



Rafael Gaia Duarte

**Modelo de previsão de carga elétrica considerando
a influência da mini e microgeração distribuída no
perfil da curva de carga**

Dissertação de Mestrado

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

Orientador: Prof. Ricardo Bernardo Prada
Co-orientador: Prof. Reinaldo Castro Souza

Rio de Janeiro
abril de 2021



Rafael Gaia Duarte

**Modelo de previsão de carga elétrica considerando
a influência da mini e microgeração distribuída no
perfil da curva de carga**

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

Prof. Ricardo Bernardo Prada

Orientador

Departamento de Engenharia Elétrica – PUC-Rio

Prof. Reinaldo Castro de Souza

Co-orientador

Departamento de Engenharia Industrial – PUC-Rio

Profa. Paula Medina Maçaira Louro

Departamento de Engenharia Industrial – PUC-Rio

Prof. José Francisco Moreira Pessanha

Centro de Pesquisas de Energia Elétrica – CEPEL

Rio de Janeiro, 05 de abril de 2021

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

Rafael Gaia Duarte

Graduou-se em Engenharia Elétrica, com ênfase em Sistemas de Potência, pela Universidade Federal Fluminense (UFF) em 2017. Sua área de pesquisa envolve desenvolvimento de ferramentas para previsão de séries temporais.

Ficha Catalográfica

Duarte, Rafael Gaia

Modelo de previsão de carga elétrica considerando a influência da mini e microgeração distribuída no perfil da curva de carga / Rafael Gaia Duarte ; orientador: Ricardo Bernardo Prada ; co-orientador: Reinaldo Castro Souza. – 2021.

86 f. : il. color. ; 30 cm

Dissertação (mestrado)—Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Elétrica, 2021.

Inclui bibliografia

1. Engenharia Elétrica – Teses. 2. Previsão de carga. 3. Redes neurais artificiais recorrentes. 4. Geração distribuída. 5. Energia solar fotovoltaica. I. Prada, Ricardo Bernardo. II. Souza, Reinaldo Castro. III. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Elétrica. IV. Título.

CDD: 621.3

Agradecimentos

A Deus que, pela sua misericórdia e graça, tem sido minha proteção e fonte de alegria e esperança, me permitindo concluir este trabalho em meio ao caos que a humanidade tem atravessado devido ao COVID-19. O agradeço também pela vida de cada uma das pessoas citadas aqui que contribuíram, direta ou indiretamente, para a conclusão de mais uma etapa desafiadora da minha vida.

Aos meus pais, Ana e Jorge, pelo amor e dedicação imensuráveis, por todo incentivo dado durante a minha vida acadêmica que me permitiu chegar até este momento.

À minha família e aos meus amigos, pelo carinho e palavras de incentivo.

Ao meu orientador, Reinaldo Castro, pelo apoio e paciência durante a elaboração da dissertação e pelas aulas que me despertaram interesse em buscar conhecimento em sua área de conhecimento.

Aos professores que participaram da comissão de avaliação da presente dissertação, pelo tempo e atenção concedidos.

Aos meus amigos do Delta de Dirac, pelos momentos ímpares em nossas vidas durante a graduação. Vocês também fazem parte do meu amadurecimento acadêmico.

Aos colegas de turma do mestrado que me auxiliaram durante o curso, tornando leve e prazerosa a caminhada até este momento.

Aos professores e funcionários do DEE da PUC-Rio, pela excelência na qualidade de ensino e prestação de serviço aos estudantes.

À PUC-Rio e à Capes pela oportunidade única de ter estudado em uma universidade reconhecida pela sua excelência acadêmica.

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

Resumo

Duarte, Rafael Gaia; Prada, Ricardo Bernardo; Souza, Reinaldo Castro. **Modelo de previsão de carga elétrica considerando a influência da mini e microgeração distribuída no perfil da curva de carga.** Rio de Janeiro, 2021. 80p. Dissertação de Mestrado – Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

O Brasil vem registrando a cada ano um crescimento expressivo no número de conexões de geração distribuída na rede de distribuição devido à concessão de incentivos governamentais que permitiu a difusão do uso de placas solares fotovoltaicas, fonte de geração de energia mais usada na geração distribuída no Brasil. Em sistemas elétricos com alta penetração de fontes intermitentes a previsão do comportamento da curva de carga tende a representar um grande desafio para os operadores do sistema devido à imprevisibilidade associada à geração de energia, podendo impactar diretamente no planejamento e operação da rede elétrica. Para lidar com esse desafio, este trabalho propõe uma metodologia de previsão de carga usando redes neurais recorrentes com arquitetura LSTM, considerando o impacto da mini e microgeração distribuída solar fotovoltaica conectada à rede de distribuição brasileira. São feitas previsões de carga do Sistema Interligado Nacional brasileiro e dos subsistemas que o integram, levando em conta um horizonte de curto prazo, de 24 horas, em intervalos horários, e um horizonte de médio prazo, de 60 meses, em intervalos mensais. Os resultados indicam que a metodologia pode ser uma ferramenta eficiente para a obtenção de previsões de carga podendo ser utilizada também para horizontes de previsão distintos dos apresentados neste trabalho. O MAPE encontrado para as previsões de curto prazo não passam de 2% e para as previsões de médio prazo não passam de 3,5%.

Palavras-chave

Previsão de carga; Redes Neurais Artificiais Recorrentes; Geração distribuída; Energia solar fotovoltaica.

Abstract

Duarte, Rafael Gaia; Prada, Ricardo Bernardo (Advisor); Souza, Reinaldo Castro (Co-Advisor). **Electric load forecasting model considering the influence of distributed generation on the load curve profile**. Rio de Janeiro, 2021. 80p. Dissertação de Mestrado – Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

Every year, Brazil has been registering a significant growth in the number of distributed generation connections in the distribution grid due to the granting of government incentives that allowed the use of solar photovoltaic panels to spread, the most used source of energy in distributed generation in Brazil. In electrical systems with high penetration of intermittent sources, the prediction of the behavior of the load curve tends to represent a great challenge for system operators due to the unpredictability associated with power generation, which can directly impact the planning and operation of the electrical grid. To deal with this challenge, this work proposes a load forecasting methodology using recurrent neural networks with LSTM architecture, considering the impact of the distributed photovoltaic solar generation connected to the Brazilian distribution grid. Load forecasts are made for the Brazilian National Interconnected System and for the subsystems that integrate it, taking into account a short-term horizon, of 24 hours, in hourly intervals, and a medium-term horizon, of 60 months, in monthly intervals. The results indicate that the methodology can be an efficient tool for obtaining load forecasts and can also be used for different forecast horizons than those presented in this work. The MAPE found for short-term forecasts is no more than 2% and for medium-term forecasts, no more than 3.5%.

Keywords

Electric load forecasting; Recurrent Artificial Neural Network; Distributed generation; Solar photovoltaic power.

Sumário

1	Introdução	13
1.1.	Considerações iniciais	13
1.2.	Motivação e objetivos	16
1.3.	Revisão bibliográfica	18
1.4.	Estrutura da dissertação	19
1.5.	Conclusão do capítulo	20
2	Panorama da mini e microgeração distribuída no Brasil	22
2.1.	Panorama da matriz elétrica do Brasil	22
2.2.	Regulamentação da geração distribuída	24
2.3.	Cenário atual	26
2.4.	Desafios e impactos	30
2.5.	Conclusão do capítulo	35
3	Metodologia	36
3.1.	Introdução	36
3.2.	Mapeamento das informações	37
3.3.	Análise e tratamento dos dados	39
3.4.	Estimação da geração solar fotovoltaica distribuída	40
3.5.	Definição do modelo de previsão de carga	41
3.5.1.	Arquitetura LSTM	43
3.6.	Simulação computacional	46
3.6.1.	Cálculo da estimação da geração solar fotovoltaica distribuída	47
3.6.2.	Treinamento da rede neural para previsão de carga	50
3.7.	Métricas de performance das redes neurais	53
3.8.	Conclusão do capítulo	54
4	Resultados	55
4.1.	Previsão de carga de curto prazo	55
4.1.1.	Sistema Interligado Nacional	55

4.1.2.	Subsistema Sudeste/Centro-Oeste	59
4.1.3.	Subsistema Sul	62
4.1.4.	Subsistema Nordeste	63
4.1.5.	Subsistema Norte	64
4.2.	Previsão de carga de médio prazo	66
4.2.1.	Sistema Interligado Nacional	67
4.2.2.	Subsistema Sudeste/Centro-Oeste	68
4.2.3.	Subsistema Sul	68
4.2.4.	Subsistema Nordeste	70
4.2.5.	Subsistema Norte	72
4.3.	Conclusão do capítulo	72
5	Conclusões	74
5.1.	Trabalhos futuros	76
5.2.	Conclusão do capítulo	77
6	Referências bibliográficas	79

Lista de figuras

Figura 1.1 - Participação das fontes renováveis na produção de energia elétrica.....	14
Figura 1.2 - Custo médio de geração de eletricidade das fontes	15
Figura 2.1 - Oferta interna de energia elétrica por fonte.....	23
Figura 2.2 - Quantidade anual de conexão de GD no Brasil	28
Figura 2.3 - Potência instalada de GD no Brasil.....	29
Figura 2.4 - Composição da capacidade instalada de GD por região do Brasil	30
Figura 2.5 - Curvas de carga horária do SIN dos dias 10/01/2012 e 07/01/2020	34
Figura 3.1 – Fluxograma da metodologia proposta	37
Figura 3.2 - Estrutura interna da arquitetura LSTM	44
Figura 3.3 - Etapas de funcionamento da rede LSTM.....	46
Figura 3.4 - Série temporal da variável exógena para previsões de curto prazo	49
Figura 3.5 - Série temporal da variável exógena para previsões de médio prazo	50
Figura 4.1 - Curvas de carga horária do SIN do dia 01/01/2020.	56
Figura 4.2 - Curvas de carga horária do SIN do dia 02/01/2020	56
Figura 4.3 - Curvas de carga horária do SIN do dia 03/01/2020.	57
Figura 4.4 - Curvas de carga horária do SIN do dia 04/01/2020.	58
Figura 4.5 - Curvas de carga horária do SIN do dia 05/01/2020.	58
Figura 4.6 - Curvas de carga horária do SIN do dia 06/01/2020.	59
Figura 4.7 - Curvas de carga horária do SIN do dia 07/01/2020.	59
Figura 4.8 - Carga horária prevista do Subsistema SE/CO no período de 01/01/2020 a 07/01/2020	61
Figura 4.9 - Carga horária prevista do Subsistema Sul no período de 01/01/2020 a 07/01/2020	63

Figura 4.10 - Carga horária prevista do Subsistema Nordeste no período de 01/01/2020 a 07/01/2020.....	65
Figura 4.11 - Carga horária prevista do Subsistema Norte no período de 01/01/2020 a 07/01/2020	66
Figura 4.12 - Carga de energia prevista do SIN no período de jan/2016 a dez/2020.....	67
Figura 4.13 - Carga de energia prevista do subsistema SE/CO no período de jan/2016 a dez/2020	69
Figura 4.14 - Carga de energia prevista do subsistema Sul no período de jan/2016 a dez/2020.....	70
Figura 4.15 - Carga de energia prevista do subsistema NE no período de jan/2016 a dez/2020.....	71
Figura 4.16 - Carga de energia prevista do subsistema NO no período de jan/2016 a dez/2020.....	72
Figura 5.1 - Média dos erros das previsões de carga de curto prazo.....	75
Figura 5.2 - Média dos erros das previsões de carga de médio prazo.....	76

Lista de Tabelas

Tabela 2.1 - Quantidade de conexão de GD e potência instalada por modalidade de geração	28
Tabela 2.2 - Participação das classes de consumo	30
Tabela 3.1 - Informações sobre a base de dados das previsões de carga de curto prazo	47
Tabela 3.2 - Informações sobre a base de dados das previsões de carga de médio prazo.....	48
Tabela 3.3 - - Informações sobre a base de dados das previsões de irradiação solar.....	49
Tabela 3.4 - Definição dos dados referentes aos hiperparâmetros da rede neural LSTM.....	51
Tabela 4.1 - Resultado das métricas de erros associados ao modelo de previsão de carga de curto prazo do SIN.	60
Tabela 4.2 - Resultado das métricas de erros associados ao modelo de previsão de carga de curto prazo do Subsistema SE/CO.	61
Tabela 4.3 - Resultado das métricas de erros associados ao modelo de previsão de carga de curto prazo do Subsistema Sul.	62
Tabela 4.4 - Resultado das métricas de erros associados ao modelo de previsão de carga de curto prazo do Subsistema Nordeste.	64
Tabela 4.5 - Resultado das métricas de erros associados ao modelo de previsão de carga de curto prazo do Subsistema Norte.....	65
Tabela 4.6 - Resultado das métricas de erros associados ao modelo de previsão de carga de médio prazo do SIN	68
Tabela 4.7 - Resultado das métricas de erros associados ao modelo de previsão de carga de médio prazo do subsistema SE/CO	69
Tabela 4.8 - Resultado das métricas de erros associados ao modelo de previsão de carga de médio prazo do subsistema Sul	70
Tabela 4.9 - Resultado das métricas de erros associados ao modelo de previsão de carga de médio prazo do subsistema Nordeste.....	71
Tabela 4.10 - Resultado das métricas de erros associados ao modelo de previsão de carga de médio prazo do subsistema Norte	73

Nomenclatura

Abreviaturas, Siglas e Símbolos

ANEEL	Agência Nacional de Energia Elétrica
BDMEP	Banco de Dados do INMET
EPE	Empresa de Pesquisa Energética
GD	Geração distribuída
GRU	<i>Gated Recurrent Unit</i>
GW	Gigawatt
kW	Quilowatt
kWh	Quilowatt-hora
kWh/m ²	Quilowatt-hora por metro quadrado
LSTM	<i>Long Short-Term Memory</i>
MAPE	<i>Mean Absolute Percentage Error</i>
MMGD	Mini e microgeração distribuída
MWh/h	Megawatt-hora por hora
MWmed	Megawatt médio
NE	Nordeste
NO	Norte
nRMSE	<i>Normalized Root-Mean-Square Error</i>
ONS	Operador Nacional do Sistema Elétrico
REN	Resolução Normativa
RMSE	<i>Root-Mean-Square Error</i>
SE/CO	Sudeste/Centro-Oeste
SIN	Sistema Interligado Nacional

1

Introdução

1.1.

