



Daiane de Souza Oliveira

**Previsão horária para o consumo de energia elétrica no
Brasil considerando a contribuição da geração distribuída
fotovoltaica**

Dissertação de Mestrado

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-Graduação em Engenharia de Produção do Departamento de Engenharia Industrial da PUC-Rio.

Orientador: Prof. Reinaldo Castro Souza

Coorientadora: Prof. Soraida Aguilar Vargas

Rio de Janeiro
janeiro de 2022



Daiane de Souza Oliveira

**Previsão horária para o consumo de energia elétrica no
Brasil considerando a contribuição da geração distribuída
fotovoltaica**

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-Graduação em Engenharia de Produção da PUC-Rio. Aprovada pela Comissão Examinadora abaixo.

Prof. Reinaldo Castro Souza

Orientador

Departamento de Engenharia Industrial - PUC-Rio

Prof. Soraida Aguilar Vargas

Coorientadora

Departamento de Engenharia Industrial - PUC-Rio

Prof. Paula Medina Maçaira Louro

Departamento de Engenharia Industrial – PUC-Rio

Prof. Alexandre Zanini

Departamento de Economia - UFJF

Rio de Janeiro, 28 de janeiro de 2022

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização da universidade, do autor e do orientador.

Daiane de Souza Oliveira

Daiane de Souza Oliveira graduou-se em Estatística em 2018 pela Universidade Federal Fluminense (UFF) e cursou Especialização em Finanças pela mesma instituição. Aluna de mestrado da PUC-Rio desde setembro de 2019.

Ficha Catalográfica

Oliveira, Daiane de Souza

Previsão horária para o consumo de energia elétrica no Brasil considerando a contribuição da geração distribuída fotovoltaica / Daiane de Souza Oliveira; orientador: Reinaldo Castro Souza; coorientadora: Soraida Aguilar Vargas. – 2022.

95 f.: il. color.; 30 cm

Dissertação (mestrado) – Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Industrial, 2022.

Inclui bibliografia

1. Engenharia Industrial – Teses. 2. Micro e minigeração distribuída. 3. Previsão de carga. 4. Energia solar fotovoltaica. 5. Previsão de demanda. 6. Setor elétrico brasileiro. I. Souza, Reinaldo Castro. II. Aguilar Vargas, Soraida. III. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Industrial. IV. Título.

CDD: 658.5

Agradecimentos

Primeiramente, agradeço a Deus, que me concedeu a força que eu necessitava para seguir em frente e continuar realizando meus sonhos.

Aos meus pais, Nilcemar e Agenor, por todo o amor, compreensão e apoio. Obrigada, mãe, por todas as palavras de incentivo que acalmaram meu coração durante todo o período de realização deste trabalho.

À minha família e aos meus amigos, pelo carinho e encorajamento.

Ao meu orientador, Reinaldo Castro, por todo conhecimento compartilhado e por ter aceitado estar me instruindo durante esta jornada.

À minha coorientadora, Soraida Aguilar, pela paciência e por todos os conselhos.

Ao meu colega, Rafael Duarte, por toda ajuda e paciência.

Aos professores que aceitaram o convite para participar da banca de avaliação desta dissertação, pelo tempo concedido e recomendações.

Aos professores e funcionários do Departamento de Engenharia Industrial da PUC-Rio, por estarem sempre presentes, ensinando e auxiliando, mesmo à distância.

A todos os professores que passaram pela minha vida, essa vitória é NOSSA.

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

Resumo

Oliveira, Daiane; Castro, Reinaldo (orientador); Aguilar, Soraida (coorientadora). **Previsão horária para o consumo de energia elétrica no Brasil considerando a contribuição da geração distribuída fotovoltaica.** Rio de Janeiro, 2022. 95 p. Dissertação de Mestrado – Departamento de Engenharia Industrial, Pontifícia Universidade Católica do Rio de Janeiro.

No Brasil, devido aos incentivos governamentais ministrados na área de energia renovável, é postulada uma perspectiva crescente no número de instalações de micro e minigeração distribuída (MMGD), sendo a fonte solar destaque no país. Dessa forma, o aumento na inserção de fontes intermitentes promove alterações significativas no comportamento da curva de carga horária, podendo atingir de maneira direta a operação e o planejamento da rede elétrica. Para atender aos novos panoramas dispostos pelo sistema elétrico brasileiro, esta dissertação propõe uma nova metodologia para contabilizar a geração distribuída fotovoltaica para as horas que compõem o dia. Usando o modelo Holt-Winters Sazonal Duplo são feitas previsões de carga e demanda para o Sistema Interligado Nacional e os subsistemas que o integram, considerando, em particular, o impacto causado pela conexão destes sistemas de MMGD solar fotovoltaica na rede de distribuição. Para as previsões são utilizados o horizonte de tempo de 24 horas, em intervalos horários, efetuadas para a primeira semana de 2020. Os resultados indicam que a metodologia proposta para a criação das séries de geração distribuída fotovoltaica é válida, pois é observada uma diminuição dos erros de previsão para a série de demanda, constituída pelo montante da geração distribuída adicionado a carga. Os valores de MAPE analisados neste trabalho não ultrapassam 10% para dias típicos, exceto feriados, indicando que o método apresentado é um recurso eficiente.

Palavras-chave

Micro e minigeração distribuída; Previsão de carga; Energia solar fotovoltaica; Previsão de demanda; Setor elétrico brasileiro.

Abstract

Oliveira, Daiane; Castro, Reinaldo (advisor); Aguilar, Soraida (co-advisor). **Hourly forecast for electricity consumption in Brazil considering the contribution of distributed photovoltaic generation.** Rio de Janeiro, 2022. 95 p. Dissertação de Mestrado – Departamento de Engenharia Industrial, Pontifícia Universidade Católica do Rio de Janeiro.

In Brazil, due to government incentives given in the area of renewable energy, a growing perspective in the number of micro and mini distributed generation (MMGD) installations is postulated, being the solar source highlighted in the country. Thus, the increase in the insertion of intermittent sources promotes significant changes in the behavior of the hourly load curve, which can directly affect the operation and planning of the electrical network. To meet the new panoramas provided by the Brazilian electricity system, this dissertation proposes a new methodology to account for distributed photovoltaic generation for the hours that make up the day. Using the Double Seasonal Holt-Winters model, load and demand forecasts are made for the National Interconnected System and the subsystems that integrate it, considering, in particular, the impact caused by the connection of these solar photovoltaic MMGD systems in the distribution network. For the forecasts, the 24-hour time horizon is used, in hourly intervals, carried out for the first week of 2020. The results indicate that the proposed methodology for the creation of distributed photovoltaic generation series is valid, as it is observed a decrease in the forecast errors for the demand series, constituted by the amount of the distributed generation added to the load. The MAPE values analyzed in this work do not exceed 10% for typical days, except holidays, indicating that the presented method is an efficient resource.

Keywords

Micro and mini distributed generation; Load forecast; Photovoltaic solar energy; Demand forecast; Brazilian electricity sector.

Sumário

1	Introdução	11
1.1	Objetivos	14
1.1.1.	Objetivos Específicos	14
1.2	Organização	14
2	Revisão da Literatura	16
3	Contextualização	22
3.1	Características das Curvas de Carga	22
3.2	Micro e Minigeração Distribuída	27
3.2.1	Geração Fotovoltaica	30
3.3	Bases de Dados de Reanálise	35
4	Metodologia	37
4.1	Metodologia para o cálculo da estimativa da GD fotovoltaica	37
4.2	Modelos de Suavização Exponencial	42
4.2.1	Modelo Holt-Winters Sazonal Duplo	44
5	Resultados	46
5.1	Dados	46
5.2	Características das Séries de Geração Fotovoltaica	47
5.3	Resultado das previsões	51
5.3.1	Sistema Interligado Nacional (SIN)	52
5.3.2	Subsistema Norte (NO)	58
5.3.3	Subsistema Nordeste (NE)	61
5.3.4	Subsistema Sudeste/Centro-Oeste (SE/CO)	64
5.3.5	Subsistema Sul (S)	67
5.4	Projeções de Carga e Demanda	70
6	Conclusões	76
	Referências bibliográficas	78
	Anexo A	87

Lista de figuras

Figura 1: Perfil de carga de 24 a 30 de junho de 2019.....	23
Figura 2: Perfil de carga do dia 1 de julho de 2019.....	24
Figura 3: Perfil de carga de três anos (2018 a 2020) – Dados brasileiros.	25
Figura 4: Histórico da capacidade instalada de MMGD no Brasil.....	29
Figura 5: Participação na geração de energia.....	31
Figura 6: Estimativa da geração proveniente de sistemas de MMGD no ano. ...	33
Figura 7: Localidades selecionadas para cada subsistema.....	39
Figura 8: Boxplots das séries de geração distribuída fotovoltaica considerando as horas do dia.....	48
Figura 9: Boxplots das series de geração distribuída fotovoltaica considerando os meses do ano.	49
Figura 10: Curvas típicas de geração distribuída fotovoltaica por dia da semana para o SIN.	50
Figura 11: Previsões para o dia 01/01/2020 – SIN.....	53
Figura 12: Previsões para o dia 02/01/2020 – SIN.....	54
Figura 13: Previsões para o dia 03/01/2020 – SIN.....	55
Figura 14: Previsões de carga e demanda para o Sistema Interligado Nacional (SIN).....	56
Figura 15: Previsões de carga e demanda para o subsistema Norte.	60
Figura 16: Previsões de carga e demanda para o subsistema Nordeste.....	63
Figura 17: Previsões de carga e demanda para o subsistema Sudeste/Centro-Oeste.....	66
Figura 18: Previsões de carga e demanda para o subsistema Sul.....	69
Figura 19: Crescimento esperado da carga e da demanda para o Sistema Interligado Nacional (SIN).....	72
Figura 20: Crescimento esperado da carga e da demanda para o subsistema Norte.....	73
Figura 21: Crescimento esperado de carga e demanda para o subsistema Nordeste.	73
Figura 22: Crescimento esperado da carga e da demanda para o subsistema Sudeste/Centro-Oeste.	74
Figura 23: Crescimento esperado da carga e da demanda para o subsistema Sul.	75

Lista de tabelas

Tabela 1: Projeção para a MMGD (PDE 2029 e PDE 2030).	30
Tabela 2: Localidades selecionadas para o subsistema Norte.....	38
Tabela 3: Comparação das bases ERA-5 <i>land</i> (ECMWF) e MERRA-2 (NASA). ..	39
Tabela 4: Estatísticas descritivas das séries de geração distribuída fotovoltaica (MWh).....	47
Tabela 5: Resultado das métricas de avaliação para os modelos de previsão do SIN.	57
Tabela 6: Resultado das métricas de avaliação para os modelos de previsão do subsistema Norte.....	58
Tabela 7: Resultado das métricas de avaliação para os modelos de previsão do subsistema Nordeste.	61
Tabela 8: Resultados das métricas de avaliação para os modelos de previsão do subsistema Sudeste/Centro-Oeste.	64
Tabela 9: Resultados das métricas de avaliação para os modelos de previsão do subsistema Sul.	67
Tabela 10: Estimativa de crescimento da carga e MMGD para os próximos anos.	71
Tabela 11: Localidades selecionadas para o subsistema Nordeste.	87
Tabela 12: Localidades selecionadas para o subsistema Sul.	88
Tabela 13: Localidades selecionadas para o subsistema Sudeste/Centro-Oeste.	91

Glossário

EPE – Empresa de Pesquisa Energética

Cepel – Centro de Pesquisas de Energia Elétrica

ONS – Operador Nacional do Sistema Elétrico

CCEE – Câmara de Comercialização de Energia Elétrica

ANEEL – Agência Nacional de Energia Elétrica

CPAMP – Comissão Permanente para Análise de Metodologias e programas

Computacionais do Setor Elétrico

SIN – Sistema Interligado Nacional

1 Introdução

As fontes de energia são indispensáveis para o desenvolvimento de um país, sendo elas finitas ou esgotáveis. Segundo a Empresa de Pesquisa Energética (EPE, 2021a), o mundo possui uma matriz energética composta, essencialmente, por fontes não renováveis. As fontes não renováveis e as fontes renováveis representam aproximadamente 86% e 14%, respectivamente, da matriz energética mundial. No entanto, a matriz energética do Brasil exibe características bem distintas, apresentando um aumento significativo na utilização de fontes renováveis.

A matriz elétrica do Brasil, ou seja, o grupo de fontes disponíveis somente para a geração de energia elétrica, é predominantemente renovável, fato que favoreceu o crescimento da micro e minigeração distribuída dentro do território brasileiro. De acordo com o Balanço Energético Nacional (BEN) de 2020 (ano base 2019) (EPE, 2020a), as fontes renováveis caracterizam 83% da oferta interna de eletricidade no Brasil (considerando a soma dos montantes relativos à produção nacional e importação), sendo 64,9% desta oferta representada pela fonte hídrica. Conseqüentemente, a geração elétrica a partir de fontes não renováveis simbolizou apenas 17,7% do total nacional em 2019 e 17,6% em 2018. O incremento das fontes eólica e solar na geração de energia elétrica e a progressão da oferta de biomassa da cana e biodiesel, contribuíram para que a matriz energética brasileira se mantivesse em destaque renovável superior ao testemunhado em outros países.

Nos dias atuais, é visível o crescente incremento de fontes alternativas, limpas e sustentáveis, como a geração solar fotovoltaica, a qual se destaca no Plano Decenal de Expansão de Energia, sendo a principal fonte que responde por aproximadamente 93% da expansão (MME/EPE, 2021). No entanto, apesar do alto potencial solar do Brasil, a geração deste tipo de energia é afetada por características intermitentes, como as radiações solares. Destaca-se também, que as incertezas presentes na geração de energia solar são mais significativas se comparadas as incertezas atribuídas a geração da energia hidráulica, que podem ser reduzidas através da construção de reservatórios de água. Inclusive, Tahir *et al.* (2020a),

afirma que os dados de radiação solar são essenciais para efetuar a estimativa do potencial de energia solar, e que no caso da falta de dados é possível utilizar a radiação contida em conjuntos de reanálise.

Conforme o BEN (EPE, 2020), o consumo final energético no Brasil, que corresponde ao uso de fontes pelos setores da economia como energia, apresentou uma evolução de 1,3% entre 2018 e 2019, no qual os setores industrial, residencial e comercial se destacaram, expondo um consumo de 79,4% da energia elétrica disponibilizada no país (ano base 2019). Nota-se também o aumento na modalidade de micro e minigeração distribuída (MMGD) que segundo o PDE 2029 (MME/EPE, 2020) alcançou, em junho de 2019, a marca de 1 GW instalados e as projeções indicam que essa capacidade pode chegar a atingir 11,4 GW em 2029. À vista disso, vários tipos de projeções são efetuadas dentro do setor elétrico, dado que o consumo de energia não é caracterizado apenas pelas variáveis do próprio sistema de energia, mas também relacionado a fatores socioeconômicos e climáticos.

A projeção de carga elétrica é conhecida como um dos desafios mais importantes no gerenciamento da oferta e demanda elétrica e tem sido amplamente estudada, pois é um elemento essencial para ampliar a eficiência energética e a confiabilidade da operação do sistema de energia. Nota-se que a agregação de fontes renováveis ao sistema de geração trouxe mudanças significativas para o setor elétrico, principalmente após as gerações centralizadas experimentarem a introdução de sistemas de MMGD, que causam distorções nos perfis de carga (Abdelsamad *et al.*, 2015). Dessa forma, verifica-se a necessidade da utilização de uma metodologia que seja capaz de contabilizar a energia gerada por sistemas de geração distribuída (GD), para, futuramente, analisar como a curva de carga é afetada pelo aumento das instalações de GD no território brasileiro.

Compreendendo a importância do planejamento eficiente dos sistemas de energia, diversas abordagens para a previsão de carga têm sido propostas. Raza e Khosravi (2015) apresentaram uma revisão sistemática da literatura sobre técnicas de previsão de carga de curto prazo baseadas em inteligência artificial (IA). Na qual exploraram a necessidade de identificar e acomodar os fatores que afetam a demanda de carga, tais como dados meteorológicos. Entre os métodos analisados, as redes neurais artificiais (RNA) ganharam destaque. Neste estudo, foram

apontadas as diferenças existentes entre a rede neural de camada única e a multicamadas, o tipo de arquitetura de rede (rede neural *feed forward* e rede neural de *feedback*) e os tipos de aprendizagem (supervisionada ou não supervisionada). Os modelos híbridos também foram examinados, pois segundo a literatura investigada, a hibridização de uma ou mais técnicas, acopladas a RNA, mostram melhores desempenhos.

Por sua vez, Kuster *et al.* (2017) realizaram uma revisão sistemática da literatura atribuída à previsão de carga elétrica que visava identificar quais, entre os modelos observados na literatura, dispõem de uma melhor capacidade preditiva, considerando cenários diferenciados. No total, foram analisados 113 estudos de caso provenientes de 41 trabalhos com enfoque acadêmico. Como desfecho, para previsões de curto prazo, as técnicas embasadas em redes neurais artificiais, máquinas de vetores de suporte (SVM) e análise de séries temporais (modelos ARIMA – auto-regressivo integrado de médias móveis) manifestaram uma performance relativamente superior aos demais modelos propostos. Os autores afirmam que a previsão proporciona informações consistentes e eficazes para a demanda de eletricidade e que os modelos estatísticos também fornecem bons resultados quando são aplicados para prever valores futuros de séries de carga.

Estudos também foram realizados com base em técnicas de suavização exponencial. Em especial, Abdul Karim e Alwi (2013), destacaram a melhora significativa nos erros de predição, considerando o erro médio absoluto percentual (MAPE), em comparação aos modelos de médias móveis (MA). Isto posto, nesta dissertação busca-se estudar a aplicação de um modelo de suavização exponencial, conhecido como modelo Holt-Winters Sazonal Duplo, que contempla os ciclos sazonais presentes nas séries de carga, propiciando pareceres importantes para o setor de energia elétrica. Considera-se igualmente, a importância da quantificação do efeito resultante do crescimento da micro e minigeração distribuída nos perfis de carga, contemplando, em especial, a energia solar fotovoltaica e os fatores intermitentes ligados a ela, como os níveis de radiação solar. Devido à falta de disponibilidade e atualização de dados públicos que mensuram a energia gerada por sistemas de MMGD fotovoltaica, torna-se necessário a estimação destes dados para o Brasil. Além disso, à escassez de dados de radiação solar no Brasil, principalmente dados para um longo período de tempo e para grandes territórios,

faz com que as bases de reanálise sejam uma alternativa promissora para lidar com este tipo de problema, trazendo bons resultados.

1.1 Objetivos

Este trabalho visa desenvolver modelos de previsão de carga e demanda de curto prazo (24 horas à frente) tendo como base a classe de modelos estatísticos. O intuito é estudar os novos perfis de carga dos consumidores brasileiros considerando as possíveis alterações causadas pela inclusão da modalidade de micro e minigeração distribuída fotovoltaica.

