</b>	6,63	7,55	7,69	20,97
<b>27/12/2018</b>	6,63	5,17	7,69	7,55
<b>28/12/2018</b>	13,49	15,80	7,03	6,95
<b>Médio</b>	17,06	19,17	8,54	10,35
<b>Máximo</b>	56,83	60,41	12,86	20,97

Tabela 14 – MAPEs, diários, médios e máximos obtidos para o segundo período de previsão para os perfis de consumo do Poder Público Municipal e Serviço Público de Água, Esgoto e Saneamento

# APÊNDICE B – Curvas previstas de carga

A Seção [B.1](#) contém as curvas de carga reais e previstas pela GRNN convencional e pela GRNN modificada para o perfil de consumo residencial.

A Seção [B.2](#) contém as curvas de carga reais e previstas pela GRNN convencional e pela GRNN modificada para o perfil de consumo comercial.

A Seção [B.3](#) contém as curvas de carga reais e previstas pela GRNN convencional e pela GRNN modificada para o perfil de consumo do poder público municipal de são paulo.

Por fim, a Seção [B.4](#) contém as curvas de carga reais e previstas pela GRNN convencional e pela GRNN modificada para o perfil de consumo do serviço público de água, esgoto e saneamento.

O período de validação corresponde aos dias 01 a 07 de dezembro de 2018. As previsões foram feitas para o período dos dias 08 a 14 de dezembro de 2018 e 22 a 28 de dezembro de 2018, totalizando 14 dias previstos.

## B.1 Perfil Residencial




Figura 14 – Curva de carga real e predita para o período de validação




Figura 15 – Curva de carga real e predita para o primeiro período de previsão




Figura 16 – Curva de carga real e predita para o segundo período de previsão

## B.2 Perfil Comercial




Figura 17 – Curva de carga real e predita para o período de validação

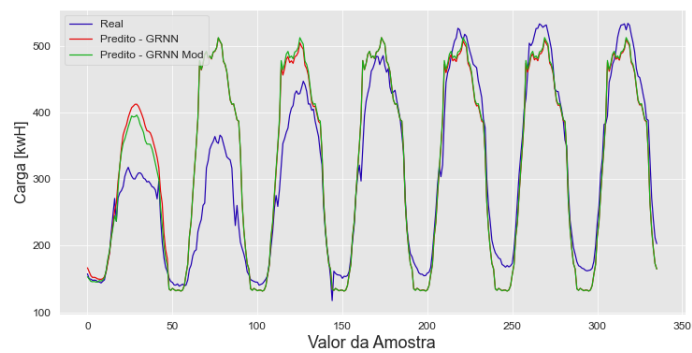


Figura 18 – Curva de carga real e predita para o primeiro período de previsão

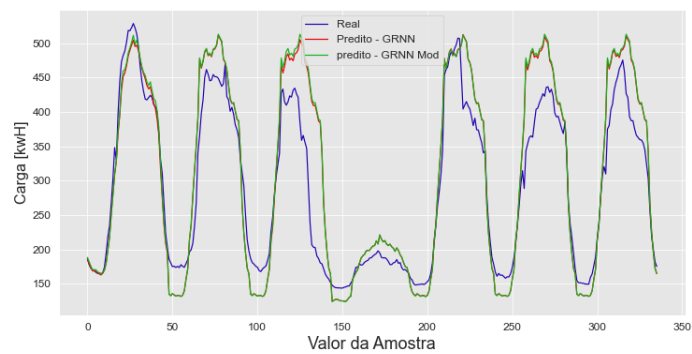


Figura 19 – Curva de carga real e predita para o segundo período de previsão

### B.3 Perfil Poder Público Municipal




Figura 20 – Curva de carga real e predita para o período de validação

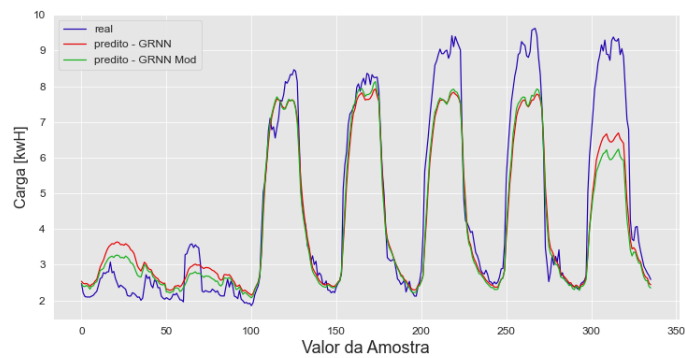


Figura 21 – Curva de carga real e predita para o primeiro período de previsão




Figura 22 – Curva de carga real e predita para o segundo período de previsão

## B.4 Perfil Serviço Público de Água, Esgoto e Saneamento




Figura 23 – Curva de carga real e predita para o período de validação

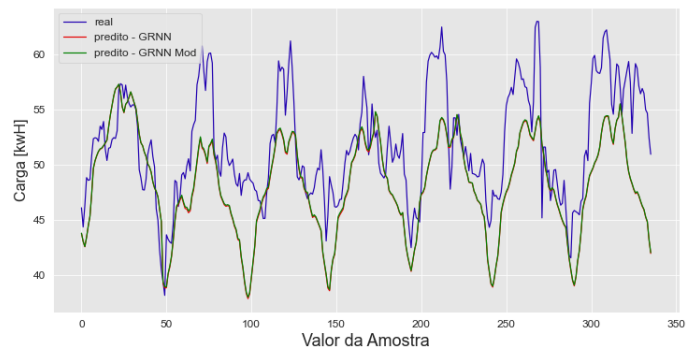


Figura 24 – Curva de carga real e predita para o primeiro período de previsão




Figura 25 – Curva de carga real e predita para o segundo período de previsão