Considerações iniciais

Segundo dados do World Energy Council (WEC), espera-se que a demanda de energia elétrica apresente um crescimento de 2020 para 2040 de, no mínimo, 45% [1]. Apesar da segurança existente para suprir as necessidades energéticas mundiais por meio do uso de combustíveis fósseis, é de interesse do setor energético buscar atender à demanda de energia por meio do uso e desenvolvimento de fontes de energia que visam diminuir a dependência de fontes que emitem gases do efeito estufa, tendo como objetivo de mitigar futuros problemas climáticos relatados por cientistas [2].

Para que a diminuição da emissão de gases do efeito estufa seja alcançada progressivamente ao longo dos anos sem ter como medida a diminuição do consumo de energia é necessário que fontes renováveis de energia se tornem mais disponíveis no cenário mundial. Diante desse desafio, o setor energético passou a desenvolver estudos para que as fontes renováveis de energia se tornem cada vez mais competitivas diante da alta eficiência dos combustíveis fósseis, para que possam se tornar cada vez mais presentes na matriz energética [2].

Constata-se pelos dados apresentados pela Universidade de Oxford, na Figura 1.1 [3], que a participação das fontes renováveis na matriz elétrica mundial vem apresentando um crescimento ininterrupto desde 2007, passando de 18,14% para 26,66% em 2019. Um dos fatores que explicam o constante crescimento da participação das fontes renováveis é o aperfeiçoamento das tecnologias envolvidas nos projetos de geração de energia que acarretou na diminuição dos custos de produção de eletricidade [4]. Segundo levantamento feito pelo IRENA (*International Renewable Energy Agency*) de 2010 a 2019 o custo médio global de geração de eletricidade pela energia da biomassa, solar fotovoltaica e eólioelétrica apresentaram uma

queda, com destaque para a energia solar fotovoltaica que apresentou uma queda de aproximadamente 82%, como mostra a Figura 1.2 [5]. Desde 2016 a energia solar fotovoltaica passou a ser a fonte de energia renovável que mais vem sendo adicionada anualmente à matriz elétrica mundial [6].

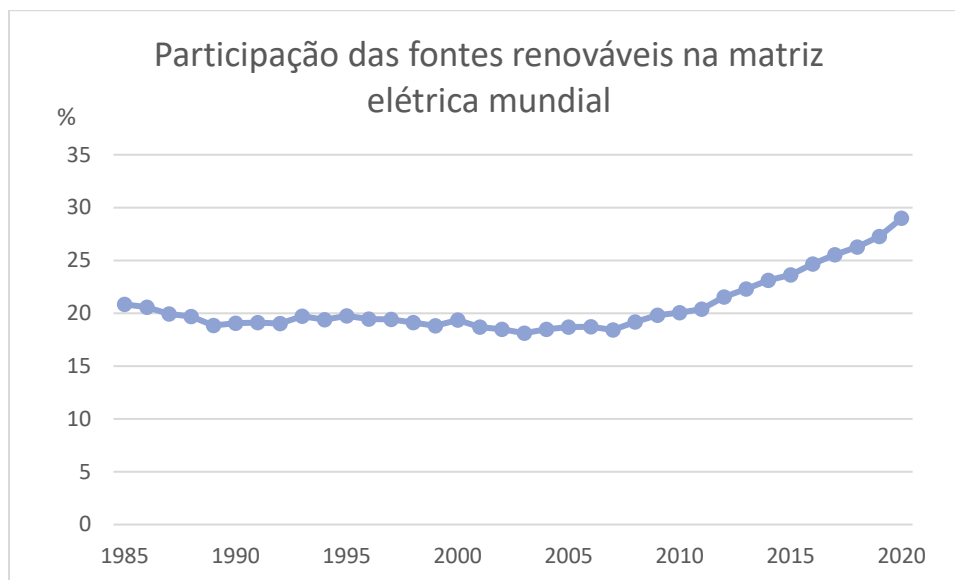


Figura 1.1 - Participação das fontes renováveis na produção de energia elétrica

Fonte: [3]

Um outro fator que explica o crescimento da potência instalada de energia solar fotovoltaica no mundo é a sua capacidade de se integrar a sistemas de energia de pequeno porte, como os residenciais e comerciais, exercendo o papel de gerador distribuído de energia [4]. Estima-se que cerca de 63% da capacidade mundial de energia solar fotovoltaica em 2020 esteja presente em sistemas de geração distribuída (GD) [7].

Diante dos dados apresentados por organizações que estudam o atual cenário energético mundial [1, 3-6] pode-se constatar que as fontes renováveis vêm se tornando cada vez mais eficientes e competitivas em relação aos combustíveis fósseis por meio do crescimento notório de sua participação na matriz energética ao longo dos anos, tornando possível o cumprimento das metas que objetivam mitigar as emissões de gases do efeito estufa. Estima-se que as fontes renováveis de energia terão participação em torno de 40% na matriz elétrica até 2040 [8], o que podem gerar uma redução de até 21% na emissão de gás carbônico até 2050 [9]. Apesar de possuir a terceira maior capacidade instalada dentre as fontes renováveis, com 2,8% de participação na composição da matriz elétrica global [4], a energia solar

fotovoltaica, segundo as projeções feitas pela IEA (*International Energy Agency*), assumirá o protagonismo dentre as fontes renováveis até o ano de 2040 [10]. Grandes feitos ainda serão alcançados até 2050 como pode-se perceber pelas projeções do IRENA [9] que relatam que a geração solar fotovoltaica será responsável pela geração de 25% de toda a eletricidade mundial (chegando até 40% de participação na matriz elétrica australiana) e terá 40% de toda a capacidade solar fotovoltaica mundial instalada proveniente da geração distribuída.

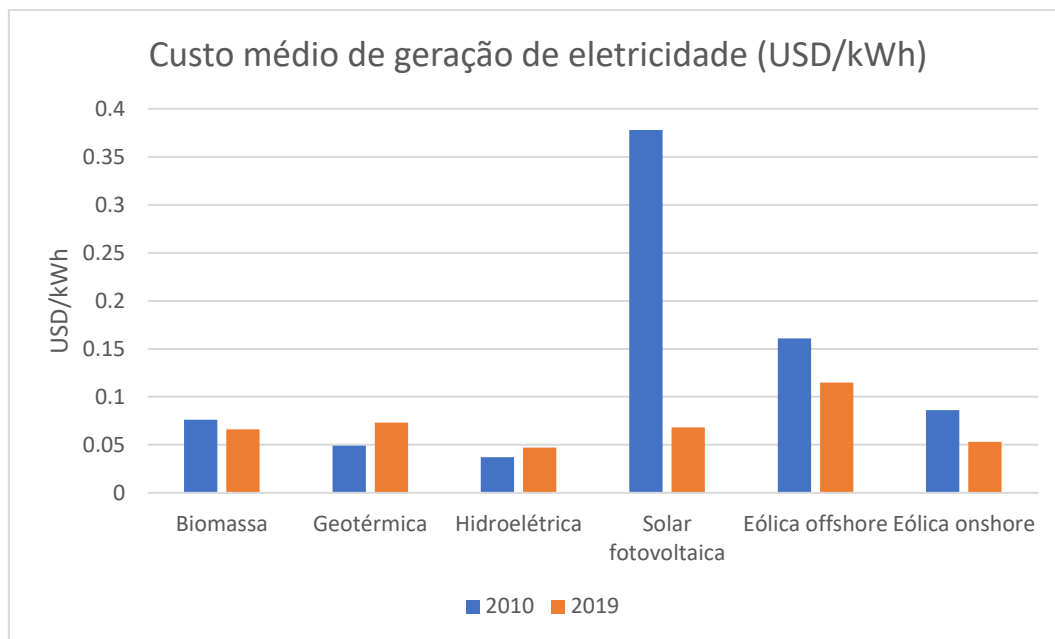


Figura 1.2 - Custo médio de geração de eletricidade das fontes

Fonte: [5]

Essa mudança gradual de paradigma no cenário elétrico mundial exigirá uma adaptação dos agentes envolvidos no mercado de energia para lidarem com questões complexas envolvendo as energias renováveis como, por exemplo, a intermitência de algumas fontes de energia que causam impactos na operação, programação e planejamento dos sistemas elétricos.

Tendo em conta o atual cenário do setor elétrico brasileiro e as análises feitas por organizações especializadas [8, 9, 11] projeta-se que o Brasil passará a receber gradualmente mudanças no setor elétrico devido ao crescimento da descentralização da geração de energia elétrica promovida pelos incentivos dados à aquisição de equipamentos para a geração de energia renovável, com destaque para placas solares fotovoltaicas.

1.2.

Motivação e objetivos

Devido ao crescimento da participação da GD na matriz elétrica brasileira e às projeções otimistas para a década de 2020, os agentes do setor elétrico brasileiro, bem como os pesquisadores, se preparam para lidar com as complexidades inerentes ao planejamento e operação do sistema elétrico [11].

Dentro do contexto de planejamento e programação do sistema elétrico os estudos de previsão de carga representam uma etapa indispensável, tendo como objetivo prever com precisão o comportamento da carga, que possibilita que a operação do sistema elétrico seja confiável, segura e econômica. Na programação da operação do sistema elétrico a previsão de carga de curto prazo se tornou particularmente interessante após a implementação do Modelo de Despacho Hidrotérmico de Curtíssimo Prazo (DESSEM) pelo ONS, em 2021. A previsão de carga, que representa um dado de entrada no DESSEM, quando estabelecida de forma acurada, se torna um dos fatores responsáveis pelo ganho de eficiência no despacho de usinas hidrotérmicas, contribuindo para uma melhor programação diária da operação do sistema e na formação do Preço de Liquidação das Diferenças (PLD) horário mais condizente com a realidade operacional.

Na literatura é possível encontrar inúmeros trabalhos que abordam o desenvolvimento de modelos de previsão de séries temporais destinados a atender, de forma satisfatória, as mais variadas demandas dos usuários. Pode-se citar como contribuição para a discussão em torno dos modelos de previsão a *Makridakis Competition*, competição organizada por Spyros Makridakis que revela a cada ano novas metodologias de previsão de séries temporais apresentadas no *International Journal of Forecasting* [12].

Para a concepção da metodologia desta dissertação foram analisados os seguintes quesitos: modelo usado para realizar previsões (estatístico ou inteligência computacional), horizonte de previsão e uso de variáveis exógenas. No Capítulo 3 desta dissertação encontram-se os trabalhos de previsão que serviram de base para a elaboração da metodologia de previsão, levando-se em consideração diferentes horizontes de previsão como em [13, 14] que apresentam previsões com horizonte de 24 horas e 5 anos e também o uso de variáveis exógenas com o objetivo de obter previsões com maior acurácia como em [15, 16] que levam em consideração

condições climáticas como a temperatura e a umidade do ar e em [17] que informa ao modelo de previsão as diferentes categorias de perfis horários de carga (dias úteis, finais de semana e feriados) das séries temporais.

A grande variedade de trabalhos de previsão de carga com resultados satisfatórios evidencia que não há um modelo de previsão considerado como o melhor, mas existe um ou mais modelos que mais se adequam a um determinado comportamento apresentado pela série temporal de carga e às necessidades do usuário.

Considerando que alta penetração de fontes intermitentes no sistema elétrico contribui para o aparecimento cada vez mais frequente de imprevisibilidades no comportamento da curva de carga, a previsão de carga se tornará cada vez mais desafiadora para o setor elétrico brasileiro tendo em vista as projeções recentes que mostram o crescimento da mini e microgeração distribuída na próxima década.

A intenção deste trabalho é de contribuir para a discussão em torno da previsão de carga com a apresentação de um modelo que leva em consideração uma variável que impacta diretamente no comportamento da curva de carga e, consequentemente, nos resultados da previsão. Pretende-se, então, apresentar aos agentes envolvidos no planejamento e operação de sistemas elétricos e também para os pesquisadores mais uma ferramenta capaz de trazer resultados satisfatórios diante do atual contexto brasileiro, com potencial para ser uma ferramenta eficiente em um contexto de maior inserção de GD num futuro próximo.

Neste trabalho será mostrado uma metodologia de previsão de carga considerando o impacto da mini e microgeração distribuída conectada à rede de distribuição sobre a curva de carga com o objetivo de atender, satisfatoriamente, às necessidades dos operadores que trabalham com sistemas elétricos que contam com a inserção de fontes de energia intermitentes.