1.1.1. Objetivos Específicos

Como objetivos específicos, pode-se destacar:

- Efetuar o cálculo da estimativa da micro e minigeração distribuída fotovoltaica para cada um dos subsistemas que compõem o Sistema Interligado Nacional;
- Realizar uma análise descritiva das séries de carga, demanda e micro e minigeração distribuída fotovoltaica;
- Identificar os fatores que afetam os perfis das curvas de carga;
- Obter previsões das séries de carga e demanda para o período de 24 horas à frente;
- Avaliar como a inclusão da micro e minigeração distribuída afeta os perfis das curvas de carga.

1.2 Organização

Esta dissertação está estruturada em seis capítulos, sendo eles: Introdução, Revisão da Literatura, Contextualização, Metodologia, Resultados e Conclusões, além das Referências Bibliográficas.

O Capítulo 1 consiste em uma introdução sobre o que foi tratado nesta dissertação, contextualizando e apresentando o objetivo deste estudo. O Capítulo 2 apresenta uma breve revisão da literatura, destacando os artigos mais pertinentes para o desenvolvimento desta dissertação. No Capítulo 3 é possível observar com mais detalhes os principais tópicos abordados nesse trabalho. No Capítulo 4 é exposta a metodologia proposta para o cálculo das séries de geração distribuída fotovoltaica e é evidenciado o modelo que será utilizado para a realização das previsões de carga e demanda. O Capítulo 5 apresenta os resultados das previsões realizadas com base no modelo sugerido, seguido da análise das métricas de erro. O Capítulo 6 finaliza a dissertação com as conclusões alcançadas de acordo com a metodologia adotada, suas limitações e possíveis ideias para trabalhos futuros.

2 Revisão da Literatura

Diversos modelos para previsão de carga têm sido abordados na literatura. Uma busca inicial nas bases da *Scopus* e *Web of Science*, realizada em 6 de dezembro de 2020, resultou em 871 artigos relevantes, onde foi possível observar a complexidade do assunto e a grande variedade de metodologias para o tema. Devido ao alto volume de artigos e as diferentes abordagens utilizadas para a previsão da carga, foi possível agrupá-los em cinco áreas distintas: Modelos Estatísticos (10,91%), Inteligência Computacional (18,60%), Redes Neurais (28,70%), Modelos Híbridos (38,69%) e Lógica Fuzzy (3,10%).

Desde muito cedo, métodos estatísticos têm sido estudados na área de previsão de carga. Nakamura (1985), afirma que a previsão de carga é uma das tarefas mais importantes dentro de uma empresa de energia, visto que a energia gerada deve ser capaz de acompanhar as demandas de carga. Em 1989, foi destacado a relevância da aplicação de modelos estatísticos clássicos (Box & Jenkins, Suavização Exponencial e Regressão Linear Múltipla) na previsão de carga horária, para um horizonte de tempo de até 24 horas, durante os picos de inverno e verão (Moghram e Rahman, 1989). A importância dos modelos de Box & Jenkins, no âmbito da previsão de carga, é demonstrada por trabalhos como Chen *et al.* (1995), Huang (1997) e Alvarado-Barrios *et al.* (2020). Da mesma maneira, a influência dos modelos de Suavização Exponencial pode ser observada nos estudos realizados por Taylor (2008, 2012).

Devido ao grande avanço tecnológico, observado no decorrer dos anos, cresceram os estudos que abordam métodos de inteligência computacional. Na área de previsão de carga, a quantidade de trabalhos que aplicam estes métodos é bem expressiva. Com a progressiva utilização de métodos de aprendizado de máquina, isto é, sistemas estruturados para aprender a partir de dados, ampliou-se o estudo das RNAs. O surgimento das redes neurais artificiais se deu através da associação de um sistema computacional com o cérebro humano. De início, a finalidade era criar um sistema com base em algoritmos computacionais que fosse capaz de

realizar tarefas que o cérebro executa, como, por exemplo, o reconhecimento de padrões.

Segundo Papalexopoulos e Hesterberg (1990), a acurácia das previsões de carga de curto prazo afeta de maneira significativa os procedimentos realizados no sistema de energia. Dessa forma, erros estatisticamente significativos nos valores preditos são capazes de gerar alterações na programação do sistema, causando graves penalidades econômicas. Portanto, declaram que incorporar fatores além do comportamento recente da carga, como, por exemplo, efeito de dias atípicos e temperatura, é essencial para melhorar a performance dos modelos de previsão. Em virtude da necessidade de integrar novas variáveis aos modelos de previsão de carga, Park *et al.* (1991) empregou uma RNA para aprender a relação entre temperaturas e cargas passadas, atuais e futuras. A rede neural realizou uma interpolação entre os dados de carga e temperatura, presentes no conjunto de dados de treinamento e, com os dados de teste, verificou-se a eficácia para as previsões de 1 hora e 24 horas à frente. Os resultados foram satisfatórios, gerando erros absolutos médios de 1,40% e 2,06%, respectivamente. No ano seguinte, Lee *et al.* (1992), obteve bons resultados ao testar a aplicação de uma RNA para dados de carga que continham dois padrões distintos, aqueles observados nos dias da semana e aqueles presentes nos dias de fim de semana.

Mais tarde, Khwaja *et al.* (2020) demonstrou como ocorreu avanços significativos no uso de redes neurais artificiais para melhorar a previsão de carga de eletricidade de curto prazo. Abordando uma técnica de combinação que consistia em treinar um conjunto de vários modelos de RNA em paralelo e calcular a média das cargas previstas destes modelos para obter a carga final, ele comprovou que ao treina-los sequencialmente, o erro de predição era minimizado. Novamente, o uso de RNAs se mostrou extremamente promissor, testemunhando uma redução de viés e variância em comparação a uma única RNA. Outros estudos que demonstraram a evolução das redes neurais artificiais são Ilic *et al.* (2013), Shi *et al.* (2018) e Kong *et al.* (2019).

Em razão do aumento do poder computacional e da abundância de dados gerados, alguns estudos debateram a previsão de carga elétrica dentro do contexto de *Big Data*. Segundo Zhang *et al.* (2015), a implementação de medidores inteligentes inovou o modo como as informações são repassadas e usadas para a

previsão de carga de curto prazo. No entanto, os autores atentam para o fato que a quantidade de dados provenientes dos medidores atingiu a escala *terabyte* (TB) ou *petabyte* (PB) e, que por este motivo, apenas um método de previsão pode não ser capaz de prever adequadamente a carga e avaliar todos os fatores associados a ela. Dessa forma, a estrutura oferecida neste estudo incluiu cinco etapas, que buscaram categorizar padrões de carga diários individuais (Análise de *Cluster*), identificar fatores influentes (Análise de Associação), estabelecer regras de classificação entre os fatores de influência crítica e os padrões observados (Árvores de Decisão), para, posteriormente, construir os modelos de previsão conforme os diferentes padrões de carga, utilizando máquinas de vetores de suporte (SVM), impulsionando assim, a obtenção da carga total prevista do sistema. Os resultados se mostraram pertinentes, concedendo maior precisão para as previsões realizadas.

Metaxiotis *et al.* (2003), apresentaram um estudo cujo principal intuito era fornecer para os pesquisadores uma visão geral de tecnologias de inteligência artificial (IA) aplicadas na previsão de carga elétrica de curto prazo. Conforme os autores, a expansão que ocorreu no campo da inteligência artificial nas últimas décadas possibilitou a resolução de diversas problemáticas e influenciou positivamente no processo de apoio à decisão. Uma grande variedade de métodos de previsão de curto prazo foi discutida. Dentre eles, os modelos estatísticos (técnicas convencionais de suavização, métodos de regressão e modelos de séries temporais) se mostraram populares, no entanto, os autores alertam para o fato da dificuldade inerente que esses modelos manifestam para se adaptar a condições climáticas atípicas e feriados, fatores que constituem uma relação não linear com a carga diária. Prontamente, os métodos de IA revelaram uma melhor capacidade para lidar com a não linearidade observada. Como conclusão, os sistemas especialistas (ES) e as redes neurais artificiais (RNAs) foram considerados os métodos mais influentes neste campo. Além disso, é possível destacar as vantagens que as RNAs possuem sobre os outros métodos, visto que ostentam a habilidade de extrair a relação não linear implícita entre as variáveis de entrada.

O princípio da incerteza serviu como alicerce para o desenvolvimento da lógica *fuzzy*, mais comumente denominada, lógica difusa. Novamente, como em redes neurais, foi considerado o próprio cérebro humano como base para sua criação, sendo um algoritmo que apresenta uma forma de "raciocinar" muito semelhante ao

método de raciocínio humano, fundamentado em aproximações e rodeado de incertezas e suposições. Conforme Wagner (2003), a lógica *fuzzy* é uma ferramenta capaz de reter informações vagas, que são normalmente descritas em linguagem natural, alterando estas informações para o formato numérico que apresenta fácil manipulação. Mori e Kobayashi (1996), desenvolveram um estudo cuja ideia principal era construir uma estrutura ótima de inferência *fuzzy* simplificada, com intuito de minimizar os erros relacionados ao modelo e ao escalonamento das funções de pertinência, facilitando a compreensão do comportamento não linear das cargas de curto prazo do sistema de potência. Posteriormente, Khosravy *et al.* (2012), efetuou um estudo comparativo onde foi testado a aplicação do então intitulado *Interval Type-2 Fuzzy Logic Systems (IT2 FLSs)*, que se mostrou uma ferramenta conveniente para lidar com as incertezas presentes na operação dos sistemas de energia e no comportamento inesperado de variáveis exógenas. Segundo os autores, experimentos conduzidos com conjuntos de dados reais mostraram que os modelos IT2 FLSs se aproximavam com precisão das demandas de carga futura.

Em um trabalho mais recente, Ebrahimi e Moshari (2013) aplicaram a metodologia *fuzzy* na previsão de carga de curto prazo para feriados. Segundo os autores, o tópico em questão é desafiador, especialmente porque os feriados apresentam um perfil de carga incomum e os dados para estes dias podem ser considerados insuficientes. Ademais, é destacado que a aparência da curva de carga dos feriados sofre uma alteração a cada ano com base nas características do próprio feriado e do tipo de dia da semana em que ele se manifesta. Várias pesquisas envolvidas com este tema foram relatadas e muitas delas fizeram uso de métodos como lógica difusa, redes neurais artificiais e métodos combinados. O trabalho em foco, propôs não somente a utilização de um sistema especialista *fuzzy*, mas também a abordagem de dias semelhantes. A técnica proposta foi testada na rede de eletricidade de Isfahan (Irã), considerando feriados lunares e solares. Os resultados transmitiram a complexidade da previsão de carga para feriados religiosos, entretanto, o método proposto evidenciou um desempenho adequado.

As pesquisas com lógica difusa na área de energia continuaram com o passar dos anos, e hoje, é possível observar um grande acervo de trabalhos que fazem uso da lógica *fuzzy* em complemento a outros métodos de previsão. Esses casos são

expostos em Liang e Cheng (2002), Khosravi e Nahavandi (2014) e Santika *et al.* (2017).

Os modelos que combinam diversas técnicas para melhorar as previsões, ou seja, modelos híbridos, apresentaram uma grande aceitação da comunidade científica quando o assunto é a previsão de carga. As técnicas atuais continuam sendo aperfeiçoadas, porém novas metodologias combinadas estão sendo desenvolvidas com o objetivo de melhorar a exatidão dos valores preditos e sua confiabilidade. Alguns trabalhos que associam múltiplos métodos para previsão de carga podem ser destacados: wavelet, redes neurais artificiais e modelo ARIMA (modelo auto-regressivo integrado de médias móveis) (Fard e Akbari-Zadeh, 2014); *support vector regression* (SVR) e *modified firefly algorithm* (MFA), resultando em um algoritmo híbrido MFA-SVR (Kavousi-Fard *et al.*, 2014); *Support Vector Regression* (SVR) e algoritmo *cuckoo search* (CS), ocasionando em um modelo SVR com busca de cuco caótico, denominado SVRCCS e em um modelo SSVRCCS (que considera a variação sazonal) (Dong *et al.*, 2018); método de decomposição em modo empírico (EMD), PSO e SVR, que foram combinados para gerar o modelo H-EMD-SVR-PSO, que melhorou significativamente a precisão das previsões (Hong e Fan, 2019); entre outros.

Mesmo diante de uma gama de métodos, os modelos estatísticos ainda são destaque, pois não existe um consenso na literatura sobre a superioridade de um determinado método para a previsão de carga de curto prazo. Trabalhos realizados na área mostraram a utilização destes modelos desde o momento da validação e filtragem dos dados (Bui *et al.*, 2020), até a incorporação de variáveis exógenas, como, por exemplo, a temperatura, com a finalidade de analisar os efeitos vindos de fontes externas na tendência cíclica da carga elétrica (Cui *et al.*, 2015).

Um trabalho mais recente efetuado por Shah *et al.* (2021), apontou os desafios observados na rede elétrica moderna, que lida com fatores como a incorporação de energia renovável em grande escala e drásticas mudanças climáticas. Foi enfatizado o uso de diferentes abordagens para realizar a previsão de carga e geração, comparando múltiplos métodos univariados e multivariados. Entre os modelos analisados destacam-se os modelos sazonais, mais especificamente, o SARIMA e as classes aditiva e multiplicativa do método Holt-Winters, os resultados são promissores.

Taylor (2003) observou em uma série de demanda de eletricidade dois padrões distintos de sazonalidade e levando em consideração a necessidade de se obter um método que fosse capaz de capturar estes dois ciclos (diário e semanal), desenvolveu o modelo Holt-Winters Sazonal Duplo, mediante os modelos expostos por Winters (1960). Em um estudo posterior, Taylor e McSharry (2007) usaram dez séries de carga de curto prazo, provenientes de países europeus, e ao investigar diversos modelos preditivos puderam corroborar a eficiência do método proposto por Taylor (2003). Sendo assim, devido ao número limitado de estudos que contemplam os ciclos sazonais presentes nas séries de carga elétrica e que não abrangem o aumento de sistemas de MMGD como um fator que afeta diretamente o perfil de carga dos consumidores brasileiros, este trabalho propõe analisar a acurácia deste modelo de duplo ciclo, apresentado por Taylor (2003), através da aplicabilidade em séries de carga e demanda horárias do Brasil, atentando para as modificações ocorridas nos perfis das curvas de carga perante a crescente inclusão da micro e minigeração distribuída fotovoltaica no país.

3 Contextualização

Neste capítulo, para o melhor entendimento desta dissertação, serão expostas considerações essenciais sobre o setor de energia do Brasil, tendo como foco os perfis das curvas de carga e a atual situação da micro e minigeração distribuída no país.

3.1 Características das Curvas de Carga

A curva de carga pode ser caracterizada como um registro horário, em um período diário, das demandas de capacidade de energia elétrica, podendo ser reproduzida para períodos semanais, mensais e anuais. O estudo do perfil das curvas de carga contribui para o planejamento do setor energético, pois auxilia com informações essenciais para a tomada de decisões técnicas e econômicas, que, por sua vez, implicarão em uma gestão operacional mais eficaz para o sistema elétrico brasileiro. Segundo Queiroz (2011), o conhecimento da curva de carga também permite uma análise mais meticulosa sobre o melhor enquadramento tarifário do consumidor, tornando possível a execução de ações de eficiência energética, através do gerenciamento da demanda, resultando na redução de tarifas e consumo. Balasubramanian e Balachandra (2021), afirmam que as transformações que estão ocorrendo no setor elétrico, mais especificamente, à inserção de novas tecnologias e fontes de energia renováveis, impuseram mais variabilidade no mercado de eletricidade, estabelecendo assim, novos desafios para o planejamento e operação. Por este motivo, estudar as causas destas variações e desenvolver modelos que possam ser capazes de capturá-las, tornou-se uma temática de extrema importância para a evolução do setor.

Conforme Balachandra e Chandru (1999), o consumo de eletricidade apresenta padrões e níveis de variabilidade que são influenciados por diversos fatores. De acordo com Raza e Khosravi (2015), a curva de carga apresenta uma variação cíclica ao longo das horas que compõem o dia, causada pela demanda

diária proveniente da rotina do consumidor. No entanto, fatores meteorológicos, sociais e econômicos, também afetam a curva de carga de maneira periódica. De acordo com a Empresa de Pesquisa Energética (EPE, 2020b), fatores como a alteração de hábitos de consumo, adoção de novas tecnologias e o efeito causado pelo crescimento diferenciado das classes de consumo, podem influenciar significativamente, no longo prazo, o perfil da curva de carga horária.

Como as curvas de carga refletem o perfil de consumo de energia elétrica, Raza e Khosravi (2015) afirmam que os fins de semana (sábado e domingo), assim como os feriados, retratam um comportamento distante do padrão dos dias úteis (segunda-feira a sexta-feira). Em alguns casos, o perfil de carga é afetado por atividades cotidianas, ligadas, por exemplo, a horários escolares e de trabalho. Desse modo, Raza e Khosravi (2015) destacam que nos dias úteis a demanda de carga é superior à demanda observada em dias de folga, e que essa diferença é atribuída ao aumento das atividades sociais. A Figura 1 apresenta a curva de carga de uma semana considerando dados brasileiros. Estes dados são provenientes do agrupamento das regiões do Brasil, ou seja, são referentes ao Sistema Interligado Nacional (SIN). É possível observar padrões de carga semelhantes entre os dias da semana, entretanto de segunda-feira até sexta-feira a demanda de carga é maior do que nos finais de semana, o que ocorre devido a mudança na estrutura das atividades interpessoais praticadas nestes dias.




Figura 1: Perfil de carga de 24 a 30 de junho de 2019.

Fonte: Criação própria com base nos dados do Operador Nacional do Sistema Elétrico (ONS, 2021).

A Figura 2, a seguir, exibe a curva de carga de um único dia. Nota-se a diminuição gradativa da demanda de carga no período noturno, causada pela redução das atividades humanas, e seu aumento significativo com o passar do dia, influenciado pela ampliação das dinâmicas sociais.




Figura 2: Perfil de carga do dia 1 de julho de 2019.

Fonte: Criação própria com base nos dados do Operador Nacional do Sistema Elétrico (ONS, 2021).

Regiões distintas demonstram padrões climáticos desiguais, dessa forma a localização geográfica em que as medições foram realizadas também é um fator que interfere no perfil da curva de carga. Segundo a Empresa de Pesquisa Energética (EPE, 2020b), variações bruscas de temperatura estão diretamente relacionadas ao montante de energia requerido e no molde da curva de carga horária. Sendo assim, no transcorrer dos anos, é possível observar padrões que se repetem de acordo com as estações do ano (como é possível perceber na Figura 3). De acordo com Raza e Khosravi (2015), a demanda de carga no verão pode alcançar quase o dobro da demanda observada no inverno.