Para esse propósito, será usado a rede neural artificial recorrente com arquitetura *Long Short-Term Memory* (LSTM) como modelo previsor que receberá em sua camada de entrada a série temporal da carga elétrica e, como variável explicativa, a estimação da geração solar fotovoltaica distribuída ao longo do tempo. Tendo como base a Programação Diária da Operação Eletroenergética e o Planejamento da Operação Energética, definidos pelo Operador Nacional do Sistema Elétrico (ONS), serão feitos dois tipos de previsão de carga para verificar a aplicabilidade da metodologia: de curto prazo, considerando a previsão para o dia seguinte de operação, em intervalos horários e, de médio prazo, com horizonte de cinco anos,

discretizado mensalmente. As previsões serão feitas para o Sistema Interligado Nacional brasileiro (SIN) e para cada um dos subsistemas contidos no SIN.

1.3.

Revisão bibliográfica

Na literatura podem ser encontrados trabalhos que buscam compreender e mensurar os impactos da difusão da geração distribuída e apresentar soluções para atender as necessidades presentes no contexto atual e futuro do setor elétrico brasileiro e mundial. Pesquisas que apresentam modelos de previsão de carga de um sistema elétrico considerando a inserção de GD na rede de distribuição são escassas na literatura científica. Nesta seção serão mostrados os trabalhos que serviram de referência para a composição da metodologia desta dissertação.

Os trabalhos a serem citados nesta seção contemplam análises de impacto da GD na curva de carga de uma residência e/ou num determinado barramento de uma rede de distribuição, estando aquém das pretensões desta dissertação que visa apresentar uma metodologia que apresenta um modelo de previsão considerando o impacto da GD num contexto nacional.

Fiorotti [18] propõe uma metodologia para determinar a potência firme das unidades de geração distribuída por meio da simulação de Monte Carlo que modelará a potência das fontes renováveis eolielétrica e fotovoltaica, seguida pela aplicação da ferramenta de análise de riscos *Value at Risk*. A metodologia proposta pelo autor tem como função ajudar os modelos de previsão de carga do sistema de distribuição a realizarem previsões mais confiáveis.

Em [19], Xiaojing et al. apresentam uma metodologia de previsão de carga de médio e longo prazo considerando a futura inserção de placas fotovoltaicas e aerogeradores em uma determinada rede de distribuição da China. Primeiramente, os autores realizaram previsão de carga da rede de distribuição sem considerar a inserção da geração distribuída, e, em seguida, determinaram a curva de produção da geração distribuída por meio da simulação de Monte Carlo. Por fim, determinaram a previsão de carga considerando o impacto da GD através da determinação da carga líquida que representa a diferença entre a previsão de carga sem considerar o impacto da GD e previsão da produção de energia da GD.

Em [20], Song et al. desenvolveram um modelo de previsão de carga de médio e longo prazo de uma região considerando as incertezas provenientes da instalação de fontes fotovoltaicas na rede de distribuição com a finalidade de encontrar o valor e o mês com maior demanda de energia. Primeiramente os autores realizaram a previsão da capacidade instalada considerando os fatores: capacidade atual da energia fotovoltaica local, produto interno bruto (PIB) do país, densidade populacional do país, consumo médio de energia residencial, área telhado de novas construções e custo da geração solar fotovoltaica. Por último, será feita a previsão da carga para o ano seguinte, com discretização mensal, a partir da previsão da capacidade instalada da energia solar fotovoltaica em conjunto com a base histórica de dados de carga do sistema elétrico.

Izzatillaev & Ysupovi [21] propõem dois modelos de previsão de carga de curto prazo de um consumidor considerando a influência de sua microgeração distribuída conectada à rede de distribuição. Um modelo é baseado em redes neurais e o outro no *Group Method of Data Handling* (GMDH).

Para a formulação matemática da estimativa da geração solar fotovoltaica foram usados como referência os trabalhos:

- De Hasan et al. [22], que apresenta a potência de saída em função da temperatura ambiente, irradiância solar, área e eficiência do painel fotovoltaico e eficiência dos inversores;
- Da Empresa de Pesquisa Energética (EPE) [23], que leva em consideração o fator de degradação das placas fotovoltaicas ao longo dos anos no cálculo da potência gerada.

Na definição do modelo de previsão de carga foram analisados os diferentes tipos de previsão relatados na literatura, tanto os modelos estatísticos quanto os de inteligência artificial, observando as vantagens e desvantagens de cada um. No Capítulo 3 deste trabalho são mencionados os trabalhos que foram usados como objeto de estudo para a definição do modelo mais adequado para este trabalho e também para estabelecer comparação com os resultados obtidos nesta dissertação.

1.4. Estrutura da dissertação

Esta dissertação é composta por 5 capítulos.

Neste presente capítulo é apresentado o cenário atual da presença de fontes renováveis na matriz elétrica no mundo e as projeções para os próximos anos. Também é mostrado a motivação e o objetivo da metodologia proposta neste trabalho, além da revisão bibliográfica que serviu como norte para concepção desta dissertação.

No Capítulo 2 é mostrado um panorama da matriz elétrica do Brasil e as projeções para os próximos anos feitas pela EPE. Exibe também um breve histórico do desenvolvimento da GD no Brasil, a regulamentação e os incentivos que permitiram o crescimento da mini e microgeração distribuída, o cenário atual da geração distribuída a partir dos dados obtidos pela Agência Nacional de Energia Elétrica (ANEEL) e os desafios e impactos causados pela entrada destes na rede de distribuição.

No Capítulo 3 é exibido os procedimentos usados para definir a construção do modelo utilizado para a realização das previsões de carga. São detalhados como se deu a obtenção dos dados a serem usados na previsão, a metodologia usada para a análise e tratamento dos dados, a formulação matemática da estimação da geração solar fotovoltaica, a definição do modelo de inteligência computacional que será usado para a previsão e a escolha das métricas de performance das previsões obtidas que serão usadas para avaliar a qualidade dos modelos para as previsões.

O Capítulo 4 consiste na apresentação dos resultados obtidos após a definição do modelo de previsão de carga definido no Capítulo 3. São apresentados os resultados da previsão de curto e médio prazos, para o Sistema Interligado Nacional (SIN) e para cada um dos subsistemas elétricos do Brasil.

O Capítulo 5 traz um resumo do que foi apresentado no trabalho e as conclusões feitas a partir das análises sobre os resultados apresentados no Capítulo 4, além das recomendações de aprimoramentos para trabalhos futuros.

1.5.

Conclusão do capítulo

Através da leitura deste presente capítulo foi possível notar que a busca pela diversificação da matriz energética pelo desenvolvimento de fontes renováveis de energia tem crescido consideravelmente desde o início do século XXI. Tendo em vista a busca pela diminuição da emissão de gases poluentes na atmosfera muitos

países têm voltado suas atenções para a utilização de fontes renováveis que estão se tornando cada vez mais competitivas em relação aos combustíveis fósseis.

Diante do crescente uso de fontes renováveis, principalmente as de caráter intermitente, os agentes do setor elétrico precisam se adaptar aos novos desafios trazidos pela diversificação das fontes de energia que impactam diretamente na operação e no planejamento do sistema elétrico.

Considerando esse desafio, o Capítulo 1 mostrou as motivações do autor deste trabalho em apresentar uma metodologia ainda inexistente na literatura capaz de trazer resultados satisfatórios, considerando o atual cenário vivido pelo setor elétrico brasileiro, em uma etapa importante do planejamento e operação do sistema elétrico: a previsão de carga.

Para atingir os objetivos definidos neste capítulo foram analisados trabalhos presentes na literatura que serviram como uma bússola para a concepção da metodologia proposta apresentada no Capítulo 3. Para a aplicação da metodologia no atual contexto de geração distribuída no Brasil foram levantadas informações sobre o cenário atual e as perspectivas da mini e microgeração distribuída em cada unidade federativa que serão apresentadas na seção seguinte.

2

Panorama da mini e microgeração distribuída no Brasil

Neste capítulo serão apresentados, primeiramente, o panorama da matriz elétrica do Brasil, seguido pelo levantamento do estado atual da mini e microgeração distribuída em cada uma das regiões do Brasil, bem como o contexto histórico envolvido e as projeções acerca desta modalidade de geração de energia elétrica que vem crescendo no Brasil. Este capítulo representa uma das referências teóricas que norteou o desenvolvimento da metodologia da previsão de carga mostrada no Capítulo 3 deste trabalho.

2.1.

Panorama da matriz elétrica do Brasil

Com uma matriz elétrica bem diversificada o Brasil ocupava, em 2018, a nona posição entre os países com maior consumo de energia elétrica do mundo, apresentando crescimento no consumo pelo terceiro ano consecutivo de acordo com a IEA [24]. Dentre os dez maiores consumidores de energia elétrica do mundo o Brasil no momento é o país que conta com maior participação das fontes renováveis na composição da matriz elétrica para atendimento da demanda interna, superando, por exemplo, a China e os Estados Unidos da América que representam os países com maior capacidade instalada de fontes renováveis do mundo [3].

De acordo com a EPE, a matriz elétrica brasileira, em 2019, contou com, aproximadamente, 83% de participação de fontes renováveis na oferta interna de energia elétrica, tendo uma queda de 0,3 pontos percentuais (p.p.) em relação ao ano de 2018. O destaque entre as fontes renováveis ficou com a energia hidráulica que foi responsável por quase 65% de participação na geração de energia elétrica, como mostra a Figura 2.1 [23]. Apesar de ser a maior responsável pela geração de energia elétrica no Brasil e de ter tido um acréscimo de aproximadamente 5 GW na sua capacidade instalada a energia hidráulica teve sua participação na composição

da oferta de energia reduzida de 2018 para 2019 devido ao crescimento do uso de outras fontes renováveis de energia. A energia solar foi a fonte renovável que teve maior crescimento, saindo de 0,54% para 1% em 2019 (crescimento de quase 100% na participação da oferta de energia), seguido da energia eólica que passou de 7,6% para 8,6% de participação [23].

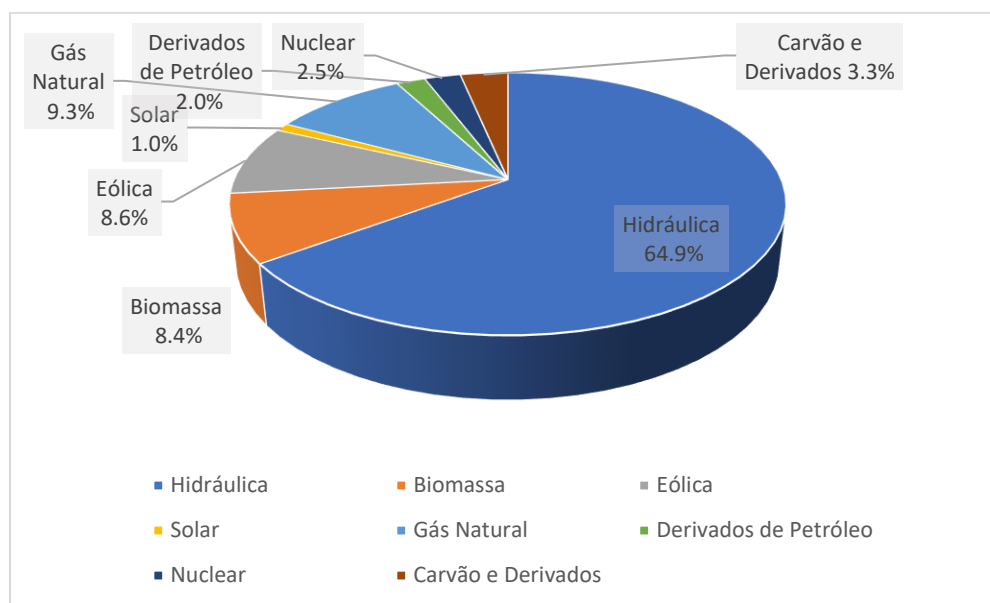


Figura 2.1 - Oferta interna de energia elétrica por fonte

Fonte: [16]

No que diz respeito à capacidade instalada da matriz elétrica brasileira, de 2018 para 2019 as fontes de energia renováveis tiveram crescimento em relação às fontes não renováveis passando de 83% para 83,3%. As fontes renováveis de energia que apresentaram crescimento na participação foram: hidrúlica, solar e eólica [23]. A EPE, por meio do relatório final do Balanço Energético Nacional de 2020 [23], constata que as energias térmica e nuclear sofreram uma estagnação no crescimento da capacidade enquanto que as demais fontes de energia, que são renováveis, estão em constante crescimento, sendo que a energia solar desde 2017 vem sendo a fonte de energia que mais cresce em valores relativos devido aos últimos leilões realizados que viabilizaram a operação das usinas solares.

No atual cenário do setor elétrico brasileiro é necessário também destacar o importante papel que a geração descentralizada vem fazendo após a regulamentação das atividades e os crescentes incentivos concedidos que atraíram interessados nesta nova prática de geração de energia. Com o crescimento da geração distribuída no

Brasil é possível destacar que esta nova modalidade de geração vem contribuindo para o crescimento da participação das fontes renováveis de energia, já que aproximadamente 99% da potência instalada da GD é composta pelas fontes solares fotovoltaicas, pequenas centrais hidrelétricas (PCH's), biomassa e eólioelétrica. Em 2020 a geração distribuída ultrapassou o valor de 4 GW de capacidade instalada, sendo superior à soma das capacidades instaladas das energias nuclear e centralizada solar [24]. Na seção 2.2.3 será exibido com mais detalhes o alcance da GD em cada região do país.

2.2. Regulamentação da geração distribuída

Seguindo a tendência global de difusão do uso de fontes renováveis de energia na matriz elétrica, o Brasil tem concedido incentivos para que o potencial das fontes renováveis seja explorado por meio do crescimento do interesse do público-alvo, desde o produtor de equipamentos das unidades geradoras de energia até o consumidor que deseja se tornar prosumidor¹. Da década de 1990 até o presente momento o governo aprovou inúmeras medidas que ajudaram direta e indiretamente na expansão do uso de fontes renováveis. Assim como mencionado em [11, 25] pode-se citar como principais incentivos e medidas de iniciativa governamental e privada:

- Lei da Informática, criada em 1991, que concede isenções tributárias para empresas que investem em pesquisa e desenvolvimento (P&D) e produção de produtos de informática e automação;
- Isenção do Imposto sobre Circulação de Mercadorias e Serviços (ICMS) em operações que envolvem vários equipamentos destinados à geração de energia elétrica;
- Regime Especial de Incentivos para o Desenvolvimento da Infraestrutura (REIDI) que suspende a exigência de contribuição do Programa de Integração Social/Programa de Formação do Patrimônio do Servidor Público (PIS/PASEP) e Contribuição para o Financiamento da Seguridade Social COFINS incidentes sobre bens e serviços voltados para o setor de energia;

¹ Prosumidor é a junção dos termos produtor e consumidor, nome dado ao consumidor que produz a sua própria energia elétrica.

- Desconto para operações do minigerador e do microgerador de energia elétrica na Tarifa de Uso dos Sistemas de Transmissão (TUST) e na Tarifa de Uso dos Sistemas de Distribuição (TUSD) (nos primeiros dez anos do empreendimento), isenção de PIS/PASEP e COFINS e desconto, ou, em alguns estados, isenção de ICMS;
- Condições diferenciadas de financiamento de projetos voltados para pesquisa e uso de fontes renováveis de energia oferecidas por instituições governamentais, como o Banco Nacional do Desenvolvimento (BNDES) e a Caixa Econômica Federal, e por instituições financeiras privadas.

Além desses incentivos citados, a regulamentação da geração distribuída foi importante para definir as regras necessárias para o estabelecimento das unidades geradoras. Dá-se início às relações entre as distribuidoras de energia e as unidades de GD a partir do Artigo 14º do Decreto Lei nº 5163 de 2004 que estabelece a definição de GD no Brasil e da Lei nº 10 848 de 2004 que determina as condições de contratação de energia proveniente de geração distribuída por parte das distribuidoras. Nesse modelo de relação as distribuidoras estavam restritas a contratar energia de “empreendimentos de agentes concessionários, permissionários e autorizados” [25].

Com a intenção de expandir a descentralização da geração de energia elétrica a Agência Nacional de Energia Elétrica (ANEEL), em 2012, pôs em vigor a Resolução Normativa nº 482/2012 que estabelece condições para que as unidades consumidoras com minigeração e microgeração distribuídas que geram sua própria energia a partir de fontes renováveis ou por meio da cogeração tenham acesso ao sistema de distribuição de energia para fornecer o excedente de energia para a rede de distribuição em que estiverem conectados.

Segundo dados da ANEEL [26], até a data de estabelecimento da Resolução nº 482/2012 o Brasil contava com a presença de 19 unidades consumidoras com mini e microgeração, com capacidade total de, aproximadamente, 636 quilowatts (kW), valores considerados inexpressivos diante do potencial exploratório de fontes renováveis que o Brasil possui. No ano de implementação prática da Resolução, em 2013, o Brasil teve a conexão de mais 59 unidades de GD no ano inteiro, contabilizando 1494 kW de potência instalada, mostrando que a regulamentação da GD trouxe benefícios para o crescimento da descentralização da geração ao exibir um desempenho superior à soma dos anos anteriores.

Tendo em vista aumentar o público alvo e aperfeiçoar as condições de integração das unidades consumidoras à rede elétrica a ANEEL revisou a Resolução nº 482/2012 e publicou a Resolução Normativa nº 687/2015. As principais inovações que entraram em vigor são: permissão de uso de qualquer fonte renovável, definição da microgeração distribuída como central geradora com potência instalada até 75 kW e minigeração distribuída como central geradora com potência acima de 75 kW e menor ou igual a 3 megawatts (MW) para fontes hídricas e menor ou igual a 5 MW para as demais fontes renováveis ou cogeração, possibilidade de instalação de geração distribuída em empreendimentos de múltiplas unidades consumidoras e o sistema de compensação de energia elétrica, também conhecido como *net metering*². A Resolução passou por mais uma alteração em 2017 com a publicação da Resolução Normativa nº 786/2017 que, como principal medida, alterou o valor da potência máxima instalada da minigeração distribuída, passando de 3 MW para 5 MW para qualquer fonte renovável [27].

A partir da implementação das novas medidas da Resolução de 2015, o Brasil passou a registrar crescimento expressivo no número de novas conexões de GD. Em 2016, por exemplo, a conexão de novas unidades de GD foi maior do que o valor registrado no acumulado até o início do ano de 2016, revelando a eficácia das medidas adotadas [26].

2.3. Cenário atual

A ANEEL disponibiliza informações referentes à conexão de mini e microgeração distribuídas nas redes de distribuição pelo Brasil por meio de um endereço eletrônico para consulta pública [26]. Por meio deste endereço é possível extrair informações como data e local de conexão de uma unidade consumidora, potência instalada, tipo de GD, classe de consumo, etc. Através da análise desses dados é possível estabelecer um ponto de partida para a compreensão da magnitude do impacto da geração distribuída no sistema elétrico brasileiro. No decorrer desta seção

² Net metering é um sistema de compensação de energia em que o excedente de energia elétrica produzido pela unidade consumidora é injetado na rede e transformado em créditos que servirão como desconto no consumo final de energia elétrica ativa.

são apresentadas informações sobre a GD desde o ano de publicação da Resolução nº 482/2012 até o final do ano de 2020.

Entre a primeira instalação que ocorreu em 2008 até a data de publicação da Resolução nº 482/2012, no dia 17/04/2012, a ANEEL contabilizou 15 conexões entre mini e microgeração distribuída com a rede de distribuição totalizando 582 kW de capacidade total.

No ano seguinte à publicação da resolução da ANEEL, em 2013, percebe-se que a adesão foi superior ao registrado nos anos anteriores. Só em 2013 a ANEEL registrou mais conexões novas e potência instalada na rede em comparação com a soma dos anos anteriores. Após a introdução da Resolução nº 482/2012 a quantidade de conexões novas continuou crescendo a cada ano, fazendo o Brasil saltar de 582 kW de capacidade instalada antes da publicação da resolução a 4,7 GW em 2020, como mostram as Figuras 2.3 e 2.4 [26]. Tais resultados observados no cenário brasileiro mostram que além dos incentivos fiscais concedidos ao público-alvo da GD o aspecto regulatório e a facilidade de conexão da energia solar fotovoltaica vêm exercendo grande impacto na disseminação da geração descentralizada.

No período entre 2013 e 2020, a Resolução Normativa passou por duas revisões que contribuíram para o crescimento do número de conexões, através de medidas como: diversificação da modalidade de geração, alteração da definição de minigeração distribuída, entrada do sistema de compensação de energia, dentre outras [27].

Por meio da Resolução nº 687/2015 foi possível atrair um público interessado em possuir geração distribuída em modalidades diferentes da modalidade de geração na própria unidade consumidora, a única permitida pela ANEEL na resolução de 2012. A inclusão proposta pela Resolução nº 687/2015 permitiu a entrada das modalidades: empreendimentos com múltiplas unidades consumidoras, geração compartilhada e autoconsumo remoto [27]. Através desta inclusão na resolução o Brasil até o final de 2020 possuía em cerca de 55.000 conexões de GD enquadradas nessas três novas modalidades de geração, representando 14% do total de conexões, como mostra a Tabela 2.1 [26]. Já com a Resolução Normativa nº 786/2017 foi possível ter conexões de GD com a rede de distribuição com potência acima de 1 MW por meio da revisão da Resolução Normativa nº 482/2012 que não permitia conexão de minigeração distribuída com potência superior [27]. Com a revisão da Resolução foi possível ter até o final de 2020 a conexão de 81 unidades de GD,

correspondendo a uma capacidade instalada de aproximadamente 227 MW, cerca de 5% da capacidade total [26].

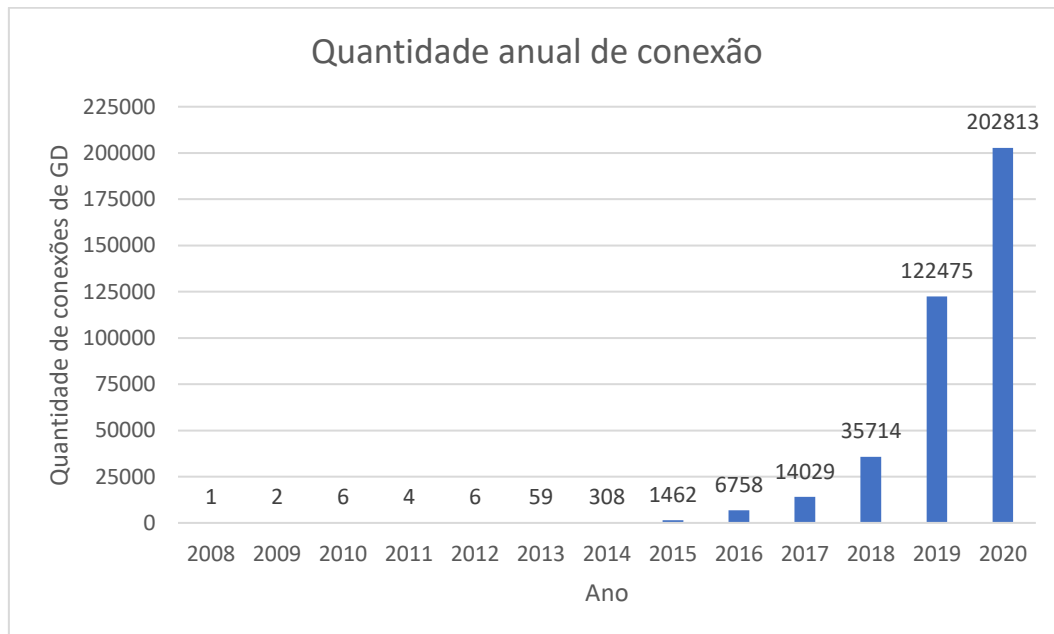


Figura 2.2 - Quantidade anual de conexão de GD no Brasil

Fonte: [26]

Tabela 2.1 - Quantidade de conexão de GD e potência instalada por modalidade de geração

Fonte: [26]

Modalidade de geração	Quantidade de conexão de GD	Potência instalada (kW)
Autoconsumo remoto	54023	903644,95
Geração compartilhada	808	43027,81
Geração na própria UC	328618	3795823,18
Múltiplas UC	188	4550,26

Além das resoluções publicadas permitirem uma maior adesão à GD, os incentivos oferecidos e a praticidade da instalação permitiram que a energia solar fotovoltaica atraísse cada vez mais o interesse dos consumidores de pequena escala. Em 2020 a microgeração solar fotovoltaica distribuída, que representa a geração em pequena escala, era responsável por 99% das conexões de GD na rede de distribuição e tinha participação em 80% da capacidade total instalada. Dentro desse grupo de consumidores de pequena escala estão os de classe residencial que foram particularmente beneficiados com o aumento do custo benefício da geração de energia solar, tornando-os, ao longo dos anos, cada vez mais participativos na

capacidade instalada de GD, chegando bem próxima da classe comercial como pode ser observado na Tabela 2.2 [26].

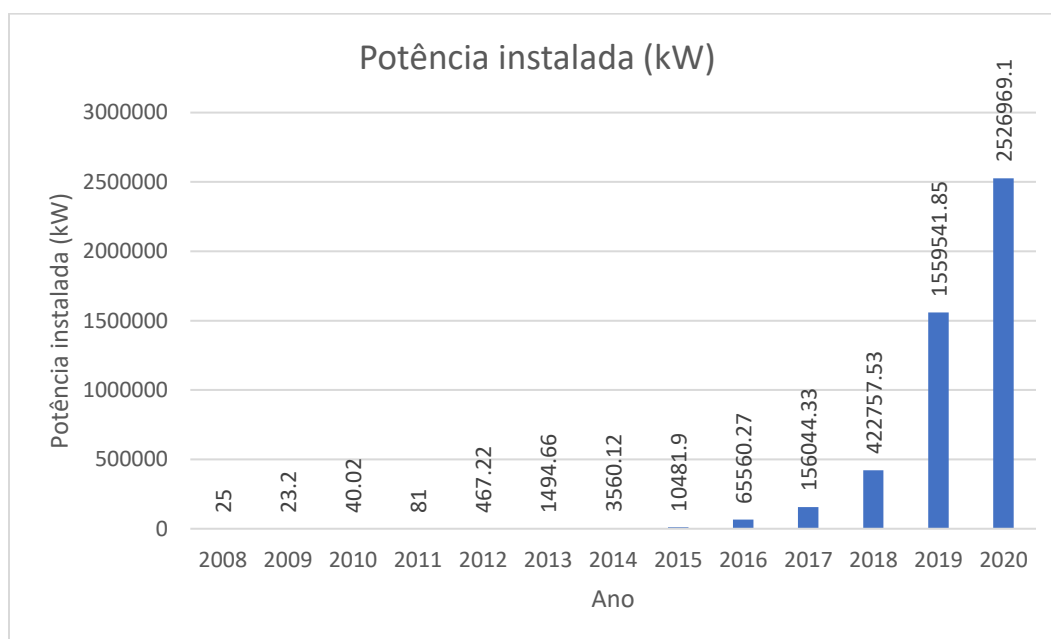


Figura 2.3 - Potência instalada de GD no Brasil

Fonte: [26]

A Figura 2.5 [26] traz a participação de cada uma das regiões do Brasil na composição da capacidade instalada de GD. A nível regional a mini e microgeração distribuída possui grande destaque na Região Sudeste que, desde 2016, passou a ter maior participação na capacidade instalada, sendo que em 2020 sua contribuição passou a ser de mais de um terço de toda potência instalada no Brasil. A Região Sul foi a última região a ter sua primeira conexão de GD na rede elétrica, em 2013, e desde 2017 passou a ter a segunda maior capacidade instalada, chegando a ter 23% de participação total em 2020. A Região Nordeste, terceira maior em participação na potência instalada total (18%), ocupou por quatro anos, de 2012 a 2015, o posto de Região do Brasil de maior capacidade instalada de mini e microgeração distribuída. A Região Centro-Oeste e a Região Norte foram as regiões que tardiamente reagiram aos incentivos concedidos e à publicação da regulamentação, culminando em uma menor participação na capacidade instalada total e, por esse motivo, encontram-se nas duas últimas colocações nesse quesito. De 2016 a 2020 tem crescido a participação dessas regiões na composição da capacidade instalada com os crescentes investimentos realizados, com destaque para o estado do Mato Grosso que é

o quarto maior estado em capacidade instalada e possui a cidade – Cuiabá - com maior participação na capacidade instalada.