Figura 3: Perfil de carga de três anos (2018 a 2020) – Dados brasileiros.

Fonte: Criação própria com base nos dados do Operador Nacional do Sistema Elétrico (ONS, 2021).

No decorrer de um ano, observam-se comportamentos distintos de carga, como consequência principalmente das variações climáticas e dos diversos ciclos de atividades dos setores produtivos, propiciando o atingimento de patamares cerca de 15% acima ou abaixo da energia média anual requerida do Sistema Interligado Nacional. Quando são analisados intervalos diários, há ainda mais variabilidade, e atingem-se, por vezes, amplitudes de 50 a 150% da energia média diária. Dependendo das particularidades de cada classe de consumo e de sua dinâmica de evolução, associadas a questões como jornada de trabalho, iluminação natural, hábitos de uso de equipamentos, entre outros, a necessidade de consumo acaba por variar no decorrer do dia (EPE, 2020b).

Uma investigação feita por Pérez *et al.* (2015), para o mercado de eletricidade colombiano, mostrou que os mercados regulamentados e não regulamentados desfrutam de curvas de carga diferentes. Além disso, é enfatizado que todos os setores econômicos apresentam uma curva de carga plana, exceto, é claro, aqueles cujas atividades estão diretamente relacionadas a uma programação horária, como, por exemplo, agricultura, pecuária e comércio. Dessa forma, vale ressaltar que para o cenário brasileiro as curvas de carga também podem ser estudadas de acordo com o tipo de consumidor e a finalidade da utilização da energia elétrica. Conforme a Resolução ANEEL nº 800 de 19/12/2017 (ANEEL, 2017), estes consumidores podem ser definidos como:

- **Residencial:** englobam as unidades consumidoras com fim residencial;
- **Industrial:** abrangem as unidades consumidoras em que são desenvolvidas atividades industriais, incluindo o transporte de insumos;
- **Comércio, serviços e outras atividades:** contam com as unidades consumidoras que desenvolvem funções de prestação de serviços;
- **Rural:** enquadram-se as unidades localizadas em área rural, onde são desempenhados afazeres de caráter rural;
- **Poder público:** compreendem as unidades que independentemente das atividades que desenvolvem são regidas por um consumidor referido como pessoa jurídica de direito público;
- **Iluminação pública:** englobam de forma exclusiva as unidades designadas para a prestação de serviços públicos destinados a iluminação pública;
- **Serviço público:** enquadram-se as unidades que fornecem equipamentos e materiais vitais à operação de serviços públicos;
- **Consumo próprio:** abrangem as unidades consumidoras pertencentes as próprias distribuidoras.

Balasubramanian e Balachandra (2021), declaram que para qualquer entidade (ou concessionária) gerenciar o sistema elétrico, considerando as mudanças que estão ocorrendo rapidamente dentro deste, é uma tarefa altamente desafiadora, pois exige que ações sejam tomadas no lado da oferta, da demanda, ou ambos. Levando em conta estes aspectos, a gestão dos sistemas elétricos em transição necessita de atenção, para que decisões mais assertivas e intervenções mais adequadas possam ser implementadas. Diante deste fato, fica explícito a necessidade da análise das curvas de carga horária para o setor elétrico brasileiro, tendo em vista o impacto que tem a crescente inserção da micro e minigeração distribuída no país.

3.2 Micro e Minigeração Distribuída

Nos últimos anos, a adesão da geração distribuída (GD) no Brasil tem se mostrado um investimento promissor. De acordo com a Agência Nacional de Energia Elétrica (ANEEL, 2016), é possível caracterizar a geração distribuída como sendo a instalação de geradores de pequeno porte, usualmente abastecidos a partir de fontes renováveis, localizados perto dos estabelecimentos de consumo de energia elétrica. Dessa forma, a GD promove incentivos significativos para o consumidor, como, por exemplo, a redução nos custos referentes a eletricidade.

De forma geral, a presença de pequenos geradores próximos às cargas também pode proporcionar diversos benefícios para o sistema elétrico, dentre os quais se destacam a postergação de investimentos em expansão nos sistemas de distribuição e transmissão; o baixo impacto ambiental; a melhoria do nível de tensão da rede no período de carga pesada e a diversificação da matriz energética (ANEEL, 2016).

O potencial de crescimento da geração distribuída no Brasil é muito expressivo, o que enseja o surgimento de oportunidades de geração de emprego e renda em toda a cadeia produtiva. Trata-se de um excelente nicho de negócios que anda na contramão da crise econômica que o país vivencia (Bezerra, 2021).

Ainda segundo Bezerra (2021), até o dia 16 de dezembro de 2020, a capacidade instalada de geração distribuída no Brasil era de 4,4 GW, destacando-se nesta modalidade a energia solar, representando 97% do total de energia gerada. Com o avanço da tecnologia e a maior inserção das fontes renováveis no mercado brasileiro e mundial, a micro e minigeração distribuída (MMGD) tornou-se um investimento atrativo para a população.

Dentre os diferentes RED¹, a micro e minigeração distribuída (MMGD) têm um papel de destaque, sendo uma modalidade de geração que cresce exponencialmente no país. A MMGD foi regulamentada no Brasil em 2012 pela Agência Nacional de Energia Elétrica (ANEEL) através da Resolução Normativa (REN) número 482, que instituiu o modelo de *net-metering*² no país. Em 2015, o

¹ A sigla RED corresponde à Recursos Energéticos Distribuídos.

² Refere-se ao sistema de compensação de energia elétrica.

regulamento foi aprimorado, de modo a tornar o processo de conexão mais célere e ampliar o acesso à geração distribuída para um número maior de unidades consumidoras (EPE e MME, 2021).

A Resolução Normativa número 687 de 2015 estabeleceu modificações na resolução inicial publicada no ano de 2012, a microgeração distribuída e a minigeração distribuída podem ser definidas da seguinte forma:

- **Microgeração distribuída:** central geradora de energia elétrica, com potência instalada menor ou igual a 75 kW e que utilize cogeração qualificada, conforme regulamentação da ANEEL, ou fontes renováveis de energia elétrica, conectada na rede de distribuição por meio de instalações de unidades consumidoras (ANEEL, 2015);
- **Minigeração distribuída:** central geradora de energia elétrica, com potência instalada superior a 75 kW e menor ou igual a 3 MW para fontes hídricas ou menor ou igual a 5 MW para cogeração qualificada, conforme regulamentação da ANEEL, ou para as demais fontes renováveis de energia elétrica, conectada na rede de distribuição por meio de instalações de unidades consumidoras (ANEEL, 2015).

Os dados de carga horária disponibilizados pelo Operador Nacional do Sistema Elétrico (ONS) não contabilizam o montante de energia gerada por sistemas de micro e minigeração distribuída. Essa problemática deve ser estudada, dado que as leis vigentes estão favorecendo a aceitação da modalidade no país, acarretando em um crescimento da capacidade instalada referente a MMGD. Na Figura 4, a seguir, é possível observar o histórico da capacidade instalada de micro e minigeração distribuída no Brasil.




Figura 4: Histórico da capacidade instalada de MMGD no Brasil.

Fonte: Criação própria com base nos dados da Empresa de Pesquisa Energética (EPE, 2022).

O PDE 2029 (Plano Decenal de Expansão de Energia) (EPE e MME, 2020) destacou o aumento dos empreendimentos de micro e minigeração distribuída, resultando em aproximadamente 1,3 milhão de instalações e totalizando 11,4 GW de capacidade instalada. No entanto, devido principalmente as alterações previstas nas cotas tarifárias para unidades que possuem MMGD, o PDE 2030 (EPE e MME, 2021) trabalhou sobre duas vertentes, considerando diferentes cenários regulatórios. Em suma, o cenário verão visa representar a situação onde não ocorre mudanças significativas na regulamentação, mantendo uma política de incentivo para os investimentos nessa área. Porém, no cenário primavera, os incentivos em relação as tarifas cobradas para sistemas de MMGD seriam retirados, provocando um crescimento mais lento no número de novos empreendimentos. A Tabela 1 apresenta os principais resultados obtidos em ambos os Planos Decenais de Expansão de Energia (PDE 2029 e PDE 2030).

Tabela 1: Projeção para a MMGD (PDE 2029 e PDE 2030).

PDE 2029		
Cenário Único		
Potência em 2029	11,4 GW	
Energia em 2029	2.300 MWméd	
Investimentos	R\$ 50 bi	
% da Carga Total	2,3%	
PDE 2030		
	Cenário Verão	Cenário Primavera
Potência em 2030	24,5 GW	16,8 GW
Energia em 2030	4,3 GWméd	2,9 GWméd
Investimentos	R\$ 70 bi	R\$ 50 bi
% da Carga Total	4,6%	3,2%

Fonte: Criação própria com base nos dados do PDE 2029 (EPE e MME, 2020) e PDE 2030 (EPE e MME, 2021).

3.2.1 Geração Fotovoltaica

Sabe-se que a energia solar fotovoltaica é a energia elétrica proveniente do calor e da luz do sol. Dessa forma, a radiação solar desempenha um papel fundamental neste tipo de geração, pois impacta diretamente na quantidade de energia produzida. Com a maior inserção de fontes renováveis na matriz elétrica brasileira e diante dos incentivos regulatórios propostos para a adesão de sistemas de geração distribuída, a energia solar fotovoltaica se destacou, apresentando um crescimento substancial no país. Segundo Trindade (2020), a maioria dos projetos que abordam a energia solar e demonstram potencial comercial, fazem uso da tecnologia fotovoltaica.

De fato, observa-se um crescimento exponencial no número de instalações de GD no Brasil, que totalizaram até o fim de 2020 mais de 370 mil sistemas, somando uma capacidade instalada superior a 4,6 GW. Desses sistemas, 99,9% são fotovoltaicos, que representam 97% da potência total (EPE, 2021b).

No gráfico a seguir é possível observar o quanto a participação da energia fotovoltaica foi significativa, no âmbito da MMGD, para a geração de eletricidade no país.




Figura 5: Participação na geração de energia.

Fonte: Criação própria com base nos dados da Empresa de Pesquisa Energética (EPE, 2022).

De acordo com Trindade (2020), a unidade de medida que define o fluxo energético da radiação solar é chamada irradiância solar e supõe-se que apenas 54% desta encaminhe-se de maneira efetiva para a superfície terrestre. De fato, a porcentagem de irradiância que realmente alcança a superfície da terra é chamada irradiância global. Dessa maneira, pode-se caracterizar o efeito fotovoltaico como a conversão desta energia integrada na radiação em energia elétrica.

No efeito fotovoltaico é utilizado um material semicondutor adaptado para liberar elétrons - partículas que são carregadas negativamente e representam o pilar da eletricidade. As células fotovoltaicas possuem, no mínimo, duas camadas de silício (semicondutor mais comum) carregadas positivamente ou negativamente. Após o semicondutor ser atingido pela luz solar, por meio do campo elétrico entre a junção das duas camadas, inicia-se um fluxo de energia e, assim, gera-se a corrente contínua. O fluxo de eletricidade aumenta quando há maior incidência de luz e depende da densidade das nuvens para gerar energia. Assim, os sistemas

fotovoltaicos podem produzir mais energia em dias com menos nuvens, se comparados com dias totalmente claros, isso se dá por meio da reflexão da luz do sol (Alves, 2019).

As instalações que são constituídas por sistemas fotovoltaicos autônomos, não podem ser classificadas como instalações de MMGD, uma vez que não precisam estar ligadas na rede. Marques *et al.* (2009) afirmam que estes sistemas necessitam de um processo que englobe o armazenamento de energia (proveniente dos painéis solares), para, futuramente, distribuí-la aos locais de consumo.

Os sistemas fotovoltaicos autônomos são compostos pelos seguintes equipamentos (Marques *et al.*, 2009):

- **Painel fotovoltaico:** composto por módulos fotovoltaicos que são responsáveis por gerar energia;
- **Banco de baterias:** composto por baterias, geralmente de chumbo-ácido, é o armazenador de energia elétrica para noites e períodos nublados;
- **Controlador de cargas:** protege a bateria contra sobrecarga e descarga excessiva;
- **Inversor:** converte energia elétrica de corrente contínua (CC) para corrente alternada (CA), de forma a permitir a utilização de eletrodomésticos convencionais.

A Resolução Normativa nº 482/2012 concedeu o chamado Sistema de Compensação de Energia Elétrica. Esse sistema permite que a energia excedente gerada pela unidade consumidora com micro ou minigeração seja injetada na rede da distribuidora, a qual funcionará como uma bateria, armazenando esse excedente. (ANEEL, 2016). Assim sendo, a energia gerada e não consumida pode ser transformada em créditos que futuramente são empregados no abatimento do consumo de energia elétrica da unidade.

Como nem toda energia gerada é direcionada para o autoconsumo e autoconsumo remoto³, ocorre o processo de incorporação da energia remanescente na rede elétrica, o que eventualmente implica na mudança dos padrões observados

³ O consumidor que gera sua própria energia pode optar por utilizar esta energia em outras unidades cadastradas.

nas curvas de carga. O gráfico abaixo representa a quantidade de energia gerada através de sistemas de MMGD, onde destaca-se a parte que é consumida pela instituição produtora e a parcela que é direcionada para a rede.




Figura 6: Estimativa da geração proveniente de sistemas de MMGD no ano.

Fonte: Criação própria com base nos dados da Empresa de Pesquisa Energética (EPE, 2022).

Devido as transformações ocorridas no setor elétrico, causadas principalmente pela inserção da energia resultante dos sistemas de MMGD (MME e EPE, 2021), torna-se imprescindível uma previsão mais acurada para as séries de geração fotovoltaica. Diferentes regiões do Brasil podem apresentar variáveis que influenciam a radiação solar (por exemplo, temperatura) e, como consequência, causam impacto na geração fotovoltaica. Da Silva (2017) afirma que uma das particularidades que deve ser considerada e analisada no funcionamento de um sistema solar é sua intermitência, pois esta é um fator significativo que pode proporcionar custos consideráveis para o setor. Dessa maneira, o planejamento dos sistemas de energia e a estruturação de métodos capazes de reter o efeito da variação existente na geração fotovoltaica se mostram primordiais.

A utilização de curvas horárias de geração e carga tornam-se importantes, pois permite estabelecer uma melhor relação da real carga vista pelo sistema, a chamada carga líquida. A partir dela se pode estudar novos e mais adequados

patamares de carga para alimentar os modelos utilizados no planejamento, possibilitando a verificação de possíveis alterações na operação do SIN, bem como nos critérios de suprimento de energia e potência (EPE, 2021b). Dessa maneira, devido à falta da contabilização da geração fotovoltaica proveniente de sistemas de MMGD, a Empresa de Pesquisa Energética (EPE) desenvolveu sua própria metodologia para a elaboração de séries horárias de geração distribuída fotovoltaica.

A metodologia criada para geração das séries horárias fotovoltaicas corresponde a quatro ações a serem efetuadas. Segundo o Informe Técnico nº IT-EPE-DEA-SEE-001-2021, publicado em março de 2021, elas podem ser destacadas como (EPE, 2021b):

- 1) Escolher municípios representativos em termos de instalações de geração distribuída (GD) para cada subsistema;
- 2) Baixar dados meteorológicos horários para esses municípios;
- 3) Simular a operação de sistemas de GD com as bases meteorológicas;
- 4) Ponderar os resultados de acordo com o peso de cada município no subsistema.

Em resumo, para a primeira etapa da metodologia, foi elaborado um procedimento que buscou atender o maior número de municípios que apresentavam estabelecimentos com geração distribuída, neste caso, localidades que juntas retinham no mínimo 50% do número de instalações de GD, considerando cada subsistema separadamente. Em sequência, levando em conta as localizações geográficas, latitude e longitude, foram adquiridas as séries horárias de irradiação solar e temperatura, contemplando os anos de 2000 até 2017, através da base de dados de reanálise MERRA-2 na *National Aeronautics and Space Administration* (NASA). No entanto, a metodologia proposta pela EPE difere substancialmente da metodologia desenvolvida neste trabalho, que será exposta com mais detalhes na Seção 4.1.

3.3 Bases de Dados de Reanálise

Tahir *et al.* (2020a) apontam que na privação de dados de medição de superfície é válido estimar o potencial de energia solar utilizando a radiação contida em conjuntos de reanálise. Dessa forma, como não há muita disponibilidade de medições locais de alta qualidade de radiação solar no Brasil, principalmente dados de longo prazo e para grandes regiões, é possível utilizar dados de reanálise, que podem ser definidos como séries de dados meteorológicos alcançadas através da combinação de técnicas de medição, observação, simulação e assimilação.

A reanálise é uma forma de produzir uma análise global dinamicamente consistente do estado da atmosfera durante um longo período de tempo. Trata-se de uma combinação de modelo e medição, onde aplica-se observações para restringir o modelo dinâmico e otimizar as propriedades de cobertura e precisão. A inserção de informações observacionais na integração do modelo chama-se assimilação de dados (Betts *et al.*, 2006).

Diversas organizações disponibilizam dados de reanálise que abrangem séries de radiação solar de longo prazo. Por este motivo, uma gama de estudos comparativos foi efetuada para testar a eficácia desses dados. Segundo Tahir *et al.* (2020b) a variável de interesse que representa a irradiância global possui nomes distintos dentro destas bases, no entanto, geralmente é conhecida por irradiância horizontal global (GHI) ou irradiância solar de superfície (SSI).

Estudos como o realizado por Zhang *et al.* (2016) avaliaram o potencial de seis bases de reanálise, mais especificamente, JRA-55 (*Japan Meteorological Agency - JMA*), ERA-Interim (*European Center for Medium-Range Weather Forecasts - ECMWF*), MERRA (*National Aeronautics and Space Administration - NASA*), NCEP-DOE, NCEP-NCAR e CFSR (*National Center for Environmental Prediction - NCEP*). Apesar dessas bases diferirem em vários aspectos, como, por exemplo, as parametrizações físicas presentes em seus modelos numéricos, a pesquisa comparou o incidente de radiação solar na superfície da Terra proveniente destas bases com as medições de superfície de diferentes redes de observação. Como resultado, embora a estimativa das bases de reanálise seja eficiente, o estudo revelou uma superestimação da radiação devido aos problemas relacionados a nuvens e aerossóis em seus modelos físicos.

Em novas gerações das bases de reanálise as correções que ponderam os efeitos advindos das nuvens e aerossóis já foram introduzidas, como é o caso da ERA-5 *land*, cuja resolução é menor que a ERA-5. Trabalhos mais recentes, como Tahir *et al.* (2020a) e Tahir *et al.* (2020b), analisaram a reanálise da radiação solar de superfície para regiões no Paquistão, considerando bases pertencentes a NCEP, ECMWF, NASA e JMA. Como resultado, a ERA-5 apresentou as melhores performances de erro para Quetta e Khuzdar (Tahir *et al.*, 2020a), superando a MERRA-2 e demonstrando alto potencial de predição. Além disso, os autores atentam para o fato que o ERA-5 deve ser priorizada devido sua maior resolução temporal e espacial. Logo, focando na obtenção de uma estimativa mais acurada para as séries de geração distribuída fotovoltaica e levando em consideração estudos comparativos e propriedades como resolução temporal e espacial, os dados de radiação solar da ERA-5 *land* foram escolhidos para compor a metodologia proposta nesta dissertação.

4 Metodologia

Neste capítulo, será apresentada a metodologia desenvolvida para o cálculo da estimativa da GD fotovoltaica e serão expostos conceitos teóricos referentes aos modelos de suavização exponencial, abordados na realização de previsões para as séries de carga e demanda horárias brasileiras.

4.1 Metodologia para o cálculo da estimativa da GD fotovoltaica

A metodologia proposta foi desenvolvida com o intuito de apresentar outra estratégia de estimação da GD devido à falta de dados públicos atualizados referentes as séries horárias de geração distribuída. Nesta seção será apresentada a aplicação de uma nova técnica para a criação de séries horárias de geração distribuída fotovoltaica para os quatro subsistemas que compõem o Sistema Interligado Nacional, ou seja, Norte (NO), Sul (S), Nordeste (NE) e Sudeste/Centro-Oeste (SE-CO). A metodologia desenvolvida envolveu três etapas e resultou na previsão da geração fotovoltaica para cada hora do dia, contemplando o ano de 2019 e a primeira semana de 2020, totalizando 8928 observações.

A primeira etapa desta metodologia consistiu na seleção das cidades que apresentavam a maior concentração de potência instalada (kW) de geração distribuída. O critério adotado abordou cada subsistema separadamente, para em seguida selecionar as localidades que juntas detinham pelo menos 50% da potência total instalada dentro daquele subsistema⁴. Ao todo, foram escolhidas 265 cidades, cujas informações, para o subsistema Norte, podem ser observadas na Tabela 2 (as demais informações encontram-se nas tabelas presentes no ANEXO A). Vale ressaltar que na época da coleta dos dados (agosto, setembro e outubro de 2021) considerou-se 2020 como ano base para a obtenção dos dados de potência, ou seja, os subsistemas NO, NE, S e SE-CO retinham, até 31 de dezembro de 2020, uma

⁴ O valor de 50% foi escolhido pois resulta em uma quantidade reduzida de cidades representativas e, conseqüentemente, em um volume menor de dados de potência instalada para serem obtidos.

potência total instalada de GD equivalente a 275.012,04 kW, 779.386,79 kW, 1.100.728,15 kW e 2.587.222,04 kW, respectivamente.

Tabela 2: Localidades selecionadas para o subsistema Norte.

Cidade	Estado	Potência Instalada (kW)	Potência Instalada (%)
Palmas	TO	23474,51	8,54
Manaus	AM	21176,47	7,70
Imperatriz	MA	16313,23	5,93
São Luís	MA	16230,3	5,90
Belém	PA	14992,97	5,45
Santarém	PA	9793,07	3,56
Araguaína	TO	9658,35	3,51
Marabá	PA	8685,93	3,16
Timon	MA	6816,34	2,48
Ananindeua	PA	5389,48	1,96
Parauapebas	PA	5341,24	1,94
Macapá	AP	5169,84	1,88
Total		143041,73	52,01

Fonte: Criação própria.

Após a seleção das cidades que iriam compor o portfólio representativo de cada subsistema, foi necessário construir uma base de dados que contivesse o histórico da potência instalada para estes pontos. Os dados foram obtidos diretamente do portal de Geração Distribuída disponibilizado pela Agência Nacional de Energia Elétrica (ANEEL, 2021) e refletem as informações que foram documentadas desde 2009, para a região Sudeste/Centro-Oeste, e 2012 para as demais regiões. Os locais escolhidos podem ser verificados geograficamente no mapa a seguir.

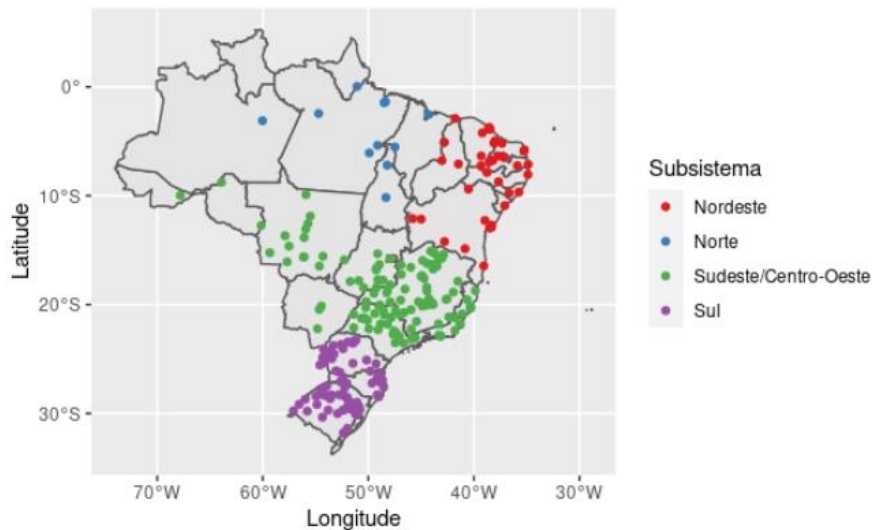


Figura 7: Localidades selecionadas para cada subsistema.

Fonte: Criação própria.

A segunda etapa deste método integrou a busca por dados referentes a radiação solar. Devido à escassez de dados nesta área, optou-se por utilizar uma base de reanálise. Levando em conta estudos comparativos e características como resolução temporal e espacial, a ERA-5 *land* (em base horária) foi escolhida para fazer parte desta metodologia. Dessa forma, as séries de radiação solar da base de reanálise ERA-5 *land* foram obtidas por meio da variável denominada “*surface solar radiation downwards*” cuja unidade de medida é em joules por metro quadrado (J/m^2), contudo, posteriormente, a variável foi transformada para kWh/m^2 . As especificações das duas bases, ERA-5 *land* e MERRA-2 (utilizada na metodologia proposta pela EPE), podem ser observadas na Tabela 3.

Tabela 3: Comparação das bases ERA-5 *land* (ECMWF) e MERRA-2 (NASA).

	ERA-5 <i>land</i>	MERRA-2
Projeção	Grade regular de latitude-longitude	Grade regular de latitude-longitude
Resolução horizontal	$0,1^\circ \times 0,1^\circ$	$0,5^\circ \times 0,625^\circ$
Cobertura temporal	1950 até o presente	1980 até o presente
Resolução temporária	1 hora	1 hora

Fonte: Criação própria.

Como a energia solar apresenta características intermitentes, desenvolver uma formulação matemática que produza estimativas mais precisas da geração distribuída fotovoltaica é uma tarefa que desafia diversos pesquisadores. Dessa forma, dando prosseguimento a metodologia aqui desenvolvida, o terceiro passo consistiu na utilização de parte do método de estimação abordado por Duarte (2021).

Segundo Duarte (2021), para estabelecer a energia auferida pelas placas solares, denominada de E_S e medida em kWh, é necessário estabelecer as seguintes variáveis:

- I_S : irradiação solar do ambiente (kWh/m^2);
- P_{FV} : equivalente a capacidade instalada das unidades fotovoltaicas, em kW, para cada ano disponível;
- I_P : referente a irradiação solar padrão empregada em testes que quantificam o nível de eficiência de painéis solares, fixada no valor de $1 kWh/m^2$;
- ε_{FV} : simboliza a eficiência dos painéis solares e é estipulada em 75%;
- T_C : correspondente a temperatura atual da célula ($^{\circ}C$);
- ρ : referente ao coeficiente de temperatura dos painéis, fixado previamente no valor de $-0,38\%/^{\circ}C$, para células criadas com silício policristalino.

Desse modo, Duarte (2021) define:

$$E_S = I_S \times \frac{P_{FV}}{I_P} \times \varepsilon_{FV} \times [1 + \rho(T_C - 25)] \quad (1)$$

No entanto, de acordo com o Informe Técnico produzido pela *SMA Solar Technology AG* (SMA, 2021), o fator que mede a qualidade de um sistema fotovoltaico, denominado de ε_{FV} , representa o vínculo entre as saídas de energia reais e as teóricas, evidenciando a proporção de energia que será exportada para a rede após a ponderação das perdas. Assim, destaca-se os principais fatores que influenciam nesta variável (SMA, 2021):

- Temperatura do módulo fotovoltaico;
- Dissipação da energia obtida pela irradiância solar;

- Tipo, localização e condições de limpeza na qual se apresenta o medidor;
- Posicionamento e sujeira do módulo fotovoltaico;
- Perdas por condução;
- Fator de eficiência do inversor, entre outros.

Em decorrência desses aspectos, a parcela que contabiliza a temperatura $(1 + \rho(T_C - 25))$ será retirada, dado que o fator ε_{PV} contempla as perdas decorrentes da temperatura das placas. Desse modo, a Equação (1) pode ser reescrita e é apresentada abaixo.

$$E_S = I_S \times \frac{P_{FV}}{I_P} \times \varepsilon_{FV} \quad (2)$$

Duarte (2021) aponta que a degradação (D) das placas solares é um fator decisivo na quantidade de energia produzida e, por este motivo, deve ser considerada. A degradação pode ser concebida como a degeneração gradual dos componentes presentes nos módulos fotovoltaicos que, eventualmente, afetam a capacidade de operação.

Com um período de garantia tão longo, as taxas de degradação dos painéis solares devem ser bem definidas e estar abaixo de 0,8% ao ano. A taxa de degradação de muitos módulos pode ultrapassar 0,7% ao ano, resultando em perdas para os fabricantes, uma vez que devem cumprir a garantia fornecendo um novo módulo. Dependendo do mecanismo envolvido, a degradação dos painéis solares no campo pode ser de longo ou curto prazo (Kim *et al.*, 2021).

Isto posto, para a estimação das séries de geração distribuída fotovoltaica é considerado um fator de degradação (D), equivalente a 0,5% ao ano, resultando na Equação (3). Destaca-se que n equivale ao número de anos de funcionamento das placas solares.

$$E_S = [P_{FV} \ P_{FV-1} \ \dots \ P_{FV-n}] \times \begin{bmatrix} (1-D)^0 \\ (1-D)^1 \\ \vdots \\ (1-D)^n \end{bmatrix} \times \varepsilon_{FV} \times \frac{I_S}{I_P} \quad (3)$$

4.2 Modelos de Suavização Exponencial

Os modelos de amortecimento exponencial fazem parte de uma classe de métodos de previsão que consideram que as observações passadas contêm informações valiosas sobre o comportamento da série temporal. Um diferencial destes métodos é que eles atribuem pesos variáveis que diminuem com a idade da observação. O método Holt-Winters padrão foi inicialmente exposto por Winters (1960) e é adequado para a modelagem de séries temporais que possuem características sazonais. Segundo Lawton (1998), no método de amortecimento exponencial de Holt-Winters são observados dois grupos: aditivo e multiplicativo. A diferença entre estes grupos é exposta por Taylor (2003):

“A versão multiplicativa é apropriada se a magnitude da variação sazonal aumenta com o crescimento do nível médio da série, enquanto a versão aditiva deve ser usada se o efeito sazonal não depender do nível médio.”

O modelo sazonal aditivo é usado quando a amplitude da variação sazonal permanece constante ao longo dos períodos de tempo. Os índices S_t , T_t e I_t são referentes ao nível, a tendência e a sazonalidade, nesta ordem. O modelo pode ser visto a seguir.

- **Nível:**

$$S_t = \alpha (X_t - I_{t-s}) + (1 - \alpha)(S_{t-1} + T_{t-1}) , \quad 0 \leq \alpha \leq 1 ; \quad (4)$$

- **Tendência:**

$$T_t = \gamma (S_t - S_{t-1}) + (1 - \gamma) T_{t-1} , \quad 0 \leq \gamma \leq 1 ; \quad (5)$$

- **Sazonalidade:**

$$I_t = \delta (X_t - S_t) + (1 - \delta) I_{t-s} , \quad 0 \leq \delta \leq 1 ; \quad (6)$$

A previsão k passos à frente para o modelo Holt-Winters aditivo é calculada da seguinte forma:

$$\hat{X}_t(k) = S_t + k T_t + I_{t-s+k} \quad (7)$$

sendo α , γ e δ as constantes de amortização, X_t o valor real observado no período de tempo t e s o comprimento do ciclo sazonal.

O modelo sazonal multiplicativo apresenta uma variação na amplitude do ciclo sazonal que é proporcional ao nível da série ao longo do período de tempo. Este método engloba uma tendência de origem aditiva e estima a inclinação, T_t , amortecendo as diferenças sucessivas, $(S_t - S_{t-1})$, provenientes do nível S_t . O índice sazonal I_t é atribuído para o período s e é estimado pelo amortecimento da razão do valor observado pelo nível. Pode-se expressar o modelo Holt-Winters multiplicativo através das seguintes equações:

- **Nível:**

$$S_t = \alpha \left(\frac{X_t}{I_{t-s}} \right) + (1 - \alpha)(S_{t-1} + T_{t-1}) , \quad 0 \leq \alpha \leq 1 ; \quad (8)$$

- **Tendência:**

$$T_t = \gamma (S_t - S_{t-1}) + (1 - \gamma) T_{t-1} , \quad 0 \leq \gamma \leq 1 ; \quad (9)$$

- **Sazonalidade:**

$$I_t = \delta \left(\frac{X_t}{S_t} \right) + (1 - \delta) I_{t-s} , \quad 0 \leq \delta \leq 1 ; \quad (10)$$

onde α , γ e δ são as constantes de suavização. A equação de previsão pode ser encontrada a seguir,

$$\hat{X}_t(k) = (S_t + k T_t) I_{t-s+k} \quad (11)$$

na qual k indica a quantidade de períodos futuros a serem previstos.

4.2.1 Modelo Holt-Winters Sazonal Duplo

Pode-se afirmar que várias séries temporais são caracterizadas por apresentarem mais de um padrão sazonal. Taylor (2003) analisou uma série de demanda de eletricidade cujas observações foram coletadas a cada 30 minutos. Nesta série constatou-se dois padrões distintos de sazonalidade, mais especificamente, um ciclo sazonal dentro do dia formado por 48 períodos e um ciclo sazonal dentro da semana constituído por 336 períodos. Em termos gerais, notou-se que o perfil da demanda de um dia tinha o comportamento semelhante com o perfil da demanda do próximo dia e o mesmo fenômeno ocorria ao se observar as semanas, pois estas também exibiam perfis similares entre si.

Atentando-se para o fato de que existe a necessidade de um método de previsão que seja capaz de capturar dois ciclos sazonais (diário e semanal), Taylor (2003) desenvolveu a seguinte formulação para o Modelo Holt-Winters Sazonal Duplo:

- **Nível:**

$$S_t = \alpha \left[\frac{X_t}{(D_{t-s_1} W_{t-s_2})} \right] + (1 - \alpha)(S_{t-1} + T_{t-1}), \quad 0 \leq \alpha \leq 1; \quad (12)$$

- **Tendência:**

$$T_t = \gamma (S_t - S_{t-1}) + (1 - \gamma) T_{t-1}, \quad 0 \leq \gamma \leq 1; \quad (13)$$

- **Primeira Sazonalidade:**

$$D_t = \delta \left[\frac{X_t}{(S_t W_{t-s_2})} \right] + (1 - \delta) D_{t-s_1}, \quad 0 \leq \delta \leq 1; \quad (14)$$

- **Segunda Sazonalidade:**

$$W_t = \omega \left[\frac{X_t}{(S_t D_{t-s_1})} \right] + (1 - \omega) W_{t-s_2}, \quad 0 \leq \omega \leq 1; \quad (15)$$

A equação de previsão é dada por:

$$\hat{X}_t(k) = (S_t + k T_t) D_{t-s_1+k} W_{t-s_2+k} \quad (16)$$

onde α , γ , δ e ω são as constantes de amortização, s_1 é designado para representar o comprimento do primeiro ciclo sazonal e s_2 equivale ao comprimento do segundo ciclo sazonal.

Vale enfatizar que a formulação do modelo de Holt-Winters para dois padrões de sazonalidade, vistas nas equações de (12) a (15), pode ser ampliada para sustentar três ou mais ciclos sazonais. Para adicionar o ciclo anual, por exemplo, essa modificação é efetuada introduzindo um índice sazonal extra e uma equação de suavização para a sazonalidade adicional.

5 Resultados

Neste capítulo, são expostas as análises descritivas efetuadas nas séries horárias de geração distribuída fotovoltaica, assim como são apresentados os resultados obtidos nas previsões de carga e demanda realizadas com a aplicação do modelo proposto (Holt-Winters Sazonal Duplo).

5.1 Dados

Os dados referentes a curva de carga horária em MWh (megawatt-hora) são originários da base de dados técnica do Operador Nacional do Sistema Elétrico (ONS, 2021). Nestes dados não está incluso o montante de energia gerada através de sistemas fotovoltaicos de geração distribuída, devido a este motivo e a falta de dados que contabilizem a geração proveniente de sistemas de MMGD, foi necessário elaborar estimativas para as séries horárias de GD fotovoltaica. Os dados primários para a criação destas séries, mais especificamente, a potência instalada em kW (kilowatts) por ano, foram conseguidos pelo portal de Geração Distribuída oferecido pela Agência Nacional de Energia Elétrica (ANEEL, 2021). Ambas as séries de dados, em intervalos horários, abrangeram o período de 1 de janeiro de 2019 a 7 de janeiro de 2020, totalizando 8928 observações, para cada subsistema e para o SIN. Vale destacar, que os dados de 2019 foram utilizados como base histórica para a realização das previsões (efetuadas para a primeira semana de 2020) pois em fevereiro de 2020 ocorreu um aumento significativo das incertezas devido a pandemia de COVID-19.

Para a modelagem dos dados o *software* R (R Core Team, 2021) e seu editor R-Studio (RStudio Team, 2021) foram usados, em específico, os seguintes pacotes: *readxl* (Wickham e Bryan, 2019) (para leitura dos dados), *forecast* (Hyndman *et al.*, 2021) (para a implementação do modelo proposto e cálculo das métricas de

avaliação), *ggplot2* (Wickham, 2016) (para criação dos gráficos) e *lubridate* (Grolemund e Wickham, 2011) (para auxiliar na manipulação de datas).

5.2 Características das Séries de Geração Fotovoltaica

As séries estimadas de geração distribuída fotovoltaica possuem características distintas. A Tabela 4 apresenta as principais medidas descritivas observadas na análise inicial destas séries. Percebe-se que o subsistema Sudeste/Centro-Oeste exibe o maior valor dentre os máximos observados nos subsistemas, indicando uma geração solar mais ampla nesta região.

Tabela 4: Estatísticas descritivas das séries de geração distribuída fotovoltaica (MWh).