Tabela 2.2 - Participação das classes de consumo na capacidade instalada de GD
Fonte: [26]

Classe de consumo	Participação (%)			
	2013	2016	2018	2020
Comercial	58,86	38,83	42,15	38,62
Iluminação pública	0,00	0,04	0,01	0,00
Industrial	23,11	18,89	12,19	9,05
Poder Público	2,47	4,41	2,57	1,19
Residencial	13,50	31,04	32,42	37,49
Rural	1,97	6,26	10,38	13,56
Serviço Público	0,09	0,53	0,28	0,07

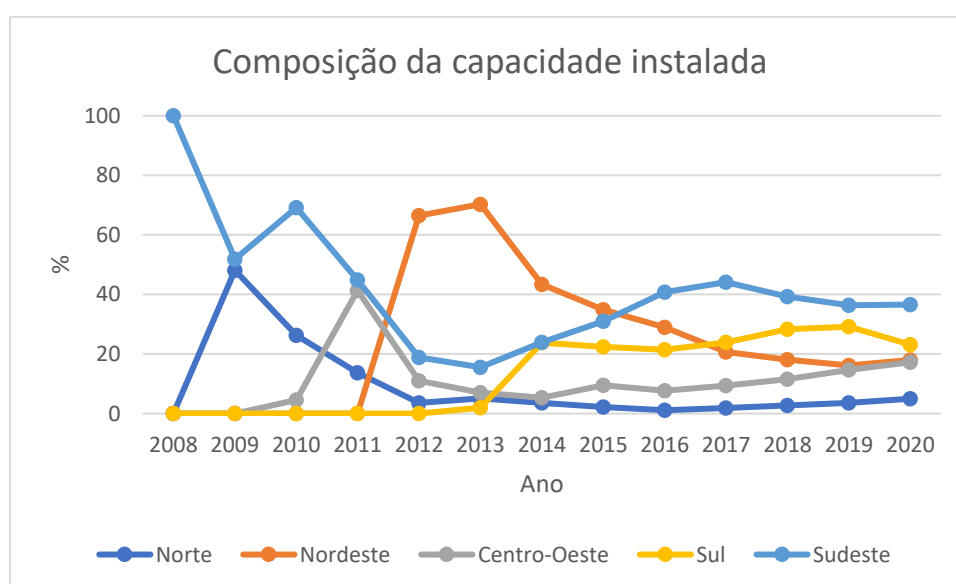


Figura 2.4 - Composição da capacidade instalada de GD por região do Brasil
Fonte: [26]

2.4. Desafios e impactos

A GD apareceu no cenário mundial como uma das alternativas tecnológicas que vieram para transformar o atual paradigma de operação que é marcado pela geração centralizada de energia. A conexão de GD na rede de distribuição tem como objetivo trazer benefícios como: diminuição das emissões de gases do efeito estufa e perdas elétricas, aumento da segurança da garantia de oferta de energia aos consumidores, adiamento de investimentos em reforço e expansão de centrais

geradoras e das redes de transmissão, etc. Mas para que os benefícios sejam vistos é necessário que alguns ajustes sejam feitos para que a experiência da GD seja benéfica para o sistema elétrico. Nesta seção são mostrados alguns trabalhos que analisaram os possíveis impactos causados pela inserção de GD na rede e desafios que o setor elétrico brasileiro deverá enfrentar durante a década de 2020 e nos anos seguintes para garantir a sustentabilidade deste novo modelo de geração de energia.

Diante dos avanços obtidos a partir do ano de 2019 a mini e a microgeração distribuídas vêm se tornando cada vez mais importantes e impactantes no setor elétrico brasileiro. Estima-se que a mini e a microgeração distribuída juntas corresponderiam a cerca de 2,7% da capacidade instalada de geração elétrica do Brasil caso fizessem parte da estimativa da Empresa de Pesquisas Energéticas (EPE) em 2020 [13, 26]. Esse dado mostra que a GD, apesar de possuir um pequeno papel em relação à geração centralizada, não ocupa mais um lugar irrelevante no cenário elétrico brasileiro e evidencia a importância de se estabelecer estudos para avaliar os impactos dessa nova perspectiva de geração de energia.

Tendo em vista a importância de se analisar os cenários atual e futuro da mini e microgeração distribuída, a EPE realizou estudos que visam apresentar os principais desafios que os agentes do sistema elétrico brasileiro deverão enfrentar diante das projeções feitas para a década de 2020. Através do Plano Decenal de Expansão de Energia a EPE mostra que até 2029 a capacidade instalada da mini e microgeração distribuída deverá atingir o valor de 11,4 GW, com energia suficiente para atender a 2,3% da carga total do sistema elétrico [28]. Um outro estudo feito pela EPE afirma que a energia solar fotovoltaica produzida pela GD responderá por 1,3% de toda a carga do SIN em 2030 e por 5,7% em 2050, podendo trazer resultados ainda maiores devido a adoção de novas medidas de incentivo [29].

Baseado neste cenário de expansão da GD na próxima década, trabalhos como [11, 25, 29-32] relatam os desafios que precisam ser estudados e as possíveis medidas que podem ser adotadas no Brasil para que a geração distribuída possa ser uma experiência que traga benefícios ao público alvo e aos agentes reguladores do setor elétrico.

Um dos problemas a serem resolvidos é em relação às adaptações que deverão ser feitas nas diretrizes regulatórias tendo em vista a busca pelo crescimento sustentável da mini e microgeração distribuída (MMGD). No atual modelo a tarifa de energia é composta por custos fixos e variáveis que as distribuidoras repassam para

os clientes. Como a receita das distribuidoras está associada ao volume de energia adquirida pelos consumidores, a EPE [28] e Castro [29, 30] alertam que com o crescimento dos prosumidores o consumo vai cair, mas os custos operacionais das concessionárias não serão alterados. Dessa forma, seguindo esse cenário, as distribuidoras terão um faturamento menor que ocasionará um desequilíbrio em sua estrutura financeira.

EPE [28] e Castro [29] propõem alterações na estrutura de arrecadação das distribuidoras para mitigar o desequilíbrio existente entre as concessionárias e os consumidores que podem trazer prejuízos para ambas as partes.

Castro [29] defende que grandes mudanças estruturais nos custos das distribuidoras devem ser feitas, mas não serão vistas em um curto prazo de tempo e, com isso, a solução primária seria propor um aumento da tarifa de energia diante do crescimento dos prosumidores. Mas tal solução não é vista como eficaz, visto que o aumento da tarifa serviria como incentivo para a conexão de mais MMGD na rede elétrica, que por sua vez ocasionaria um novo aumento na tarifa de energia elétrica, tornando este processo um ciclo vicioso que pode trazer, por exemplo, prejuízos aos consumidores de baixa renda que não possuem condições financeiras de investirem em GD.

A EPE [28] defende que a eficiência na arrecadação da receita das concessionárias, através do correto repasse dos custos operacionais para os consumidores e prosumidores, será alcançada por meio da alteração do mecanismo de compensação de energia da MMGD definida na Resolução Normativa (REN) nº 482, que será analisada em breve pela ANEEL. Além dessa proposta a EPE também sugere a definição de uma tarifa binômia, aplicadas sobre o consumo e demanda de energia, para os consumidores de baixa tensão. Tais medidas, segundo a empresa, deverão trazer mais equilíbrio à relação entre os agentes envolvidos sem afetar as projeções referentes ao crescimento do número de conexões de MMGD até 2029.

Além da revisão da política regulatória vigente que rege o setor elétrico serão necessárias também adaptações na rede elétrica, bem como alterações nos procedimentos operativos do sistema elétrico brasileiro para atender à crescente inserção de MMGD.

A alta inserção de MMGD pode causar na rede elétrica distorção da curva de carga causada pela presença predominante de fontes de energia solar fotovoltaica que possuem como uma das principais características a intermitência na geração de

energia. Castro [29] afirma que nesses sistemas com alta penetração de energia solar fotovoltaica na medida em que há um aumento de incidência solar é possível que haja uma inversão no fluxo de potência, com a rede elétrica sendo alimentada pela MMGD e, no momento em que há diminuição da irradiação solar para essas fontes, principalmente durante o período da tarde, ocorre um aumento abrupto na curva de carga, implicando numa curva de carga com oscilações bruscas na demanda de energia. Essas variações não são desejáveis para o sistema elétrico porque acarretam na redução da previsibilidade do comportamento da curva de carga e diminuição ou aumento do despacho de energia de centrais geradoras centralizadas num curto espaço de tempo, afetando diretamente na correta operação do sistema [29, 30, 32].

Castro [30] apresenta a situação vivida no estado da Califórnia, nos Estados Unidos da América, como exemplo real de oscilações bruscas na curva de carga diária. O operador independente do sistema da Califórnia (CAISO) detectou que o perfil da curva de carga do sistema elétrico local possui o formato de um pato, caracterizado pela queda brusca da carga elétrica durante o período de maior produção de energia solar fotovoltaica - que representa a fonte de energia mais participativa na geração distribuída - e pelo crescimento abrupto no momento de menor geração distribuída, que reflete o aumento da dependência da oferta da geração centralizada.

Castro [29] propõe que umas das soluções eficientes para mitigar as oscilações repentinas na curva de carga é o uso de sistemas de armazenamento de energia. Durante o período do dia em que há alta produção de energia o excedente fica armazenado em baterias para ser usado no período da tarde e/ou noite, ao invés de ser injetado na rede [11, 33]. Uma outra solução que possivelmente será útil no futuro é o crescimento do uso de carros elétricos, que pode ser usado para evitar a alta injeção de energia proveniente da geração distribuída [29].

No Brasil, levando-se em conta o atual cenário de inserção de geração distribuída, não é possível verificar alterações visíveis no perfil da curva de carga como é visto na Califórnia. A Figura 2.8 [34], que mostra o perfil da curva de carga diária do SIN nos dias 10/01/2012 e 07/01/2020, corrobora a afirmativa de que o crescimento da participação da geração distribuída na matriz elétrica brasileira ainda não é capaz de provocar alterações consideráveis no comportamento da curva de carga do sistema elétrico.

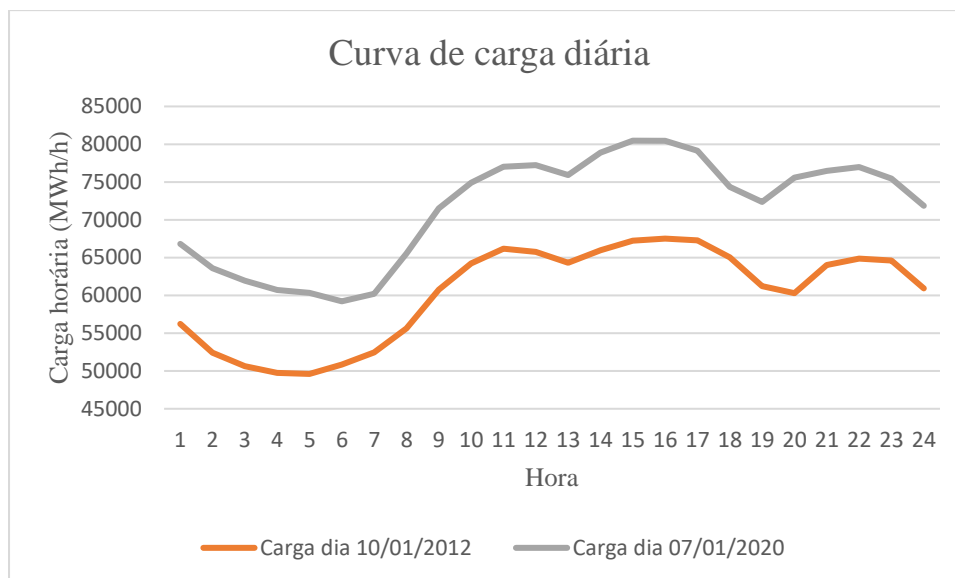


Figura 2.5 - Curvas de carga horária do SIN dos dias 10/01/2012 e 07/01/2020

Fonte: [34]

Levando-se em conta a atual infraestrutura das redes de distribuição do Brasil, a conexão cada vez maior de MMGD poderá trazer impactos negativos na qualidade da energia elétrica devido à participação predominante de fontes de energia com intermitência, como a solar fotovoltaica. As redes de distribuição estão, em sua grande maioria, configuradas para atender de forma satisfatória o obsoleto padrão estrutural do sistema elétrico, onde uma central geradora longe da carga é encarregada de suprir a demanda de energia, estabelecendo-se assim um fluxo unidirecional de energia. Nesta configuração as redes de transmissão de energia precisam estar munidas de sofisticados sistemas de controle e proteção para lidar com complexidades inerentes às redes com elevada tensão e transporte de grandes quantidades de energia. um correto funcionamento do sistema elétrico [29].