	Mínimo	Mediana	Média	Máximo
SIN	0	20,39	232,97	1571,23
Norte	0	0,7062	9,9048	63,7569
Nordeste	0	3,188	36,943	246,710
Sudeste/Centro-Oeste	0	9,181	120,179	785,465
Sul	0	3,781	65,941	547,262

Fonte: Criação própria.

A Figura 8 representa a distribuição dos dados de geração por hora, levando em conta o período de 01/01/2019 a 31/12/2019, são considerados os quatro subsistemas e o seu agrupamento, ou seja, o Sistema Interligado Nacional (SIN). Nota-se que o subsistema Norte demonstra uma maior variabilidade, que pode ser explicada pela geração estar concentrada em apenas 12 municípios. A região Sul expõe menor variabilidade, no entanto é possível verificar a presença de *outliers* em todas as horas do dia que contemplam a geração solar, mais especificamente, no intervalo de 6 da manhã as 8 da noite. Os gráficos dos subsistemas Sudeste/Centro-Oeste (Figura 8 (c)) e Nordeste (Figura 8 (b)) são similares, contudo, a região Sudeste/Centro-Oeste apresenta maior dispersão das instalações de GD.

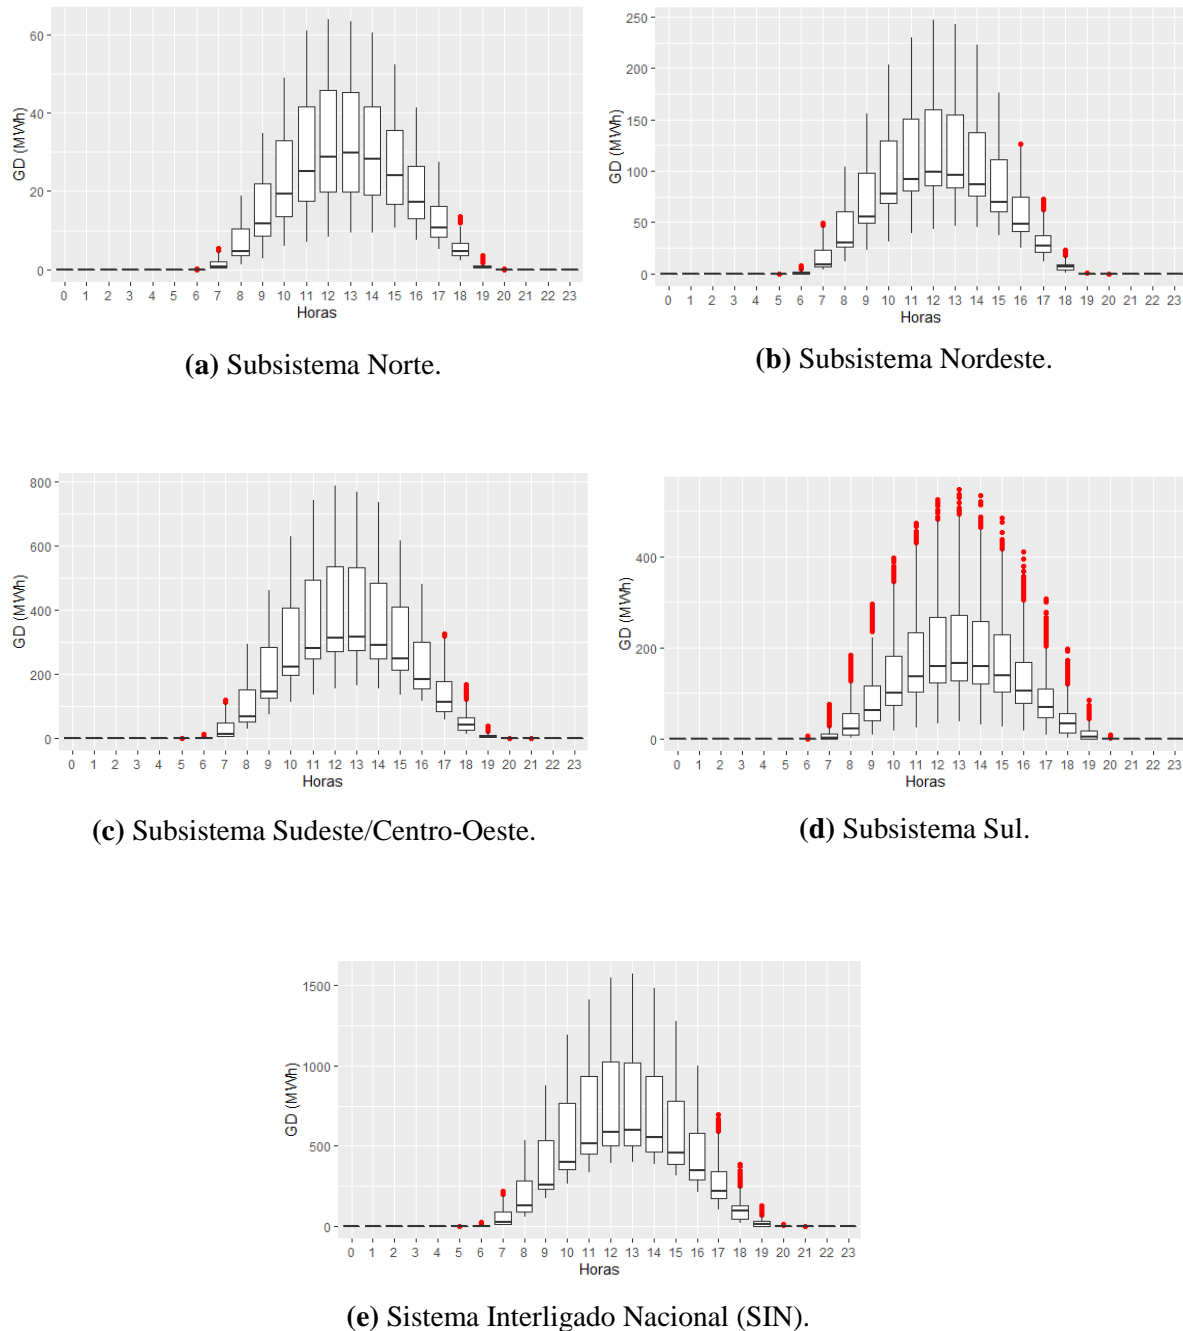




Figura 8: Boxplots das séries de geração distribuída fotovoltaica considerando as horas do dia.

Fonte: Criação própria.


A Figura 9 representa a distribuição dos dados de geração em relação aos meses do ano de 2019. É possível observar, para todas as regiões, o aumento na variação dos dados para os meses finais do ano. Verifica-se também, que apenas o subsistema Sul dispõe da presença de valores atípicos em seus dados mensais.




(a) Subsistema Norte.




(b) Subsistema Nordeste.



(c) Subsistema Sudeste/Centro-Oeste.




(d) Subsistema Sul.




(e) Sistema Interligado Nacional (SIN).

Figura 9: Boxplots das series de geração distribuída fotovoltaica considerando os meses do ano.**Fonte:** Criação própria.

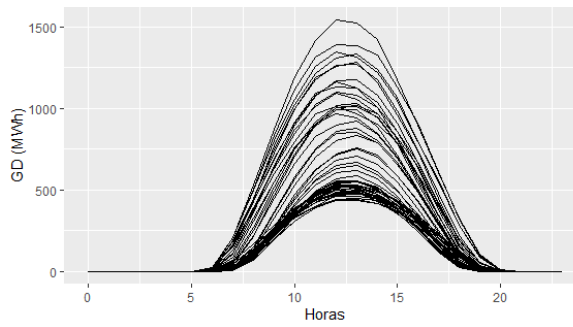
Como uma forma de estudar o comportamento das curvas de geração distribuída fotovoltaica diárias, a Figura 10, a seguir, expõe as curvas típicas observadas para os dias da semana considerando o agrupamento dos subsistemas. É possível constatar uma alternância na altura das curvas, causada, em especial, pela variação no nível de radiação solar.




(a) Segunda-feira.




(b) Terça-feira.



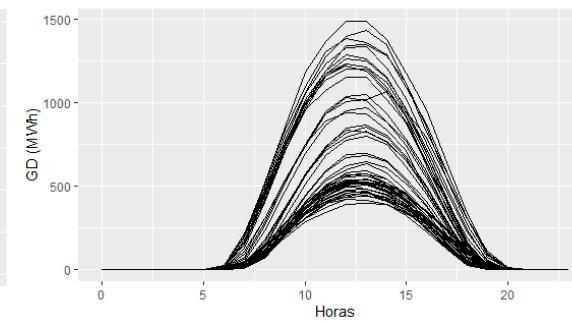
(c) Quarta-feira.




(d) Quinta-feira.



(e) Sexta-feira.



(f) Sábado.



(g) Domingo.

Figura 10: Curvas típicas de geração distribuída fotovoltaica por dia da semana para o SIN.

Fonte: Criação própria.

5.3 Resultado das previsões

Para analisar a qualidade da metodologia proposta por este trabalho foram realizadas previsões de carga e demanda, tendo como base o modelo Holt-Winters Sazonal Duplo, onde considerou-se o horizonte de tempo de 24 horas à frente, abordando, separadamente, os dias compreendidos na primeira semana do ano de 2020. Para a previsão da demanda (dados de carga somados aos dados de geração distribuída fotovoltaica) foi destacado o período entre 6 horas e 20 horas como o momento de maior inserção de GD na rede. A performance do modelo proposto foi avaliada levando-se em consideração a métrica dos erros referentes ao dia inteiro de previsão (24 horas). As métricas utilizadas podem ser vistas a seguir:

- **Erro médio absoluto percentual (MAPE):**

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{X_t - \hat{X}_t}{X_t} \right| \times 100 \quad (17)$$

- **Erro médio simétrico absoluto percentual (SMAPE):**

$$SMAPE = \frac{1}{n} \sum_{t=1}^n \frac{2 |X_t - \hat{X}_t|}{X_t + \hat{X}_t} \times 100 \quad (18)$$

- **Raiz quadrada do erro quadrático médio (RMSE):**

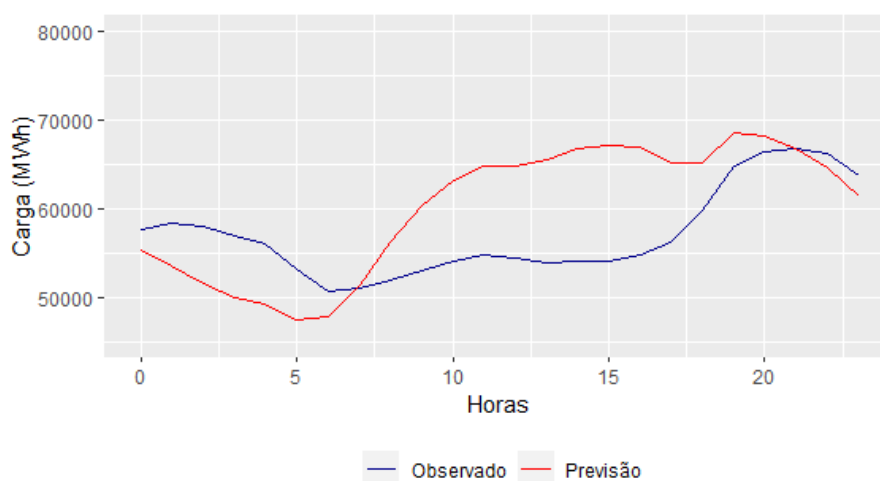
$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (X_t - \hat{X}_t)^2} \quad (19)$$

sendo X_t o valor da série temporal no período t , \hat{X}_t o valor ajustado da série para o período t e n o total de observações.


5.3.1 Sistema Interligado Nacional (SIN)

As previsões de carga e demanda foram realizadas para o Sistema Interligado Nacional (SIN) começando no dia 01/01/2020, uma quarta-feira considerada feriado nacional. A série de demanda horária foi construída somando-se a estimativa da geração distribuída fotovoltaica aos dados de carga horária. A previsão 24 horas à frente da demanda foi estabelecida levando em conta os valores previstos da carga para os intervalos de tempo compreendidos entre 0h-5h e 21h-23h, e considerando os próprios valores previstos da demanda, para 15 passos à frente, a partir das 6 horas.

Na Figura 11(b) pode-se perceber que há um distanciamento mais significativo das curvas se comparado com a Figura 11(a), onde a linha vermelha representa a curva de valores previstos e a azul exibe os valores observados. O aumento do erro de previsão para este dia é explicado pelo fato de não ter sido realizado nenhum tratamento específico para dias atípicos, neste caso, feriado nacional. Segundo Ebrahimi e Moshari (2013), a previsão de carga de curto prazo para feriados apresenta um nível maior de incerteza, dado que estes dias exibem um perfil de carga anômalo e os dados de dias semelhantes a eles podem ser considerados limitados.



(a) Previsão da curva de carga horária para o dia 01/01/2020.

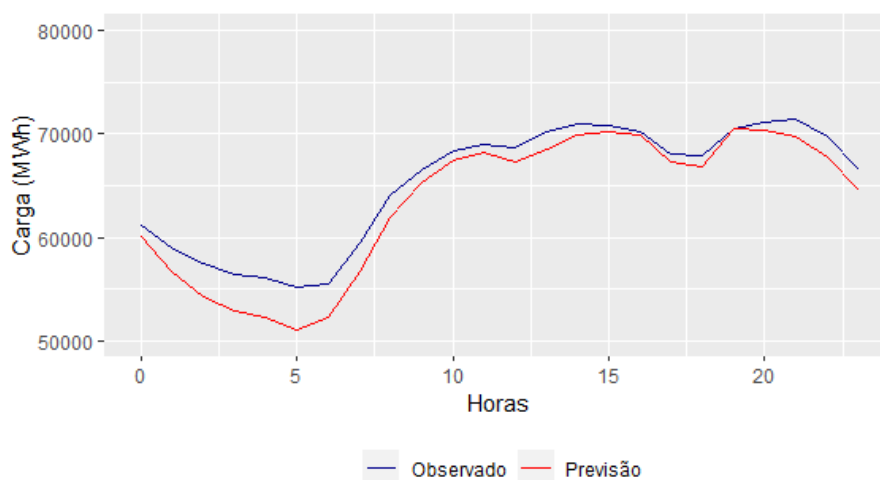


(b) Previsão da demanda horária para o dia 01/01/2020.


Figura 11: Previsões para o dia 01/01/2020 – SIN.

Fonte: Criação própria.

Para o dia seguinte ao feriado, ou seja, dia 02/01/2020, observou-se uma melhora significativa na previsão. Nota-se que a curva de carga real e as previsões estão bem próximas, como mostra a Figura 12(a), indicando um desempenho superior se comparado aos valores obtidos para o dia anterior. Para a demanda, Figura 12(b), é possível observar uma sobrestimação das previsões no intervalo de maior geração de energia solar fotovoltaica (6 horas até 20 horas).



(a) Previsão da curva de carga horária para o dia 02/01/2020.




(b) Previsão da curva de demanda horária para o dia 02/01/2020.


Figura 12: Previsões para o dia 02/01/2020 – SIN.

Fonte: Criação própria.

Para o dia 03/01/2020, sexta-feira e dia útil, os valores previstos para ambos os casos, carga e demanda horária, foram muito próximos aos valores reais, como pode ser observado na Figura 13. Constata-se que o erro de previsão foi minimizado durante o período entre 11 horas e 15 horas.



(a) Previsão da curva de carga horária para o dia 03/01/2020.




(b) Previsão da curva de demanda horária para o dia 03/01/2020.

Figura 13: Previsões para o dia 03/01/2020 – SIN.


Fonte: Criação própria.

As previsões para os dias 04/01/2020 e 05/01/2020, dias de final de semana, mostram que o comportamento da curva de previsão foi muito similar a curva real, como pode-se observar nas Figuras 14(a)(b) e 14(c)(d). No entanto, comparando-se ambas as previsões, repara-se que a previsão da carga foi subestimada nos horários contemplados pela geração solar, resultando em erros mais expressivos. Neste caso, é possível supor que os erros na previsão da demanda foram diminuídos justamente por se considerar a estimativa de geração distribuída fotovoltaica.


As Figuras 14(e)(f) e 14(g)(h) apresentam as previsões para os dias 06/01/2020 e 07/01/2020. Os resultados alcançados para estes dias foram satisfatórios, expondo uma melhora considerável nos valores previstos da demanda para o intervalo de tempo contido entre 6 horas e 17 horas, ou seja, na maior parte do período em que foi considerada a inserção de GD na rede elétrica.




(a) Previsão de carga para o dia
04/01/2020.




(b) Previsão de demanda para o dia
04/01/2020.




(c) Previsão de carga para o dia
05/01/2020.




(d) Previsão de demanda para o dia
05/01/2020.




(e) Previsão de carga para o dia
06/01/2020.



(f) Previsão de demanda para o dia
06/01/2020.



(g) Previsão de carga para o dia
07/01/2020.



(h) Previsão de demanda para o dia
07/01/2020.

Figura 14: Previsões de carga e demanda para o Sistema Interligado Nacional (SIN).

Fonte: Criação própria.

A Tabela 5, a seguir, expõe as métricas de avaliação utilizadas para analisar a qualidade dos modelos de previsão de carga e demanda de curto prazo para o Sistema Interligado Nacional (SIN). As três métricas selecionadas, MAPE, SMAPE e RMSE, determinam o erro a partir da associação entre os valores previstos e os valores reais das séries temporais abordadas. As medidas de avaliação relacionadas a série de demanda apresentaram uma redução nos erros de previsão para os dias 3, 4, 5, 6 e 7 de janeiro de 2020, validando a metodologia proposta neste trabalho. Pode-se concluir, em um primeiro momento, que este método é capaz de produzir previsões confiáveis para o atual cenário que abrange o crescimento substancial da micro e minigeração distribuída fotovoltaica no país.

Tabela 5: Resultado das métricas de avaliação para os modelos de previsão do SIN.

Data da previsão	Previsão da carga horária			Previsão da demanda horária		
	MAPE (%)	SMAPE (%)	RMSE (MWh)	MAPE (%)	SMAPE (%)	RMSE (MWh)
01/01/2020	11,28	10,72	7391,31	17,57	15,94	11635,18
02/01/2020	2,87	2,94	2096,28	4,81	4,77	3398,8
03/01/2020	2,96	3,02	2322,83	2,92	2,95	2286,82
04/01/2020	6,99	7,34	4951,67	3,42	3,5	2529,56
05/01/2020	5,61	5,9	4054,04	3,69	3,81	2652,47
06/01/2020	4,02	4,15	3764,76	2,06	2,05	1809,23
07/01/2020	5,12	5,35	5128,07	3,12	3,15	2835,98

Fonte: Criação própria.


5.3.2 Subsistema Norte (NO)

Analisando as previsões obtidas para o subsistema Norte (NO), com base na mesma metodologia adotada para o SIN, observa-se por meio da Tabela 6 e da Figura 15, que, no geral, as curvas previstas apresentam comportamentos semelhantes as curvas observadas, demonstrando uma eficácia do método proposto para este novo conjunto de dados. Comparando as métricas de avaliação associadas as previsões, pode-se constatar que os modelos que contemplam a geração distribuída fotovoltaica, ou seja, que consideram a demanda, apresentaram uma diminuição nos erros de previsão, tal fato pode ser observado em quatro dos sete dias analisados. É válido dizer que a região Norte retratou o segundo melhor desempenho dentre os subsistemas, exibindo erros inferiores a 7,61% (MAPE). Novamente, para o primeiro dia do ano, os resultados obtidos não foram tão eficientes, manifestando a necessidade da aplicação de metodologias que abordem o tratamento de dias atípicos, neste caso, feriado nacional.


Tabela 6: Resultado das métricas de avaliação para os modelos de previsão do subsistema Norte.

Data da previsão	Previsão da carga horária			Previsão da demanda horária		
	MAPE (%)	SMAPE (%)	RMSE (MWh)	MAPE (%)	SMAPE (%)	RMSE (MWh)
01/01/2020	4,65	4,57	263,89	7,61	7,2	455,34
02/01/2020	1,82	1,81	120,21	3,31	3,35	179,58
03/01/2020	5,37	5,56	327,29	3,2	3,26	191,07
04/01/2020	1,60	1,58	105,86	1,9	1,91	121,85
05/01/2020	5,18	5,39	311,25	4,23	4,38	264,03
06/01/2020	2,65	2,59	182,42	1,28	1,27	98,14
07/01/2020	2,99	3,06	202,16	2,5	2,55	173,86


Fonte: Criação própria.




(a) Previsão de carga para o dia
01/01/2020.




(b) Previsão de demanda para o dia
01/01/2020.




(c) Previsão de carga para o dia
02/01/2020.




(d) Previsão de demanda para o dia
02/01/2020.




(e) Previsão de carga para o dia
03/01/2020.




(f) Previsão de demanda para o dia
03/01/2020.




(g) Previsão de carga para o dia
04/01/2020.




(h) Previsão de demanda para o dia
04/01/2020.




(i) Previsão de carga para o dia
05/01/2020.




(j) Previsão de demanda para o dia
05/01/2020.




(k) Previsão de carga para o dia
06/01/2020.



(l) Previsão de demanda para o dia
06/01/2020.



(m) Previsão de carga para o dia
07/01/2020.



(n) Previsão de demanda para o dia
07/01/2020.

Figura 15: Previsões de carga e demanda para o subsistema Norte.

Fonte: Criação própria.


5.3.3 Subsistema Nordeste (NE)

Ao observar a Tabela 7 e a Figura 16, é possível afirmar que o bom desempenho do método proposto também foi observado no subsistema Nordeste. Nota-se, para o primeiro dia do ano e feriado nacional, que os valores de previsão foram superestimados no intervalo de tempo de 6 horas às 16 horas, no entanto, para este mesmo período, o modelo de demanda foi mais eficaz, produzindo uma diminuição nos erros de previsão. Nos dias subsequentes, ao longo de várias horas, os valores preditos foram subestimados, ficando abaixo dos observados. Novamente, foi constatado que quatro dos sete dias estudados apresentaram um decréscimo nas taxas de erro se comparados aos modelos de carga. Por fim, é razoável declarar que a performance dos modelos de demanda para a região Nordeste foram os mais eficientes, pois exibiram erros inferiores a 6,93% (MAPE).


Tabela 7: Resultado das métricas de avaliação para os modelos de previsão do subsistema Nordeste.

Data da previsão	Previsão da carga horária			Previsão da demanda horária		
	MAPE (%)	SMAPE (%)	RMSE (MWh)	MAPE (%)	SMAPE (%)	RMSE (MWh)
01/01/2020	8,67	8,12	966,12	6,93	6,72	708,85
02/01/2020	7,84	8,21	909,43	3,33	3,44	491,26
03/01/2020	5,31	5,47	621,84	3,18	3,24	392,78
04/01/2020	2,38	2,41	281,83	1,41	1,42	169,24
05/01/2020	1,25	1,24	155,71	1,35	1,35	162,79
06/01/2020	2,14	2,17	313,75	2,3	2,33	340,93
07/01/2020	3,61	3,72	541,82	5,89	6,18	870,7


Fonte: Criação própria.




(a) Previsão de carga para o dia
01/01/2020.




(b) Previsão de demanda para o dia
01/01/2020.




(c) Previsão de carga para o dia
02/01/2020.




(d) Previsão de demanda para o dia
02/01/2020.




(e) Previsão de carga para o dia
03/01/2020.




(f) Previsão de demanda para o dia
03/01/2020.




(g) Previsão de carga para o dia
04/01/2020.




(h) Previsão de demanda para o dia
04/01/2020.




(i) Previsão de carga para o dia
05/01/2020.




(j) Previsão de demanda para o dia
05/01/2020.




(k) Previsão de carga para o dia
06/01/2020.



(l) Previsão de demanda para o dia
06/01/2020.



(m) Previsão de carga para o dia
07/01/2020.



(n) Previsão de demanda para o dia
07/01/2020.

Figura 16: Previsões de carga e demanda para o subsistema Nordeste.

Fonte: Criação própria.


5.3.4 Subsistema Sudeste/Centro-Oeste (SE/CO)

Analisando os resultados obtidos através da execução do modelo Holt-Winters Sazonal Duplo nas séries de carga e demanda horária, mesma metodologia supracitada, é possível notar que, no geral, os valores previstos acompanham o comportamento das curvas reais (exceto para o feriado), validando esta aplicação para os dados do subsistema Sudeste/Centro-Oeste (SE/CO). Para os dias 01/01/2020 e 02/01/2020, os valores previstos para a demanda resultaram em erros mais significativos do que os vistos na previsão de carga, dado que estes valores se mantiveram superiores aos valores reais, tanto de demanda quanto de carga, para todo o intervalo de produção de energia solar fotovoltaica, ou seja, de 6 horas até 20 horas. Para o sábado, dia 04/01/2020, ocorreu um fenômeno de subestimação da previsão de carga ao longo das horas do dia, entretanto, para a demanda, os valores preditos foram superestimados para o período compreendido entre 10 horas e 20 horas. Foi constatado que dentre as sete previsões realizadas para a demanda, apenas três exibiram erros menores do que os presenciados na previsão de carga. Comparando os erros relacionados às previsões efetuadas em cada região, é aceitável afirmar que os modelos de demanda de curto prazo do subsistema SE/CO tiveram o terceiro melhor desempenho dentre os subsistemas.


Tabela 8: Resultados das métricas de avaliação para os modelos de previsão do subsistema Sudeste/Centro-Oeste.

Data da previsão	Previsão da carga horária			Previsão da demanda horária		
	MAPE (%)	SMAPE (%)	RMSE (MWh)	MAPE (%)	SMAPE (%)	RMSE (MWh)
01/01/2020	10,44	10,09	3874,93	15,03	14,01	5642,04
02/01/2020	3,33	3,33	1404,31	7,12	6,86	3363,48
03/01/2020	6,26	6,17	2670,83	5,2	5,08	2462,07
04/01/2020	8,33	8,76	3112,99	5,23	5,25	2103,61
05/01/2020	4,71	4,89	1941,72	5,26	5,14	2327,59
06/01/2020	4,22	4,37	2225,89	5,36	5,58	2777,06
07/01/2020	5,43	5,7	3118,70	3,98	4,07	2211,95


Fonte: Criação própria.




(a) Previsão de carga para o dia
01/01/2020.




(b) Previsão de demanda para o dia
01/01/2020.




(c) Previsão de carga para o dia
02/01/2020.




(d) Previsão de demanda para o dia
02/01/2020.




(e) Previsão de carga para o dia
03/01/2020.




(f) Previsão de demanda para o dia
03/01/2020.




(g) Previsão de carga para o dia
04/01/2020.




(h) Previsão de demanda para o dia
04/01/2020.




(i) Previsão de carga para o dia
05/01/2020.




(j) Previsão de demanda para o dia
05/01/2020.




(k) Previsão de carga para o dia
06/01/2020.



(l) Previsão de demanda para o dia
06/01/2020.



(m) Previsão de carga para o dia
07/01/2020.



(n) Previsão de demanda para o dia
07/01/2020.

Figura 17: Previsões de carga e demanda para o subsistema Sudeste/Centro-Oeste.

Fonte: Criação própria.


5.3.5 Subsistema Sul (S)

A modelagem de carga e demanda horária para o subsistema Sul retornou o pior desempenho dentre as análises realizadas, como mostram a Tabela 9 e a Figura 18. Nota-se que a previsão para o feriado, dia 01/01/2020, apresentou o pior resultado dentre os sete dias previstos, sendo o melhor resultado obtido na previsão para a segunda-feira (06/01/2020). Apesar da previsão de demanda para o feriado ter retratado altas taxas de erro, é válido considerar a aplicação desta metodologia para os dados da região Sul, dado que para os demais dias da semana as métricas utilizadas para mensurar a qualidade dos modelos não ultrapassaram um MAPE de 9,36%. Além disso, comparando estas medidas avaliativas, pode-se constatar que os modelos que contemplam a geração distribuída fotovoltaica, isto é, que consideram a demanda, tiveram erros de previsão melhorados em três dos sete casos estudados.


Tabela 9: Resultados das métricas de avaliação para os modelos de previsão do subsistema Sul.

Data da previsão	Previsão da carga horária			Previsão da demanda horária		
	MAPE (%)	SMAPE (%)	RMSE (MWh)	MAPE (%)	SMAPE (%)	RMSE (MWh)
01/01/2020	13,3	12,87	1500,31	26,86	23,36	3142,18
02/01/2020	3,92	4,09	560,93	7,71	7,45	1133,54
03/01/2020	5,08	5,28	633,30	7,24	7,05	989,93
04/01/2020	9,55	10,17	1085,20	4,71	4,83	578,97
05/01/2020	5,03	5,25	570,09	4,87	4,8	632,78
06/01/2020	3,28	3,32	490,3	2,5	2,5	349,98
07/01/2020	5,84	5,89	880,19	9,36	8,88	1590,49


Fonte: Criação própria.




(a) Previsão de carga para o dia
01/01/2020.




(b) Previsão de demanda para o dia
01/01/2020.




(c) Previsão de carga para o dia
02/01/2020.




(d) Previsão de demanda para o dia
02/01/2020.




(e) Previsão de carga para o dia
03/01/2020.




(f) Previsão de demanda para o dia
03/01/2020.




(g) Previsão de carga para o dia
04/01/2020.




(h) Previsão de demanda para o dia
04/01/2020.




(i) Previsão de carga para o dia
05/01/2020.




(j) Previsão de demanda para o dia
05/01/2020.




(k) Previsão de carga para o dia
06/01/2020.



(l) Previsão de demanda para o dia
06/01/2020.



(m) Previsão de carga para o dia
07/01/2020.



(n) Previsão de demanda para o dia
07/01/2020.

Figura 18: Previsões de carga e demanda para o subsistema Sul.

Fonte: Criação própria.

5.4 Projeções de Carga e Demanda

Sabe-se que as previsões do mercado, da carga de energia e de demanda, são fatores que demonstram o desenvolvimento social e econômico de uma sociedade. Dessa forma, esta seção destaca as principais expectativas de crescimento para a carga e para demanda, considerando a micro e minigeração distribuída fotovoltaica, e focando nas perspectivas elaboradas nos relatórios técnicos emitidos pela CCEE, EPE, ONS e MME (EPE e MME, 2021; CCEE, EPE, MME e ONS, 2021). Vale ressaltar, que os dados utilizados nesta dissertação abordaram como base o ano de 2019, em razão do aumento das incertezas causado pela pandemia que se estabeleceu em 2020.

Diversos fatores influenciaram o comportamento do crescimento da carga no SIN ao longo de 2020. A influência da pandemia de COVID-19 sobre o uso da energia elétrica no Brasil ocorreu de forma distinta entre os consumidores. Enquanto as classes de consumo produtivas registraram quedas expressivas no consumo de eletricidade, em especial o comércio e serviços, os consumidores residenciais exigiram mais energia da rede comparativamente ao ano de 2019 devido ao aumento na posse e no uso de seus equipamentos elétricos (CCEE, EPE, MME e ONS, 2021).

As modificações ocorridas no perfil de consumo e os recentes incentivos fiscais direcionados para obtenção do maior número de adotantes de sistemas de MMGD, tornaram as previsões e seus respectivos cenários de crescimento fundamentais para melhorar a eficácia do sistema elétrico brasileiro. Além disso, as perspectivas elaboradas nos relatórios técnicos abordam dois pontos extremamente importantes que afetam diretamente as taxas de crescimento de carga e demanda observadas, são eles: o crescimento econômico e às expectativas de investimento.

A previsão da carga de energia, realizada a partir da previsão de consumo, contempla a agregação de parcela de perdas. As perdas totais englobam as chamadas perdas técnicas inerentes ao transporte de energia elétrica na rede de transmissão e distribuição e as denominadas perdas não técnicas, que consideram ligações irregulares/clandestinas, erros de medição, erros no processo de faturamento, unidades consumidoras sem equipamento de medição e etc. Adicionalmente, as perdas totais contabilizam os casos que atendem os

consumidores livres conectados na rede básica que possuem autoprodução de energia, cujo consumo é integralmente considerado na carga global, porém não no consumo da rede (CCEE, EPE, MME e ONS, 2021).


Com base nas taxas de crescimento anuais indicadas na nota técnica (CCEE, EPE, MME e ONS, 2021) e no Plano Decenal de Expansão de Energia 2030 (EPE e MME, 2021) estima-se que a carga e a contribuição elétrica da MMGD cheguem a atingir (de maneira aproximada) as taxas de evolução exibidas na Tabela 10. Nota-se que o crescimento da micro e minigeração distribuída fotovoltaica no país irá trazer mudanças substanciais nas curvas de demanda horária, fazendo com que seja necessário a aplicação de novos métodos para mensurar a energia total produzida por esses sistemas individuais.

Tabela 10: Estimativa de crescimento da carga e MMGD para os próximos anos.


Ano	Crescimento da carga	Crescimento da MMGD
2022	11%	300%
2025	23%	733%
2030	46%	1333%

Fonte: Criação própria.

Nas Figuras 19 a 23, é possível observar as curvas de carga e demanda referentes a um dia (22/01/2019) e uma semana (20/01/2019 a 26/01/2019), considerando o cenário verão, que mantêm uma política de grande incentivo para a MMGD no país. Levando em conta as perspectivas de crescimento testemunhadas na Tabela 10, nota-se o aumento gradual da carga e a evolução das curvas de demanda (carga somada a estimativa de geração distribuída fotovoltaica). Para o ano de 2030, a participação da micro e minigeração distribuída fotovoltaica na carga final do sistema elétrico brasileiro é muito expressiva, mostrando novamente a importância da realização de estudos que abordem e discutam metodologias como a apresentada nesta dissertação.




(a) Crescimento esperado da carga e da demanda para o dia 22/01/2019.




(b) Crescimento esperado da carga e da demanda para a semana de 20/01/2019 até 26/01/2019.

Figura 19: Crescimento esperado da carga e da demanda para o Sistema Interligado Nacional (SIN).

Fonte: Criação própria.



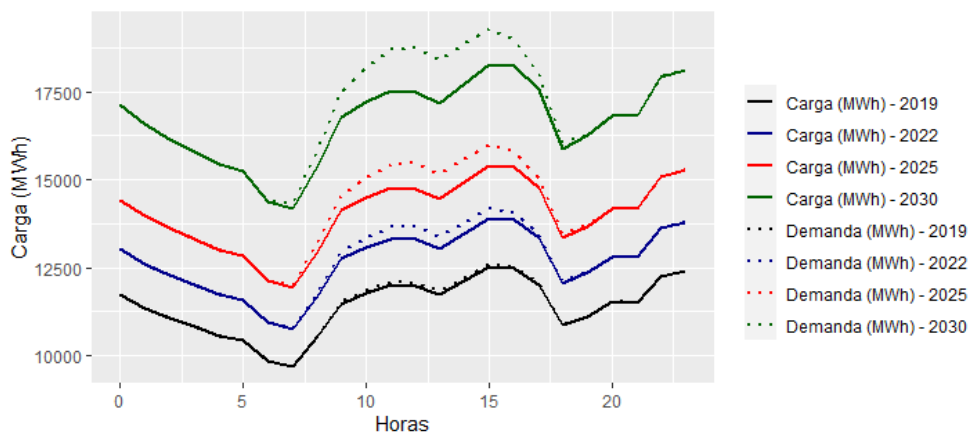
(a) Crescimento esperado da carga e da demanda para o dia 22/01/2019.




(b) Crescimento esperado da carga e da demanda para a semana de 20/01/2019 até 26/01/2019.

Figura 20: Crescimento esperado da carga e da demanda para o subsistema Norte.

Fonte: Criação própria.



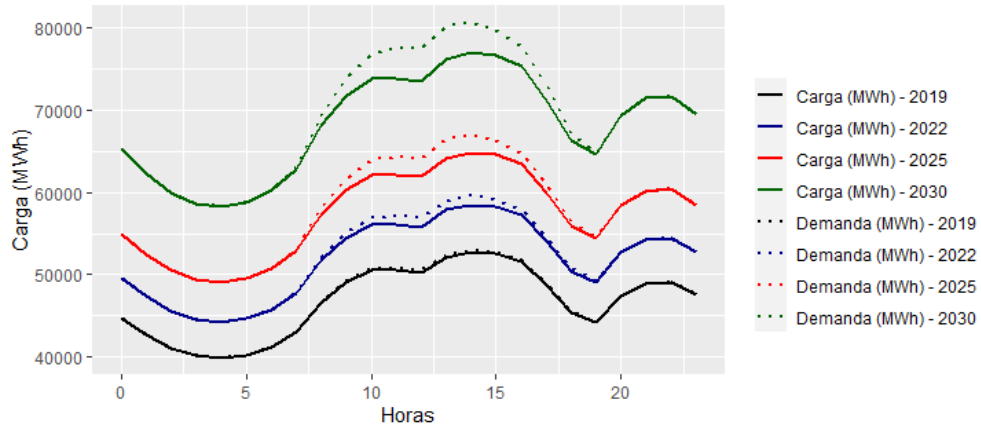
(a) Crescimento esperado da carga e da demanda para o dia 22/01/2019.




(b) Crescimento esperado da carga e da demanda para a semana de 20/01/2019 até 26/01/2020.

Figura 21: Crescimento esperado de carga e demanda para o subsistema Nordeste.

Fonte: Criação própria.




(a) Crescimento esperado da carga e da demanda para o dia 22/01/2019.