Com o crescimento da penetração da energia proveniente da MMGD as redes de distribuição necessitam passar pelo mesmo processo de aperfeiçoamento das redes de transmissão, com a introdução de sistemas de controle e proteção da rede. Caso não haja mudanças, a rede de distribuição, com o crescimento da geração distribuída, estará mais sujeita a: oscilações que podem levar a tensão a operar fora da margem de segurança, desequilíbrios de tensão entre fases, distorções harmônicas de corrente, desequilíbrios da frequência do sistema [11, 29, 31]. Uma outra sugestão é o desenvolvimento de redes inteligentes que permitiriam o estabelecimento de comunicação entre os operadores do sistema elétrico e a rede elétrica para um

correto gerenciamento da carga em momentos críticos, trazendo maior eficiência e confiabilidade à rede [30, 31].

Em uma análise primária pode-se afirmar que a geração distribuída tem como vantagens em relação à geração centralizada: redução das perdas elétricas associadas ao transporte de energia e postergação de investimentos voltados para a ampliação e reforço da rede de transmissão. Mas, paradoxalmente, a alta penetração de geração distribuída na rede de distribuição pode causar um aumento das perdas, visto que a estrutura atual das redes não suporta alta penetração de fontes intermitentes. Com isso os investimentos que seriam realizados na rede de transmissão, diante de um possível crescimento da geração centralizada, serão destinados para aperfeiçoamento da rede de distribuição [29].

Considerando o atual cenário e as projeções futuras da EPE [28], bem como os impactos que a alta penetração da geração descentralizada pode causar no sistema, conclui-se que a geração distribuída precisa reunir, no momento, condições para que cresça de forma sustentável por meio de mudanças regulatórias, operativas e tecnológicas no setor elétrico.

2.5.

Conclusão do capítulo

Neste capítulo foram mostrados os estudos que visam à compreensão do atual cenário e das perspectivas da matriz elétrica do Brasil, bem como os impactos causados pela mudança de paradigma no setor elétrico. Foi constatado através dos dados da ANEEL e pelas análises da EPE que a geração distribuída vem desempenhando um papel cada vez mais importante no setor elétrico brasileiro, com destaque para a mini e microgeração solar fotovoltaica distribuída que após a regulamentação da conexão à rede de distribuição passou a crescer ao longo dos anos, representando cerca de 97% de toda a capacidade instalada.

De posse das informações e dados coletados sobre a MMGD e o uso da energia solar fotovoltaica exibidos neste capítulo foram definidas, no Capítulo 3, as diretrizes para a definição da estimação da geração solar fotovoltaica distribuída que representa uma das etapas da metodologia proposta para a previsão de carga.

3

Metodologia

3.1.

Introdução

Com base nas publicações científicas citadas no Capítulo 2 deste trabalho percebe-se que há um consenso em afirmar que a geração distribuída no Brasil, com destaque para a geração solar fotovoltaica, possui grandes chances de crescer ainda mais devido ao alto potencial solar brasileiro e às políticas de incentivo e investimento, trazendo consigo desafios inerentes à operação e ao planejamento do sistema elétrico, bem como da estruturação do mercado de eletricidade.

Tendo em vista as consequências no que diz respeito à operação e planejamento do sistema elétrico de potência brasileiro, este trabalho – mais precisamente este capítulo – pretende apresentar uma nova metodologia utilizando inteligência artificial para realizar previsões de carga elétrica utilizando, como variável explicativa, a estimação da geração solar fotovoltaica distribuída conectada à rede de distribuição enquadrada no regime de mini ou microgeração distribuída definida pela ANEEL.

Além disso, serão mostrados os procedimentos usados para a concepção do modelo de previsão de carga, desde o levantamento dos dados a serem utilizados até a modelagem da rede neural. De forma a facilitar o entendimento, a metodologia foi dividida em etapas. A Figura 3.1 mostra a divisão e o nome dado para cada etapa, sendo explicadas ao longo da apresentação da metodologia.

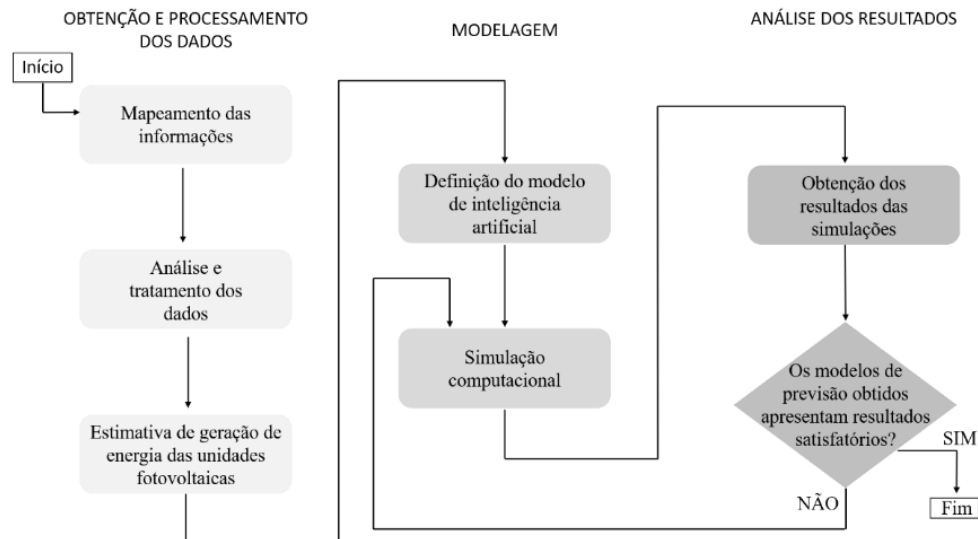


Figura 3.1 – Fluxograma da metodologia proposta
Fonte: o próprio autor

3.2. Mapeamento das informações

O levantamento das informações que fazem parte desta metodologia tem como objetivo principal apresentar um modelo de previsão que considere a influência da mini e microgeração distribuída no comportamento da curva de carga elétrica. Para realizar as previsões de carga foram consideradas, primeiramente, as seguintes informações: dados históricos de carga elétrica definidos pelo ONS, trabalhos relacionados à apresentação de equações matemáticas que determinem a energia gerada pelas unidades fotovoltaicas e literatura sobre a aplicação de modelos estatísticos e de inteligência computacional em estudos de previsão de carga.

Antes de obter os dados de carga elétrica é necessário definir o horizonte e o intervalo das previsões que se deseja obter por meio dos modelos de previsão. As definições do horizonte e discretização das previsões a serem realizadas neste trabalho foram baseadas nos módulos 3 (Planejamento da Operação) e 4 (Programação da Operação) dos Procedimentos de Rede definidos pelo ONS [35]. De forma a avaliar a qualidade e a aplicabilidade da metodologia de previsão de carga proposta por este trabalho para os agentes do setor elétrico foram levados em consideração dois tipos de previsão: de curto prazo e de médio prazo, baseados na Programação Diária da Operação Eletroenergética e no Planejamento Anual da Operação Energética realizados pelo ONS.

Na Programação Diária da Operação Eletroenergética os agentes envolvidos nos estudos de previsão de carga são responsáveis por realizar previsão para o dia seguinte (horizonte de 24 horas), em intervalos de trinta minutos. Diferentemente da previsão feita pelo ONS neste trabalho, devido à incompatibilidade de alguns dados, será realizada a previsão de carga horária de curto prazo com horizonte de 24 horas, em intervalos de uma hora. A previsão de carga de médio prazo será feita de acordo com estudos feitos pelo ONS no Planejamento Anual da Operação Eletroenergética: previsão com horizonte de cinco anos, em intervalos mensais.

A série temporal de carga elétrica do SIN foi obtida no site do ONS [34]. Para a obtenção do modelo de previsão de carga de curto prazo será usada a base de dados de carga horária do SIN, em megawatt-hora por hora (MWh/h), no período de 01/01/2019 a 07/01/2020, em intervalos de uma hora. A base de dados de carga de energia do SIN, em megawatt médio (MWmed), no período de 01/01/2001 a 31/12/2020, discretizada mensalmente, será usada na formulação do modelo de previsão de carga de médio prazo.

Para se obter a estimacão da geracão solar fotovoltaica distribuída, por meio da equacão a ser mencionada na próxima seccão, serão usadas, como variáveis, a irradiacão solar e a temperatura do ar. Ambas as variáveis foram adquiridas através do Banco de Dados do Instituto Nacional de Meteorologia (BDMEP) [36] compreendendo o período de 2008 a 2020 em intervalos de uma hora, de cada capital brasileira e do Distrito Federal, para fins de simplificacão³. Outra variável presente no cálculo da estimacão da geracão é a capacidade instalada das unidades fotovoltaicas em cada unidade federativa do Brasil. Por meio do site da ANEEL [26] foi possível obter os dados referentes à potência instalada de cada estado brasileiro e do Distrito Federal no período de 13/12/2008 (dia da conexão da primeira unidade solar fotovoltaica de MMGD no Brasil informada) a 06/01/2020, para cada dia.

³ Neste trabalho será considerado que a mini e a microgeracão distribuída estão presentes nas capitais dos estados brasileiros devido à falta de dados de irradiacão solar e temperatura do ar em muitas cidades pequenas no site do BDMEP.

3.3. Análise e tratamento dos dados

Após a obtenção dos dados que serão utilizados para a concepção do modelo de previsão é necessário que haja uma análise minuciosa dos valores de cada base de dados de forma a investigar possíveis anomalias presentes como a inexistência de dados e a presença de *outliers*⁴ para que se tenha resultados mais satisfatórios. Devido à grande quantidade de dados a investigação manual dos dados se torna uma tarefa árdua, passível de erros. Por esse motivo o uso de ferramentas computacionais se torna um aliado apresentando resposta mais confiável e em menor tempo se comparado à avaliação manual.

Para o tratamento de tais anomalias será usada como base a metodologia apresentada por Gonçalves [37]. Em caso de aparição de informações faltantes na base de dados de irradiação solar e temperatura do ar, os espaços vazios serão preenchidos pelo valor médio apresentado pela unidade federativa para aquele dia e hora. Na base de dados de carga de energia do SIN, carga horária do SIN e potência instalada de unidades fotovoltaicas foi verificado que não há dados faltantes. No caso de aparição de *outliers* a verificação será feita utilizando o teste de Grubbs. O teste de Grubbs analisará a presença tanto de valores muito altos quanto de valores muito baixos que compõem as séries temporais. Como o número de observações da amostra é muito maior do que o apresentado na tabela de Grubbs, a avaliação da presença de *outliers* será feita seguindo a proposta apresentada por Oliveira [38], exibida na eq. (3.1) que mostra que a hipótese nula (H_0) é rejeitada se:

$$G > \frac{(n-1)}{\sqrt{n}} \times \sqrt{\frac{t^2}{n-2+t^2}} \quad (3.1)$$

Sendo:

G, o valor estatístico do teste de Grubbs.

t, o valor crítico da distribuição t de Student com $(n - 2)$ graus de liberdade e nível de confiança 0,025.

n, representando o número de observações na amostra.

⁴ Valor atípico, inconsistente, que apresenta grande afastamento dentre os demais valores pertencentes à uma amostra de dados.

Assim como no tratamento dos dados faltantes, foi verificado que não há dados faltantes na base de dados de carga de energia do SIN, carga horária do SIN e potência instalada de unidades fotovoltaicas. Para os dados de irradiação solar e temperatura do ar foram verificados *outliers* que foram substituídos pela média entre os valores da hora anterior e a hora seguinte. Essa estratégia usada para a substituição dos *outliers* foi suficiente para que os dados não tivessem perda considerável de qualidade.

3.4.

Equação da estimação da geração solar fotovoltaica distribuída

Por se tratar de uma fonte de energia elétrica intermitente com muitas variáveis que influenciam na geração de energia a obtenção de formulações matemáticas que visam estimar, com boa precisão, a energia oriunda das unidades fotovoltaicas se torna um grande desafio para os estudiosos da área. Na literatura pode-se encontrar metodologias que associam a influência da irradiação solar e potência nominal das unidades fotovoltaicas com fatores como: sombra ocasionada por nuvens [39, 40], sujeira presente nas células fotovoltaicas [41, 42], perdas associadas ao cabeamento dos equipamentos elétricos [43], vida útil das placas solares [44], temperatura das células [45], dentre outros.

Para este trabalho será usada uma adaptação de uma equação genérica que pode ser encontrada em trabalhos feitos por Hasan et al. [22] e Riffoneau et al. [45]. Na eq. (3.2) pode-se perceber que para se determinar a energia obtida pelas placas solares E_S , em quilowatt-hora (kWh), foram usadas como variáveis a irradiação solar do ambiente I_S , em quilowatt-hora por metro quadrado (kWh/m²), a capacidade instalada das unidades fotovoltaicas P_{FV} , em quilowatt (kW), em cada ano, a irradiação solar padrão usada em testes de eficiência em painéis solares I_P no valor de 1 kWh/m², a eficiência dos painéis solares η_{FV} (75%), a temperatura da célula T_C , em graus Celsius (°C), e o coeficiente de temperatura dos painéis γ (considerando o uso de células de silício policristalino, valor de -0,38%/°C).

$$E_S = I_S \times \frac{P_{FV}}{I_P} \times \eta_{FV} \times [1 + \gamma(T_C - 25)] \quad (3.2)$$

Levando-se em consideração que a degradação ao longo dos anos das placas solares impacta diretamente na produção de energia, a equação final usada para estimar a geração solar fotovoltaica distribuída está apresentada na eq. (3.3) abaixo, onde n representa o número de anos/operação anterior ao ano base e D representa o fator de degradação anual dos módulos fotovoltaicos com valor de 0,5% ao ano, definido por Jordan & Kurtz [37]. O uso do fator de degradação das placas solares no cálculo de estimação da geração solar fotovoltaica distribuída pode ser visto no Balanço Energético Nacional (BEN) da EPE no ano de 2020 [23].

$$E_S = [P_{FV} \quad P_{FV-1} \quad \cdots \quad P_{FV-n}] \times \begin{bmatrix} (1-D)^0 \\ (1-D)^1 \\ \vdots \\ (1-D)^n \end{bmatrix} \times \eta_{FV} \times \frac{I_S}{I_P} \times [1 + \gamma(T_C - 25)] \quad (3.3)$$

As estimativas foram feitas para cada unidade federativa, em intervalos de uma hora, que serão usados para a realização de previsões de carga de curto prazo. Para a previsão de carga de médio prazo a estimativa de geração foi feita em intervalos mensais.

3.5.

Definição do modelo de previsão de carga

A escolha das variáveis a serem observadas e o tratamento adequado dos dados representam etapas importantes na construção metodológica do trabalho, contribuindo para uma melhor experiência na predição de carga elétrica. Em conjunto com as etapas citadas a definição do modelo de previsão deve ser avaliada seguindo critérios como: horizonte de previsão, características inerentes à carga elétrica, esforço computacional, entre outros.

Ao longo dos anos a previsão de carga tem sido objeto de estudo de pesquisadores que visam apresentar modelos ainda precisos e que atendam satisfatoriamente aos mais variados problemas associados à previsão para os agentes interessados, conforme foi mencionado no Capítulo 1 deste trabalho. Os modelos estatísticos foram os primeiros a serem utilizados como modelos de previsão de carga tendo grande relevância os trabalhos que utilizavam a metodologia Box & Jenkins como o modelo autorregressivo de médias móveis (ARMA) [46], que foi aprimorado para captar evidências de não estacionariedade e sazonalidade (SARIMA) das

séries temporais [47] e, posteriormente, foi aperfeiçoada para incluir variáveis exógenas (SARIMAX) como irradiação solar, por exemplo, que pudessem auxiliar na previsão de carga [48]. Apesar de terem sido utilizados em previsões de carga nos mais variados horizontes de previsão, os modelos estatísticos atualmente dividem espaço com os modelos não lineares de previsão que geralmente apresentam resultados melhores em previsões de curto prazo. Em aplicações de médio e longo prazos os modelos estatísticos de previsão ainda possuem grande aplicabilidade, apresentando competitividade em relação aos modelos não lineares [49].

Com o aperfeiçoamento e popularização da tecnologia computacional os modelos de inteligência artificial foram ganhando destaque entre os pesquisadores apesar do ceticismo envolvendo esses novos modelos de previsão de carga na década de 1990 [50]. Diante da limitação apresentada pelos modelos lineares, os modelos não lineares, representados primeiramente pelas redes neurais *feedforward*, demonstraram ter grande potencial de melhoria no futuro para previsões de carga como mostram os resultados obtidos nos trabalhos de Banda & Folly [51] e Park et al. [52]. Devido ao avanço nos estudos relacionados à aplicação de aprendizado de máquinas em previsão de carga outros modelos mais sofisticados foram ganhando destaque como: rede neural artificial associada à máquina de vetores de suporte (*support vector machine*, em inglês) [53-55], rede neural convolucional [56, 57], rede neural *fuzzy* [58, 59], rede neural recorrente [60] e modelos híbridos que combinam características particulares de cada um dos modelos [61-64].

Apesar de obter sucesso em algumas aplicações de previsão, as redes neurais artificiais *feedforward* não são capazes de capturar a importância da ordem temporal dos dados, se tornando, em algumas aplicações, ineficientes ao descrever o comportamento da carga elétrica. Diante de tantos modelos computacionais apresentados no meio científico as redes neurais recorrentes e suas variadas arquiteturas vêm ganhando destaque no contexto de previsão de carga devido à sua capacidade de memorização, tornando-as capazes de extrair informações contidas na série de dados, trazendo maior eficiência em comparação com as redes *feedforward*, conforme relatado por Bianchi [65]. As redes recorrentes possuem noção de ordem no tempo e são alimentadas pelos dados de entrada atual e pela saída do tempo anterior, ou seja, a decisão da rede obtida no passado afetará a decisão a ser tomada no futuro.

Como foi mencionado anteriormente, o grande atrativo das redes neurais artificiais recorrentes é o fato de poderem utilizar informações passadas para realizar

com mais precisão uma tarefa no presente. Mas as primeiras arquiteturas de redes neurais recorrentes como a rede neural de Elman, usada nos trabalhos de previsão de carga [66, 67], apresentam baixa eficiência à medida que a distância entre as informações importantes e o local onde elas podem ser usadas cresce [65]. De forma a melhorar a performance apresentada pela rede neural recorrente surgiram as arquiteturas LSTM (*long short-term memory*) e GRU (*gated recurrent unit*) que já tiveram trabalhos voltados à previsão de carga [68, 69].

Bianchi [58] realizou uma análise acerca do uso das diferentes arquiteturas de redes neurais recorrentes e do desempenho destas na previsão de 3 séries temporais de carga. Os resultados mostram uma pequena diferença de performance entre os modelos estudados, sendo que as redes LSTM e GRU apresentam elevado tempo de resposta e esforço computacional como destaques negativos em relação a outros modelos.

Na escolha do modelo de previsão deste trabalho foi feita uma análise dos trabalhos mencionados nesta seção. O modelo escolhido para este trabalho foi a rede neural LSTM devido ao seu bom desempenho, à crescente aceitação deste modelo por parte dos pesquisadores nos últimos anos para a realização de previsões de carga e à semelhança observada entre os objetivos deste trabalho e os objetivos dos trabalhos citados nesta seção.

3.5.1. Arquitetura LSTM

As redes LSTM foram concebidas por Hochreiter e Schmidhuber e aprimoradas ao longo dos anos por outros pesquisadores. Esta arquitetura de rede surgiu em decorrência das limitações apresentadas pela arquitetura padrão de rede neural recorrente (modelo Elman), visando corrigir problemas de dependências de longo prazo da série temporal e explosão e dissipação do gradiente da rede neural [70].

Na Figura 3.2 [71] pode-se verificar a estrutura interna de uma rede LSTM em diagrama de blocos com repetição. A alimentação do módulo no tempo t é dada pelo valor da série no tempo t (x_t), pelo valor previsto no tempo $t-1$ (h_{t-1}) e o estado da célula, que representa a memória de longo prazo, no tempo $t-1$ (C_{t-1}), apresentando como saída, após interagir com as quatro camadas de rede neural, o valor previsto no tempo t (h_t).

O estado da célula (C_t) representa uma célula da rede que possui a capacidade de armazenar e transportar informações que determinarão os valores de previsão. Os dados contidos no estado da célula (C_t), são controlados por camadas de rede neural que também são chamadas de portas (*gates*), possuindo, cada uma, uma função específica. As portas são representadas na Figura 3.2 pela letra sigma (σ), indicando a aplicação da função sigmoide em associação com os pesos (W_x) e *biases* (b_x) dos respectivos portões que trará como resposta um valor entre 0 e 1, onde 0 indica bloqueio completo na passagem de informações e 1 indica a passagem completa de informações.

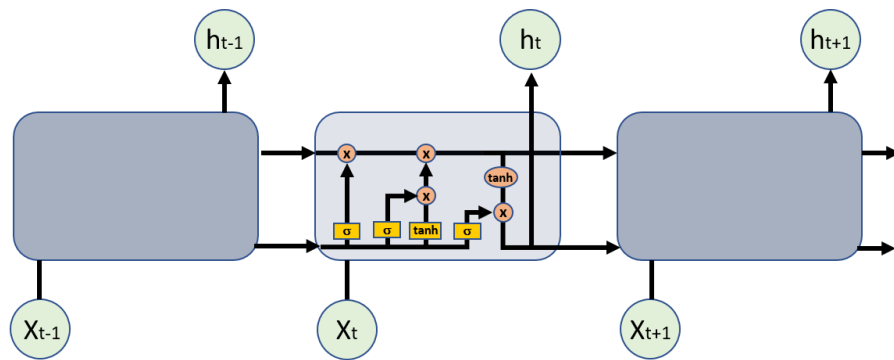


Figura 3.2 - Estrutura interna da arquitetura LSTM
Fonte: [71]

O funcionamento passo a passo da estrutura interna da rede LSTM desde a entrada das informações até a saída dos resultados é mostrado na Figura 3.3 [71], sendo respeitada a ordem crescente representada pela numeração na figura. Primeiramente é necessário definir quais informações serão descartadas do estado da célula baseada no valor da previsão no tempo $t - 1$ e no valor de entrada x_t . O *forget gate* (f_t) definirá o descarte por meio da eq. (3.4):

$$f_t = \sigma(W_f x [h_{t-1}, x_t] + b_f) \quad (3.4)$$

Definida as informações que serão descartadas, o próximo passo é definir as novas informações que serão passadas para o estado da célula. Neste passo o *input gate* (i_t), definido pela eq. (3.5), será usado para determinar os valores que serão atualizados para o estado da célula e a camada tangente hiperbólica (*tanh*) será responsável pela criação de novos valores candidatos ao estado da célula (\tilde{C}_t), como

mostra a eq. (3.6). A combinação dos valores obtidos pelo *input gate* e pela camada tangente hiperbólica resultará em um novo estado da célula.

$$i_t = \sigma(W_i \times [h_{t-1}, x_t] + b_i) \quad (3.5)$$

$$\tilde{C}_t = \tanh(W_C \times [h_{t-1}, x_t] + b_C) \quad (3.6)$$

Nesta etapa será realizada a atualização do antigo estado da célula (C_{t-1}), para o novo estado (C_t) por meio da eq. (3.7). O produto de C_{t-1} , com a função *forget gate* da eq. (3.4), bem como o produto da função *input gate*, na eq. (3.5), com o novo candidato a estado da célula da eq. (3.6) representam as novas informações que serão armazenadas no estado da célula e usadas para a definição do valor de previsão.

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \quad (3.7)$$

Por último tem-se a determinação da saída h_t em duas etapas: na primeira etapa os valores de entrada (x_t) e previsão no tempo anterior (h_{t-1}) entram na porta chamada *output gate* (o_t) para definir as informações a serem transmitidas adiante, como mostra a eq. (3.8). Na segunda etapa o estado da célula (C_t) será introduzido na camada tangente hiperbólica para obter valores entre -1 e 1 que serão multiplicados pela resposta verificada em *output gate*, como mostra a eq. (3.9):

$$o_t = \sigma(W_o \times [h_{t-1}, x_t] + b_o) \quad (3.8)$$

$$h_t = o_t \times \tanh(C_t) \quad (3.9)$$

Com isso o valor h_t é apresentado ao usuário como uma resposta de previsão emitida pela rede neural. Se a rede neural estiver programada para realizar outras previsões os valores h_t e C_t , no próximo processo iterativo, passarão a ser chamados de h_{t-1} e C_{t-1} na camada de entrada da rede, respectivamente, dando continuidade ao processo de previsão explicado, anteriormente, passo a passo, com os novos valores sendo definidos pelas equações acima (de eq. (3.4) a eq. (3.9)).

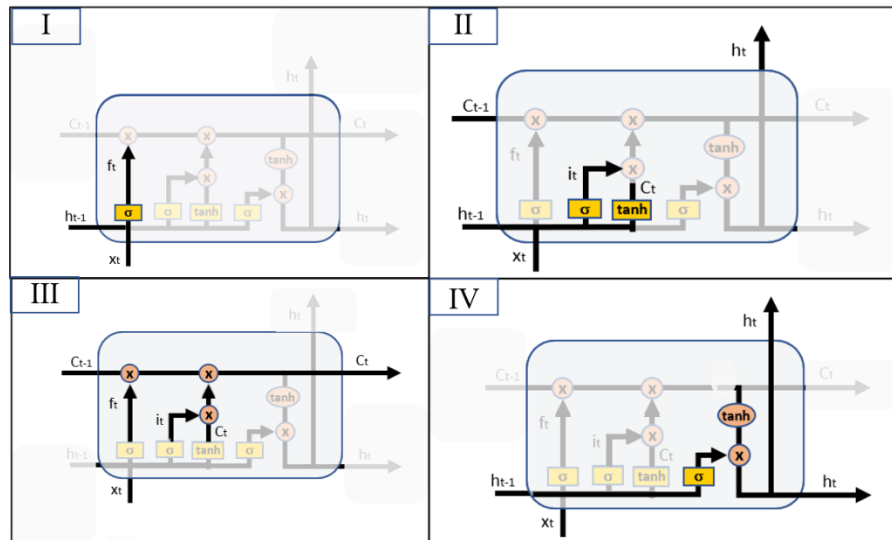


Figura 3.3 - Etapas de funcionamento da rede LSTM
Fonte: [71]

Por meio das equações apresentadas acima e do entendimento das etapas a serem seguidas será possível modelar esta rede neural em uma linguagem de programação. Na próxima seção será mostrado detalhes sobre os dados de entrada na rede neural LSTM, a fase de treinamento da rede, o horizonte de previsão, etc.