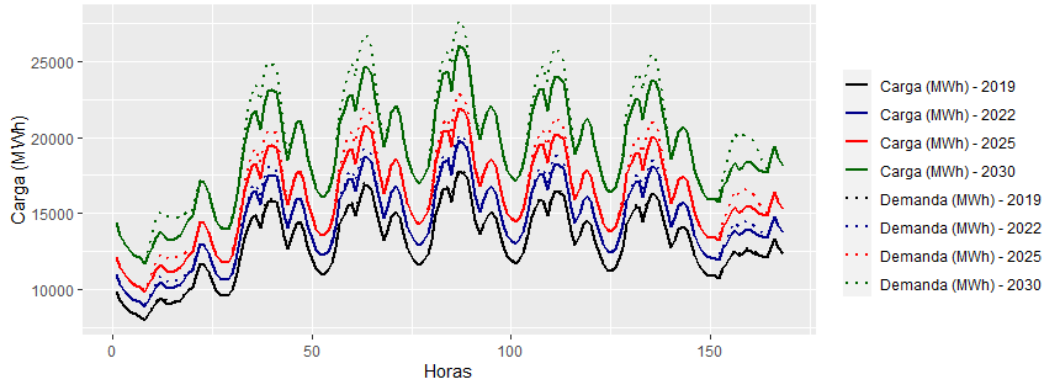
(b) Crescimento esperado da carga e da demanda para a semana de 20/01/2019 até 26/01/2019.

Figura 22: Crescimento esperado da carga e da demanda para o subsistema Sudeste/Centro-Oeste.

Fonte: Criação própria.



(a) Crescimento esperado da carga e da demanda para o dia 22/01/2019.



(b) Crescimento esperado da carga e da demanda para a semana de 20/01/2019 até 26/01/2019.

Figura 23: Crescimento esperado da carga e da demanda para o subsistema Sul.

Fonte: Criação própria.

6 Conclusões

Ao longo desta dissertação foram observadas altas taxas de crescimento para a MMGD no Brasil, onde a falta de disponibilidade de dados públicos resultou na necessidade da implementação de uma nova metodologia para a criação de estimativas para as séries de geração distribuída fotovoltaica. Este novo método foi desenvolvido no decorrer deste trabalho e se mostrou eficaz, dado que ao considerar as previsões de demanda (carga somada a estimativa de MMGD) ocorreu uma melhora significativa nos erros de previsão se comparado aos erros apresentados nas previsões de carga.

Constatou-se que o modelo Holt-Winters Sazonal Duplo, de natureza adaptativa, quando aplicado na previsão de carga e demanda horária de eletricidade, produziu resultados satisfatórios com valores de MAPE inferiores a 10%, exceto para o dia 01/01/2020 que é considerado um feriado totalmente atípico. Dessa forma, para trabalhos futuros, nota-se a importância da aplicação de um tratamento específico para lidar com as incertezas observadas nos diferentes tipos de feriados, mais especificamente, feriados municipais, estaduais e federais.

Em geral, as previsões realizadas atenderam às expectativas, dado que os erros obtidos para todas as localidades consideradas, desconsiderando o feriado, não ultrapassaram 10%. Pode-se destacar que o subsistema Sul apresentou resultados ligeiramente inferiores se comparado com os outros subsistemas e o SIN, o que provavelmente é explicado pela ocorrência de mudanças abruptas no clima da região.

Considerando as projeções de crescimento da MMGD e da carga conforme taxas anuais disponibilizadas na nota técnica (CCEE, EPE, MME e ONS, 2021) e no Plano Decenal de Expansão de Energia 2030 (EPE e MME, 2021), foi possível conjecturar como seria o comportamento das curvas de carga e demanda para os anos 2022, 2025 e 2030. Verifica-se que o crescimento da micro e minigeração distribuída fotovoltaica no país irá trazer mudanças significativas nas curvas de

demanda horária, sendo essas informações extremamente importantes para o planejamento, operação e expansão do setor elétrico brasileiro.

Referências bibliográficas

- [1] ABDELSAMAD, S. F.; MORSI, W. G. e SIDHU, T. S. Probabilistic Impact of Transportation Electrification on the Loss-of-Life of Distribution Transformers in the Presence of Rooftop Solar Photovoltaic. **IEEE Transactions on Sustainable Energy**, v. 6, p. 1565-1573, 2015.
- [2] ALVARADO-BARRIOS, Lázaro; DEL NOZAL, Álvaro R.; VALERINO, Juan B.; VERA, Ignacio G. e MARTÍNEZ-RAMOS, José L. Stochastic unit commitment in microgrids: Influence of the load forecasting error and the availability of energy storage. **Renewable Energy**, v. 146, p. 2060-2069, 2020.
- [3] ALVES, Marliana de O. L. **Energia solar: estudo da geração de energia elétrica através dos sistemas fotovoltaicos ON-GRID e OFF-GRID**. Monografia (Departamento de Engenharia Elétrica), Instituto de Ciências Exatas e Aplicadas, Universidade Federal de Ouro Preto. João Monlevade, Minas Gerais, p. 75, 2019.
- [4] ANEEL (Agência Nacional de Energia Elétrica), 2015. **Resolução Normativa nº 687, de 24 de novembro de 2015**. Disponível em: <https://www2.aneel.gov.br/cedoc/ren2015687.pdf>. Acesso em: 20 de outubro de 2021.
- [5] ANEEL (Agência Nacional de Energia Elétrica). **Micro e minigeração distribuída: sistema de compensação de energia elétrica**. Cadernos Temáticos ANEEL. Brasília: ANEEL, 2016. 31 p. Disponível em: https://www.aneel.gov.br/livros/-/asset_publisher/NBC33JHYPjrv/content/cadernos-tematicos-aneel-micro-e-minigeracao-distribuida-2-edicao/656835. Acesso em: 20 de outubro de 2021.
- [6] ANEEL (Agência Nacional de Energia Elétrica), 2017. **Resolução Normativa nº 800, de 19 de dezembro de 2017**. Disponível em: https://www.in.gov.br/materia/-/asset_publisher/Kujrw0TZC2Mb/content/id/1283002. Acesso em: 30 de outubro de 2021.
- [7] ANEEL (Agência Nacional de Energia Elétrica), 2021. **Portal de Geração Distribuída**. Disponível em: <https://app.powerbi.com/view?r=eyJrIjoiZjM4NjM0OWYtN2IwZS00YjViLTllMjItN2E5MzBkN2ZlMzVkIiwidCI6IjQwZDZmOWI4>

LWVjYTctNDZhMi05MmQ0LWVhNGU5YzAxNzBIMSIsImMiOjR9. Acesso em: 30 de outubro de 2021.

[8] BALACHANDRA, P. e CHANDRU, Vijay. Modelling electricity demand with representative load curves. **Energy**, v. 24, p. 219-230, 1999.

[9] BALASUBRAMANIAN S. e BALACHANDRA P. Characterising electricity demand through load curve clustering: A case of Karnataka electricity system in India. **Computers and Chemical Engineering**, v. 150, 2021.

[10] BETTS, A.K.; ZHAO, M.; DIRMEYER, P.A.; BELJAARS, A.C.M. Comparison of ERA40 and NCEP/DOE near-surface data sets with other ISLSCP-II data sets. **Journal of Geophysical Research**, v. 111, p. 1-20, D22S04, 2006.

[11] BEZERRA, Francisco D. Micro e minigeração distribuída. Caderno Setorial ETENE (Escritório Técnico de Estudos Econômicos do Nordeste), n. 155, 2021. Disponível em: https://www.bnb.gov.br/s482-dspace/bitstream/123456789/678/1/2021_CDS_155.pdf. Acesso em: 20 de outubro de 2021.

[12] BUI, D. M.; LE, P. D.; CAO, T. M; NGUYEN, H.; PHAM, T. T.; PHAM, D. A. A Statistical Data-Filtering Method Proposed for Short-Term Load Forecasting Models. **Journal of Electrical Engineering & Technology**, v. 15, p. 1947-1967, 2020.

[13] CCEE (Câmara de Comercialização de Energia Elétrica). **Preço horário**, 2021. Disponível em: https://www.ccee.org.br/portal/faces/preco_horario_veja_tambem/preco_horario?_adf.ctrl-state=lywd1zirk_102&_afLoop=550927501782857#!%40%40%3F_afLoop%3D550927501782857%26_adf.ctrl-state%3Dlywd1zirk_106. Acesso em: 4 de junho de 2021.

[14] CCEE (Câmara de Comercialização de Energia Elétrica), EPE (Empresa de Pesquisa Energética), MME (Ministério de Minas e Energia) e ONS (Operador Nacional do Sistema Elétrico), 2021. **Previsão de carga para o Planejamento Anual da Operação Energética 2021-2015**. Nota Técnica nº EPE-DEA-SEE-002/2021. Rio de Janeiro: CCEE, EPE, MME e ONS. 34 p. Disponível em: <http://www.ons.org.br/AcervoDigitalDocumentosEPublicacoes/NT%20PLAN%202021-2025%20final.pdf#search=PROJE%C3%87%C3%83O%20DE%20CARGA> Acesso em: 05 de dezembro de 2021.

[15] CEPEL (Centro de Pesquisas de Energia Elétrica). **Relatório de atividades 2017-2018**. Rio de Janeiro: CEPEL, 2018. Disponível em: http://cepel.br/pt_br/ocpepel/str_relatorios_anuais/. Acesso em: 27 de outubro de 2021.

- [16] CEPEL (Centro de Pesquisas de Energia Elétrica). **Planejamento da operação energética**. Rio de Janeiro: CEPEL, 2021. Disponível em: http://www.cepel.br/pt_br/produtos/programas-computacionais-por-categoria/planejamento-da-operacao-energetica.htm. Acesso em: 7 de fevereiro de 2021.
- [17] CHEN, Jiann-Fuh; WANG, Wei-Ming e HUANG, Chao-Ming. Analysis of an adaptive time-series autoregressive moving-average (ARMA) model for short-term load forecasting. **Electric Power Systems Research**, v. 34, p. 187-196, 1995.
- [18] CUI, Herui; PENG, Xu e MU Yupei. Electric Load Forecast Using Combined Models with HP Filter-SARIMA and ARMAX Optimized by Regression Analysis Algorithm. **Mathematical Problems in Engineering**, v. 2015, p. 1-14, 2015.
- [19] DA SILVA, Hendrigo B. **Gestão eficiente dos novos recursos energéticos advindos das redes inteligentes**. Tese (Programa de Pós-graduação em Engenharia de Produção), Escola de Engenharia, Universidade Federal de Minas Gerais. Belo Horizonte, p. 173, 2017.
- [20] DONG, Yongquan; ZHANG, Zichen e HONG, Wei-Chiang. A hybrid seasonal mechanism with a chaotic cuckoo search algorithm with a support vector regression model for electric load forecasting. **Energies**, v. 11, p. 1-21, 2018.
- [21] DUARTE, Rafael G. **Modelo de previsão de carga elétrica considerando a influência da mini e microgeração distribuída no perfil da curva de carga**. Dissertação (Programa de Pós-graduação em Engenharia Elétrica), Pontifícia Universidade Católica do Rio de Janeiro. Rio de Janeiro, p. 86, 2021.
- [22] EBRAHIMI, Akbar e MOSHARI, Amir. Holidays short-term load forecasting using fuzzy improved similar day method. **International Transactions on Electrical Energy Systems**, v. 23, p. 1254-1271, 2013.
- [23] EPE (Empresa de Pesquisa Energética). **Balanco energético nacional 2020: Ano base 2019**. Rio de Janeiro: EPE, 2020a. 292 p. Disponível em: <https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/balanco-energetico-nacional-2020>. Acesso em: 27 de outubro de 2021.
- [24] EPE (Empresa de Pesquisa Energética). **Metodologia: Projeção de curva de carga horária**. Informe Técnico nº NT/EPE/DEA-005/2020. Rio de Janeiro: EPE, 2020b. 27 p. Disponível em: <https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/nota-tecnica-metodologia-projecao-de-curva-de-carga-horaria>. Acesso em: 29 de outubro de 2021.

- [25] EPE (Empresa de Pesquisa Energética), 2021a. **Matriz energética e elétrica**. Disponível em: <https://www.epe.gov.br/pt/abcdenergia>. Acesso em: 27 de outubro de 2021.
- [26] EPE (Empresa de Pesquisa Energética). **Metodologia para criação de séries horárias de geração distribuída fotovoltaica por subsistema**. Informe Técnico nº IT-EPE-DEA-SEE-001-2021. Rio de Janeiro: EPE, 2021b. 14 p. Disponível em: <https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/informe-tecnico-metodologia-para-criacao-de-series-horarias-de-geracao-distribuida-fotovoltaica-por-subsistema>. Acesso em: 20 de outubro de 2021.
- [27] EPE (Empresa de Pesquisa Energética), 2022. **Painel de Dados de Micro e Minigeração Distribuída**. Disponível em: <http://shinyepe.brazilsouth.cloudapp.azure.com:3838/pdgd/>. Acesso em: 5 de janeiro de 2022.
- [28] FARD, A. K. e AKBARI-ZADEH, M. R. A hybrid method based on wavelet, ANN and ARIMA model for short-term load forecasting. **Journal of Experimental and Theoretical Artificial Intelligence**, v. 26, p. 167-182, 2014.
- [29] GROLEMUND G. e WICKHAM H. Dates and Times Made Easy with {lubridate}. **Journal of Statistical Software**, 2011. Disponível em: <https://www.jstatsoft.org/v40/i03/>. Acesso em: 05 de dezembro de 2021.
- [30] HONG, Wei-Chiang e FAN, Guo-Feng. Hybrid empirical mode decomposition with support vector regression model for short term load forecasting. **Energies**, v. 12, p. 1-16, 2019.
- [31] HUANG, S. R. Short-term load forecasting using threshold autoregressive models. **IEE Proceedings-generation transmission and distribution**, v. 144, p. 477-481, 1997.
- [32] HYNDMAN R., ATHANASOPOULOS G., BERGMEIR C., CACERES G., CHHAY L., O'HARA-WILD M., PETROPOULOS F., RAZBASH S., WANG E. e YASMEEN F. forecast: Forecasting functions for time series and linear models. **R package version 8.14**, 2021. Disponível em: <https://pkg.robjhyndman.com/forecast/>. Acesso em: 05 de dezembro de 2021.
- [33] IEA (Agência Internacional de Energia). **Electricity market report**, 2020. Disponível em: <https://www.iea.org/reports/electricity-market-report-december-2020>. Acesso em: 27 de outubro de 2021.
- [34] ILIC, Slobodan; SELAKOVI, Aleksandar; VUKMIROVIC, Srdan; EIDELJAN, Aleksandar e KULIC, Filip. Short-term load forecasting in large scale

electrical utility using artificial neural network. **Journal of Scientific & Industrial Research**, v. 72, p. 739-745, 2013.

[35] KARIM, Samsul A. e ALWI, Saiful A. Electricity load forecasting in UTP using moving averages and exponential smoothing techniques. **Applied Mathematical Sciences**, v. 7, p. 4003-4014, 2013.

[36] KAVOUSI-FARD, Abdollah; SAMET, Haidar e MARZBANI, Fatemeh. A new hybrid modified firefly algorithm and support vector regression model for accurate short-term load forecasting. **Expert Systems with Applications**, v. 41, p. 6047-6056, 2014.

[37] KHOSRAVI, Abbas; NAHAVANDI, Saeid; CREIGHTON, Doug e SRINIVASAN, Dipti. Interval type-2 fuzzy logic systems for load forecasting: A comparative study. **IEEE Transactions on Power Systems**, v. 27, p. 1274-1282, 2012.

[38] KHOSRAVI, Abbas e NAHAVANDI, Saeid. Load forecasting using interval type-2 fuzzy logic systems: Optimal type reduction. **IEEE Transactions on Industrial Informatics**, v. 10, p. 1055-1063, 2014.

[39] KHWAJA, A. S.; ANPALAGAN A.; NAEEM, M. e VENKATESH B. Joint bagged-boosted artificial neural networks: Using ensemble machine learning to improve short-term electricity load forecasting. **Electric Power Systems Research**, v. 179, 106080, 2020.

[40] KIM, Jaeun; RABELO, Matheus; PADI, Siva P.; YOUSUF, Hasnain; CHO, Eun-Chel e YI, Junsin. A review of the degradation of photovoltaic modules for life expectancy. **Energies**, v. 14, p. 1-21, 2021.

[41] KONG, Weicong; DONG, Zhao Yang; JIA, Youwei; HILL, David J.; XU, Yan e ZHANG, Yuan. Short-term residential load forecasting based on LSTM recurrent neural network. **IEEE Transactions on Smart Grid**, v. 10, p. 841-851, 2019.

[42] KUSTER, Corentin; REZGUI, Yacine e MOURSHED, Monjur. Electrical load forecasting models: a critical systematic review. **Sustainable Cities and Society**, v. 35, p. 257-270, 2017.

[43] LAWTON, Richard. How should additive holt-winters estimates be corrected? **International Journal of Forecasting**, v. 14, p. 393-403, 1998.

[44] LEE K. Y.; CHA Y. T. e PARK J. H. Short-term load forecasting using an artificial neural network. **IEEE Transactions on Power Systems**, v. 7, p. 124-132, 1992.

- [45] LIANG, R. H. e CHENG, C. C. Short-term load forecasting by a neuro-fuzzy based approach. **International Journal of Electrical Power & Energy Systems**, v. 24, p. 103-111, 2002.
- [46] MARQUES, Rubéria C., KRAUTER, Stefan C. W. e DE LIMA, Lutero C. Energia solar fotovoltaica e perspectivas de autonomia energética para o nordeste brasileiro. **Revista Tecnologia**, v. 30, n. 2, p. 153-162, 2009.
- [47] METAXIOTIS, K; KAGIANNAS, A; ASKOUNIS, D e PSARRAS, J. Artificial intelligence in short term electric load forecasting: a state-of-the-art survey for the researcher. **Energy Conversion and Management**, v. 44, p. 1525-1534, 2003.
- [48] MME (Ministério de Minas e Energia) e EPE (Empresa de Pesquisa Energética). **Plano decenal de expansão de energia 2029**. Brasília: MME/EPE, 2020. Disponível em: <https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/plano-decenal-de-expansao-de-energia-2029>. Acesso em: 20 de outubro de 2021.
- [49] MME (Ministério de Minas e Energia) e EPE (Empresa de Pesquisa Energética). **Plano decenal de expansão de energia 2030**. Brasília: MME/EPE, 2021. Disponível em: <https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/plano-decenal-de-expansao-de-energia-2030>. Acesso em: 20 de outubro de 2021.
- [50] MOGHRAM, Ibrahim e RAHMAN, Saifur. Analysis and evaluation of five short-term load forecasting techniques. **IEEE Transactions on Power Systems**, v. 4, 1989.
- [51] MORI, H. e KOBAYASHI, H. Optimal fuzzy inference for short-term load forecasting. **IEEE Transactions on Power Systems**, v. 11, p. 390-396, 1996.
- [52] NAKAMURA, Masatoshi. Short term load forecasting using daily updated load models. **Automatica**, v. 21, p. 729-736, 1985.
- [53] ONS (Operador Nacional do Sistema Elétrico), 2021. **Histórico da operação: curva de carga horária**. Disponível em: http://www.ons.org.br/Paginas/resultados-da-operacao/historico-da-operacao/curva_carga_horaria.aspx. Acesso em: 05 de dezembro de 2021.
- [54] PAPAEXOPOULOS, A. D. e HESTERBERG, T. C. A regression-based approach to short-term system load forecasting. **IEEE Transactions on Power Systems**, v. 5, p. 1535-1547, 1990.
- [55] PARK, D. C.; EL-SHARKAWI, M. A.; MARKS, R. J.; ATLAS, L. E. e

DAMBORG M. J. Electric load forecasting using an artificial neural network. **IEEE Transactions on Power Systems**, v. 6, p. 442-449, 1991.

[56] PÉREZ, J.; VELÁSQUEZ, J. D. e FRANCO C. J. Characterization of the hourly load curve in the colombian electricity market. **IEEE Latin America Transactions**, v. 13, p. 3826-3831, 2015.

[57] QUEIROZ, Patrícia Valéria S. **Mensuração do consumo de energia elétrica: algoritmo para detecção de potenciais usuários da termoacumulação como alternativa para deslocamento de carga**. Dissertação (Programa de Pós-graduação em Metrologia), Pontifícia Universidade Católica do Rio de Janeiro. Rio de Janeiro, p. 98, 2011.

[58] RAZA, M. Q. e 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.

[59] R CORE TEAM. R: A language and environment for statistical computing. **R Foundation for Statistical Computing**, Vienna, Austria, 2021. Disponível em: <https://www.R-project.org/>. Acesso em: 05 de dezembro de 2021.

[60] RSTUDIO TEAM. RStudio: Integrated Development Environment for R. **RStudio**, PBC, Boston, MA, 2021. Disponível em: <http://www.rstudio.com/>. Acesso em: 05 de dezembro de 2021.

[61] SANTIKA, G. D.; MAHMUDY, W. F. e NABA A. Electrical load forecasting using adaptive neuro-fuzzy inference system. **International Journal of Advances in Soft Computing and its Applications**, v. 9, p. 50-69, 2017.

[62] SHAH, Aftab Ahmad; KHAN, Zafar A. e ALTAMIMI, Abdullah. SARIMA and Holt-Winters Method based Microgrids for Load and Generation Forecasting. **Przeglad Elektrotechniczny**, v. 97, p. 38-44, 2021.

[63] SHI, Heng; XU, Minghao e LI, Ran. Deep learning for household load forecasting - A novel pooling deep RNN. **IEEE Transactions on Smart Grids**, v. 9, p. 5271-5280, 2018.

[64] SMA (SMA Solar Technology AG), 2021. **Technical Information: Performance ratio**. Disponível em: <https://files.sma.de/downloads/Perfratio-TI-en-11.pdf>. Acesso em: 30 de outubro de 2021.

[65] TAHIR, Zia ul R., AZHAR, Muhammad, MUMTAZ, Manhal, ASIM, Muhammad, MOEENUDDIN, Ghulam, SHARIF, Hanzalah e HASSAN, Sohaib. Evaluation of the reanalysis surface solar radiation from NCEP, ECMWF, NASA,

and JMA using surface observations for Balochistan, Pakistan. *J. Renewable Sustainable Energy*, 12, 023703, 2020a.

[66] TAHIR, Zia ul R.; AZHAR, Muhammad; BLANC, Philippe; ASIM, Muhammad; IMRAN, Shahid; HAYAT, Nasir; SHAHID, Hamza e ALI, Hasnain. The evaluation of reanalysis and analysis products of solar radiation for Sindh province, Pakistan. *Renewable Energy*, v. 145, p. 347-362, 2020b.

[67] TAYLOR, James W. Short-term electricity demand forecasting using double seasonal exponential smoothing. *Journal of the Operational Research Society*, v. 54, p. 799-805, 2003.

[68] TAYLOR, J. W. e MCSHARRY, P. E. Short-term load forecasting methods: an evaluation based on European data. *IEEE Transactions on Power Systems*, v. 22, p. 2213-2219, 2007.

[69] TAYLOR, James W. An evaluation of methods for very short-term load forecasting using minute-by-minute British data. *International Journal of Forecasting*, v. 24, p. 645-658, 2008.

[70] TAYLOR, James W. Short-term load forecasting with exponentially weighted methods. *IEEE Transactions on Power Systems*, v. 27, p. 458-464, 2012.

[71] TRINDADE, Vinicius M. **Otimização de projetos híbridos de geração de energia elétrica compostos pelas fontes eólica e solar fotovoltaica**. Dissertação (Programa de Pós-graduação em Planejamento Energético), Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa em Engenharia – COPPE, Universidade Federal do Rio de Janeiro. Rio de Janeiro, p. 93, 2020.

[72] WAGNER, Adiléa. **Extração de conhecimento a partir de redes neurais aplicada ao problema da cinemática inversa na robótica**. Dissertação (Mestrado em Computação), Universidade do Vale do Rio dos Sinos, 2003.

[73] WICKHAM H. e BRYAM J. readxl: Read Excel Files. **R package version 1.3.1**, 2019. Disponível em: <https://CRAN.R-project.org/package=readxl>. Acesso em: 05 de dezembro de 2021.

[74] WICKHAM H. ggplot2: Elegant Graphics for Data Analysis. **Springer-Verlag New York**, 2016. Disponível em: <https://ggplot2.tidyverse.org>. Acesso em: 05 de dezembro de 2021.

[75] WINTERS, Peter R. Forecasting sales by exponentially weighted moving averages. *Management Science*, v. 6, p. 324-342, 1960.

[76] ZHANG, Pei; WU, Xiaoyu; WANG, Xiaojun e BI, Sheng. Short-term load forecasting based on big data technologies. **CSEE Journal of Power and Energy Systems**, v. 1, p. 59-67, 2015.

[77] ZHANG, Xiaotong; LIANG, Shunlin; WANG, Guoxin; YAO, Yunjun; JIANG, Bo e CHENG, Jie. Evaluation of the reanalysis surface incident shortwave radiation products from NCEP, ECMWF, GSFC, and JMA using satellite and surface observations. **Remote Sensing**, v. 8, p. 1-24, 2016.

Anexo A

Neste anexo constam as informações tabeladas das localidades selecionadas para compor cada subsistema. Suas potências instaladas, em kW, foram consideradas para a estimação das séries de geração distribuída fotovoltaica.

Tabela 11: Localidades selecionadas para o subsistema Nordeste.

Cidade	Estado	Potência Instalada (kW)	Potência Instalada (%)
Teresina	PI	43806,66	5,62
Fortaleza	CE	41282,33	5,30
Petrolina	PE	25427,09	3,26
Natal	RN	19891,42	2,55
Aracaju	SE	17012,79	2,18
Salvador	BA	14786,42	1,90
Mossoró	RN	14644,56	1,88
João Pessoa	PB	12241,37	1,57
Maceió	AL	11808,63	1,52
Sousa	PB	9721,67	1,25
Recife	PE	9388,87	1,20
Parnamirim	RN	8306,27	1,07
Campina Grande	PB	8174,65	1,05
Russas	CE	8172,71	1,05
Barreiras	BA	7819,59	1,00
Juazeiro do Norte	CE	7543,21	0,97
Eusébio	CE	7208	0,92
Lauro de Freitas	BA	7154,16	0,92
Camaçari	BA	6863,82	0,88
Aquiraz	CE	6388,25	0,82
Patos	PB	6315,03	0,81
Picos	PI	6030,28	0,77
Cajazeiras	PB	6005,53	0,77

Vitória da Conquista	BA	6005,36	0,77
Iguatu	CE	5986,87	0,77
Guanambi	BA	5881,75	0,75
Feira de Santana	BA	5431,37	0,70
Luís Eduardo Magalhães	BA	5289,56	0,68
São José do Belmonte	PE	5272,45	0,68
Limoeiro do Norte	CE	5161,79	0,66
Caridade	CE	5019,62	0,64
Maracanaú	CE	4937,74	0,63
Floriano	PI	4931	0,63
Catolé do Rocha	PB	4899,27	0,63
Arapiraca	AL	4886,07	0,63
Juazeiro	BA	4882,96	0,63
Parnaíba	PI	4828,2	0,62
Porto Seguro	BA	4814,9	0,62
Caicó	RN	4446,08	0,57
Carnaíba	PE	4311,29	0,55
Total		392979,59	50,42

Fonte: Criação própria.

Tabela 12: Localidades selecionadas para o subsistema Sul.

Cidade	Estado	Potência Instalada (kW)	Potência Instalada (%)
Caxias do Sul	RS	21047,75	1,91
Santa Cruz do Sul	RS	16625,24	1,51
Maringá	PR	16362,78	1,49
Porto Alegre	RS	16056,49	1,46
Londrina	PR	15816,26	1,44
Nova Hamburgo	RS	14281,02	1,30
Santa Maria	RS	13572,83	1,23

Cascavel	PR	13436,01	1,22
Foz do Iguaçu	PR	12894,79	1,17
Passo Fundo	RS	11054,26	1,00
Blumenau	SC	10793,84	0,98
Toledo	PR	10784,48	0,98
Curitiba	PR	10581,96	0,96
São Leopoldo	RS	9133,4	0,83
Joinville	SC	8728,83	0,79
Florianópolis	SC	8476,01	0,77
Venâncio Aires	RS	8382,96	0,76
Santa Rosa	RS	8362,05	0,76
Pelotas	RS	8335,87	0,76
Jaraguá do Sul	SC	8109,43	0,74
Chapecó	SC	7250,72	0,66
Canoas	RS	7122,89	0,65
Lajeado	RS	6962,28	0,63
Concórdia	SC	6875,82	0,62
Farroupilha	RS	6665,38	0,61
Marechal Cândido Rondon	PR	6517,41	0,59
Erechim	RS	6314,11	0,57
Sapiranga	RS	6048,05	0,55
Francisco Beltrão	PR	5856,71	0,53
Umuarama	PR	5812	0,53
São Borja	RS	5554,18	0,50
Santo Ângelo	RS	5335,26	0,48
Cianorte	PR	5093,31	0,46
Itajaí	SC	5081,09	0,46
Palotina	PR	5057,32	0,46
Bento Gonçalves	RS	4993,03	0,45
Garibaldi	RS	4966,69	0,45
Estrela	RS	4934,89	0,45
Campo Bom	RS	4794,77	0,44
Montenegro	RS	4561,58	0,41
Gravataí	RS	4544,25	0,41

Uruguaiana	RS	4471,25	0,41
Gaspar	SC	4417,42	0,40
Tubarão	SC	4395,44	0,40
São Luiz Gonzaga	RS	4386,38	0,40
Flores da Cunha	RS	4337,47	0,39
Cachoeira do Sul	RS	4266,2	0,39
Carazinho	RS	4248,72	0,39
Apucarana	PR	4227,19	0,38
São Gabriel	RS	4180,14	0,38
Guarapuava	PR	4149,31	0,38
Frederico Westphalen	RS	4129,36	0,38
Ijuí	RS	4104,71	0,37
Cruz Alta	RS	4082,94	0,37
Marau	RS	4063,29	0,37
Brusque	SC	4060,42	0,37
Medianeira	PR	3894,04	0,35
São Miguel do Iguaçu	PR	3839,74	0,35
Santa Helena	PR	3742,3	0,34
São Marcos	RS	3625,53	0,33
Dois Irmãos	RS	3559,51	0,32
Alegrete	RS	3549,92	0,32
Estância Velha	RS	3537,69	0,32
Xaxim	SC	3522,43	0,32
Ponta Grossa	PR	3502,81	0,32
Guaporé	RS	3447,51	0,31
Xanxerê	SC	3426,49	0,31
Guaíra	PR	3413,57	0,31
Arapongas	PR	3410,78	0,31
Santiago	RS	3360,94	0,31
São Lourenço do Sul	RS	3260,57	0,30
Cambé	PR	3247,71	0,30

Viamão	RS	3236,68	0,29
Assis Chateaubriand	PR	3134,98	0,28
Ivoti	RS	3124,53	0,28
Três de Maio	RS	3104	0,28
Rio do Sul	SC	3052,89	0,28
Braço do Norte	SC	3009,16	0,27
Taquara	RS	3006,65	0,27
Cachoeirinha	RS	2968,64	0,27
Panambi	RS	2909,47	0,26
Campo Mourão	PR	2909,04	0,26
Indaial	SC	2862,76	0,26
Três Passos	RS	2840,05	0,26
Mafra	SC	2819,47	0,26
Nova Aurora	PR	2780,17	0,25
Sapucaia do Sul	RS	2777,18	0,25
Teutônia	RS	2737,2	0,25
Arroio do Meio	RS	2722,68	0,25
Gramado	RS	2642,54	0,24
Casca	RS	2624,84	0,24
Carlos Barbosa	RS	2617,87	0,24
Pato Branco	PR	2591,36	0,24
Itaqui	RS	2573,6	0,23
Nova Petrópolis	RS	2555,68	0,23
Horizontina	RS	2493,22	0,23
Total		551134,44	50,07

Fonte: Criação própria.

Tabela 13: Localidades selecionadas para o subsistema Sudeste/Centro-Oeste.

Cidade	Estado	Potência Instalada (kW)	Potência Instalada (%)
Brasília	DF	62714,87	2,42
Cuiabá	MT	56680,05	2,19
Uberlândia	MG	53944,89	2,09

Rio de Janeiro	RJ	47671,32	1,84
Goiânia	GO	37916,43	1,47
Campo Grande	MS	31919,24	1,23
Belo Horizonte	MG	28848,92	1,12
Sorriso	MT	24578,35	0,95
Montes Claros	MG	22574,32	0,87
Dourados	MS	20241,92	0,78
Governador Valadares	MG	19214,53	0,74
Presidente Prudente	SP	19180,85	0,74
Uberaba	MG	18671,4	0,72
Sinop	MT	18595,48	0,72
Lucas do Rio Verde	MT	18566,7	0,72
Campinas	SP	17941,32	0,69
Rondonópolis	MT	17844	0,69
Tangará da Serra	MT	17001,31	0,66
Várzea Grande	MT	16585,76	0,64
Campos dos Goytacazes	RJ	16491,62	0,64
Rio Verde	GO	16324,18	0,63
Ipatinga	MG	15313,72	0,59
Ribeirão Preto	SP	14371,57	0,56
Janaúba	MG	14230,49	0,55
Divinópolis	MG	13610,69	0,53
Anápolis	GO	13558,71	0,52
São Paulo	SP	13315	0,51
Porteirinha	MG	13187,98	0,51
Francisco Sá	MG	13012,88	0,50
Nova Mutum	MT	12641,54	0,49
São José do Rio Preto	SP	11623,51	0,45
Contagem	MG	11618,13	0,45
Taubaté	SP	11272,4	0,44

Pirapora	MG	11241,51	0,43
Aparecida de Goiânia	GO	10740,84	0,42
Itaperuna	RJ	10462,28	0,40
Primavera do Leste	MT	10250,76	0,40
Bauru	SP	9970,83	0,39
Buritzeiro	MG	9883,27	0,38
Niterói	RJ	9116,46	0,35
Itumbiara	GO	8862,93	0,34
Porto Velho	RO	8862,25	0,34
Passos	MG	8845,93	0,34
Franca	SP	8811,78	0,34
Vitória	ES	8787,86	0,34
Patos de Minas	MG	8774,96	0,34
Araguari	MG	8586,78	0,33
Corinto	MG	8515,58	0,33
Jataí	GO	8253,47	0,32
Serra	ES	8184,53	0,32
Nova Serrana	MG	8170,94	0,32
Limeira	SP	8116,12	0,31
Cachoeiro de Itapemirim	ES	7939,35	0,31
Goianésia	GO	7774,97	0,30
Sete Lagoas	MG	7526,26	0,29
Capitão Enéas	MG	7429,17	0,29
Alta Floresta	MT	7359,2	0,28
Paracatu	MG	7182,2	0,28
Nova Lima	MG	7141	0,28
Varginha	MG	6903,09	0,27
Itaúna	MG	6807,6	0,26
Muriae	MG	6803,49	0,26
Betim	MG	6742,48	0,26
Penápolis	SP	6692,61	0,26
Pará de Minas	MG	6591,88	0,25

Unaí	MG	6539,4	0,25
Bonfinópolis de Minas	MG	6518	0,25
Vila Velha	ES	6464,93	0,25
São Francisco	MG	6370,18	0,25
Mato Verde	MG	6339,21	0,25
Guararapes	SP	6329,55	0,24
Rio Branco	AC	6301,64	0,24
Frutaí	MG	6223,47	0,24
Ituiutaba	MG	6189,36	0,24
Piumhi	MG	6059,01	0,23
Jaíba	MG	6038,3	0,23
Araçatuba	SP	5939,26	0,23
Araxá	MG	5855,57	0,23
São José dos Campos	SP	5774,72	0,22
Mirabela	MG	5762,83	0,22
Coronel Fabriciano	MG	5669,53	0,22
Piracicaba	SP	5660,09	0,22
Juiz de Fora	MG	5641,84	0,22
Marília	SP	5629,97	0,22
Várzea da Palma	MG	5589,68	0,22
Vilhena	RO	5575,33	0,22
São Sebastião do Paraíso	MG	5569,04	0,22
Barretos	SP	5563,09	0,22
Brasília de Minas	MG	5545,46	0,21
Andradina	SP	5467,4	0,21
Barra do Garças	MT	5380,2	0,21
Curvelo	MG	5366,25	0,21
Campo Novo do Parecis	MT	5285,1	0,20
Itacarambi	MG	5266,53	0,20
Pouso Alegre	MG	5216,2	0,20

Bebedouro	SP	5210	0,20
Iturama	MG	5209,2	0,20
Cáceres	MT	5196,11	0,20
Caldas Novas	GO	5187,78	0,20
Jaraguari	MS	5150,48	0,20
Quirinópolis	GO	5145,57	0,20
Araraquara	SP	5124,37	0,20
Colatina	ES	5113,58	0,20
Sorocaba	SP	5103,52	0,20
Pontes e Lacerda	MT	5066,6	0,20
Macaé	RJ	5010,27	0,19
Bom Despacho	MG	5003,36	0,19
Teófilo Otoni	MG	4942,7	0,19
Rio Claro	SP	4935,54	0,19
São Mateus	ES	4889,38	0,19
Birigui	SP	4887,54	0,19
Ibitinga	SP	4883,63	0,19
Americana	SP	4868,07	0,19
Catalão	GO	4863,78	0,19
Duque de Caxias	RJ	4853	0,19
Fernandópolis	SP	4828,78	0,19
Morrinhos	GO	4729,83	0,18
Total		1293930,69	50,01

Fonte: Criação própria.