3.6. Simulação Computacional

Nesta etapa será estabelecida de que forma a rede LSTM será treinada para a realização das previsões das séries temporais, bem como a definição dos horizontes de previsão e suas respectivas discretizações. A modelagem da rede LSTM foi feita utilizando a linguagem de programação Python e o seu extenso conjunto de bibliotecas, com destaque para o Keras que facilita a experiência do usuário na definição de parâmetros importantes da rede neural.

Neste trabalho, na etapa de previsão de carga de curto prazo, serão realizadas sete previsões para o SIN e para cada um dos subsistemas para verificar a qualidade do modelo, totalizando 35 previsões. Já na etapa de previsão de carga de médio prazo serão realizadas cinco previsões: para o SIN e para cada um dos subsistemas elétricos do Brasil. As Tabelas 3.1 e 3.2 mostram os dados e períodos analisados para a realização das etapas de treinamento e validação do modelo.

Para realizar as previsões de carga para o dia seguinte é necessário ter a estimativa da geração solar fotovoltaica distribuída para cada hora do dia que será integrada à base de dados de treinamento na entrada dos dados na rede neural. A estimativa será feita tendo posse dos valores previstos de temperatura do ar e irradiação solar para o dia que se deseja obter a previsão de carga.

Tabela 3.1 - Informações sobre a base de dados das previsões de carga de curto prazo
Fonte: o próprio autor

Previsão de Carga de Curto Prazo		
Base de dados de treinamento		Base de dados de validação
Carga horária do SIN/subsistemas	Energia estimada gerada pelas UFV	Carga horária do SIN/subsistemas
01/01/2019 a 31/12/2019	02/01/2019 a 01/01/2020	01/01/2020
02/01/2019 a 01/01/2020	03/01/2019 a 02/01/2020	02/01/2020
03/01/2019 a 02/01/2020	04/01/2019 a 03/01/2020	03/01/2020
04/01/2019 a 03/01/2020	05/01/2019 a 04/01/2020	04/01/2020
05/01/2019 a 04/01/2020	06/01/2019 a 05/01/2020	05/01/2020
06/01/2019 a 05/01/2020	07/01/2019 a 06/01/2020	06/01/2020
07/01/2019 a 06/01/2020	08/01/2019 a 07/01/2020	07/01/2020

3.6.1. Cálculo da estimacão da geração solar fotovoltaica distribuída

Os valores previstos de temperatura do ar de cada Unidade Federativa do Brasil foram obtidos por meio do INMET, como foi mencionado na seção 3.2. Para obter os valores previstos de irradiação solar para os dias que serão realizadas as previsões de carga foram feitas previsões por meio do modelo computacional utilizado neste trabalho para a previsão de carga.

A série histórica da irradiação solar e a variável exógena temperatura do ar de cada localidade serão usadas para determinar a irradiação solar nas próximas 24 horas. A Tabela 3.3 mostra os dados de entrada e saída desejada da rede neural.

A rede neural usada para a previsão da irradiação solar foi treinada de forma a fazer ajustes dos pesos associados às conexões internas entre os neurônios e definir os hiperparâmetros para que se tenha uma minimização dos erros de previsão. Na próxima seção é informado com mais detalhes como é realizado o treinamento de uma rede neural.

Para explicar como foi feita a entrada dos dados na rede para a realização das previsões de irradiação solar será usado um exemplo que serve para as demais previsões: para realizar a previsão de irradiação do dia 03/01/2020 foram usados como dados de entrada na rede neural a base de dados da irradiação solar no período entre 03/01/2019 e 02/01/2020 e a variável exógena temperatura do ar com a série histórica de 04/01/2019 a 02/01/2020 juntamente como os valores previstos pelo INMET da temperatura no dia 03/01/2020, ambas as variáveis em intervalos horários.

De posse dos valores da temperatura do ar e da irradiação solar para o dia seguinte será possível determinar a estimativa da geração solar fotovoltaica distribuída por meio da eq. (3.3) que será usada na etapa de previsão de carga. Nas Figuras 3.4 e 3.5 tem-se as séries temporais da variável exógena estimativa da geração solar fotovoltaica distribuída que serão imputadas nos modelos computacionais que serão usadas para a realização de previsões de curto e médio prazos.

Tabela 3.2 - Informações sobre a base de dados das previsões de carga de médio prazo
Fonte: o próprio autor

Previsão	Previsão de Carga de Médio Prazo		
	Base de dados de treinamento	Base de dados de validação	
	Carga de Energia do SIN	Energia Estimada Gerada Pelas UFV	Carga de Energia do SIN
SIN	jan/2001 a dez/2015	jan/2001 a dez/2015	jan/2016 a dez/2020
SE/CO	jan/2001 a dez/2015	jan/2001 a dez/2015	jan/2016 a dez/2020
Sul	jan/2001 a dez/2015	jan/2001 a dez/2015	jan/2016 a dez/2020
Nordeste	jan/2001 a dez/2015	jan/2001 a dez/2015	jan/2016 a dez/2020
Norte	jan/2001 a dez/2015	jan/2001 a dez/2015	jan/2016 a dez/2020

Tabela 3.3 - - Informações sobre a base de dados das previsões de irradiação solar
Fonte: o próprio autor

Previsão da irradiação solar		
Entrada dos dados na rede neural		Resposta da rede neural
Irradiação solar de cada UF	Temperatura do ar de cada UF	Irradiação solar de cada UF
01/01/2019 a 31/12/2019	02/01/2019 a 01/01/2020	01/01/2020
02/01/2019 a 01/01/2020	03/01/2019 a 02/01/2020	02/01/2020
03/01/2019 a 02/01/2020	04/01/2019 a 03/01/2020	03/01/2020
04/01/2019 a 03/01/2020	05/01/2019 a 04/01/2020	04/01/2020
05/01/2019 a 04/01/2020	06/01/2019 a 05/01/2020	05/01/2020
06/01/2019 a 05/01/2020	07/01/2019 a 06/01/2020	06/01/2020
07/01/2019 a 06/01/2020	08/01/2019 a 07/01/2020	07/01/2020

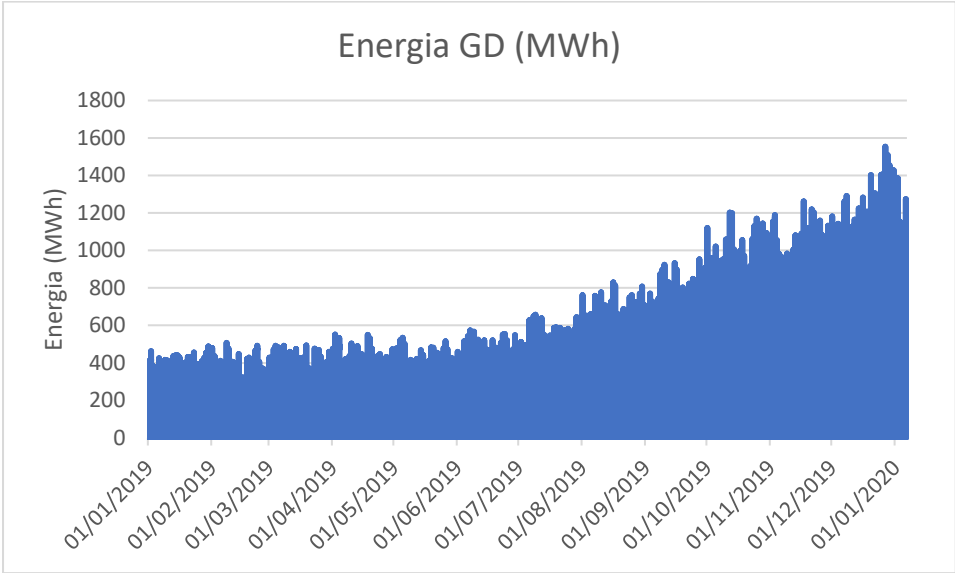


Figura 3.4 - Série temporal da variável exógena para previsões de curto prazo
Fonte: o próprio autor

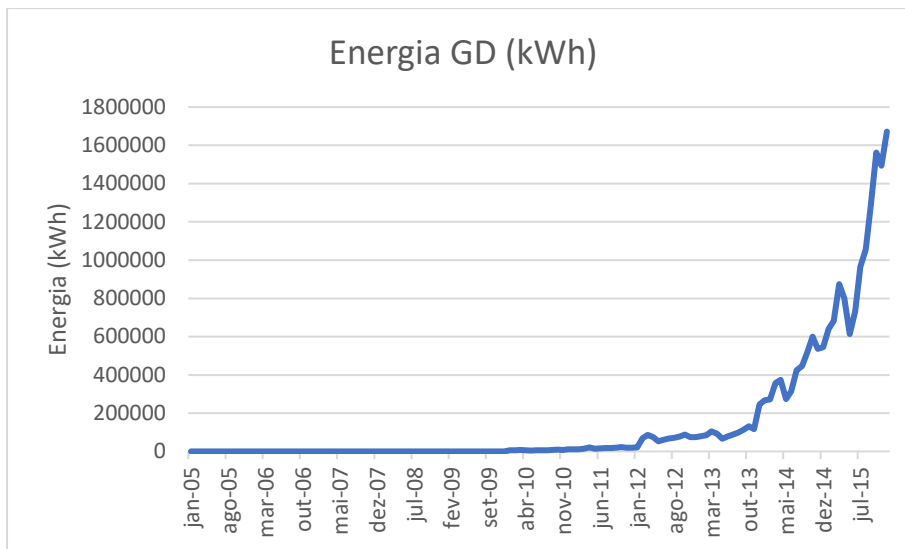


Figura 3.5 - Série temporal da variável exógena para previsões de médio prazo
Fonte: o próprio autor

3.6.2. Treinamento da rede neural para previsão de carga

O treinamento da rede LSTM será feito por meio da técnica de aprendizagem supervisionada. A técnica de aprendizagem supervisionada tem como objetivo treinar a rede para que seja capaz de prever resultados com precisão. De forma simplificada pode-se dizer que a aprendizagem supervisionada é realizada a partir da inserção na rede de um conjunto de exemplos de treinamento, sendo que cada exemplo corresponde a um objeto de entrada e seu respectivo valor de saída desejado. À medida que a rede neural apresenta como saída uma resposta em função do objeto de entrada na rede este valor previsto é comparado com o valor desejado. Se o erro associado a esses valores for considerado acima da tolerância a rede neural realiza ajustes nos pesos das conexões existentes entre os neurônios e um novo processo iterativo é realizado. Com o passar do tempo o erro associado à previsão na fase de treinamento é minimizado, tornando a rede capacitada para realizar previsões com resultados satisfatórios na fase de testes [72].

Em conjunto com a aprendizagem supervisionada ocorre a definição dos hiperparâmetros da rede neural, que representa uma etapa de grande relevância na concepção de uma rede neural. A escolha adequada dos hiperparâmetros é verificada na fase de validação, observando-se os resultados produzidos pela rede,

constatando também a qualidade da generalização do modelo obtida na fase de treinamento.

Para o trabalho, a escolha dos hiperparâmetros foi feita após sucessivas análises verificando a qualidade da resposta obtida na fase de teste, tanto para a previsão de carga de curto prazo quanto para a previsão de médio prazo, evitando sempre modelos com más generalizações (*overfitting* e *underfitting*). Os hiperparâmetros definidos pelo usuário estão presentes na Tabela 3.4, tanto para o caso de previsão de carga de curto prazo quanto para o caso de previsão de carga de médio prazo. Os hiperparâmetros que não estão presentes na tabela foram definidos como padrão pela biblioteca Keras.

Tabela 3.4 - Definição dos dados referentes aos hiperparâmetros da rede neural LSTM
Fonte: o próprio autor

Hiperparâmetros	Previsão de carga de curto prazo	Previsão de carga de médio prazo
Quantidade de neurônios na camada de entrada	50	20
Quantidade de neurônios na camada oculta	80	10
Quantidade de neurônios na camada de saída	1	1
Número de camadas ocultas	3	3
Tamanho do mini-lote	20	2
Épocas	200	500
Dropout	0.3	0.3
Otimizador	RMSprop	RMSprop

De forma a facilitar o entendimento de como se dá o processo de entrada das variáveis na rede neural para a previsão de carga de curto prazo foi feito um passo a passo descrito abaixo. Levando em consideração a previsão de carga horária para o dia 01/01/2020, foram seguidas estas etapas:

- 1) A base de dados de treinamento e validação estão descritas na Tabela 3.1. Os dados de entrada na rede neural são a série temporal de carga

horária, do período entre 01/01/2019 e 31/12/2019, e a série da variável exógena estimativa da geração solar distribuída, do período de 02/01/2019 a 01/01/2020, sendo que a estimativa da GD no dia 01/01/2020 foi obtida por meio da previsão da irradiação solar como foi mostrada na seção 3.6.1;

- 2) Na camada de entrada da rede neural são recebidos 24 valores consecutivos da série de carga e da variável exógena para obter na camada de saída um valor previsto. A rede começa recebendo a série de carga horária do período entre 0h e 23h do dia 01/01/2019 e a estimativa da geração solar distribuída do período entre 0h e 23h do dia 02/01/2019 que serão responsáveis por prever a carga horária de 0h do dia 02/01/2019;
- 3) O valor previsto é então comparado com o valor da série temporal e a diferença entre os dois será responsável (ou não) pela alteração dos pesos associados às conexões entre os neurônios, dependendo da tolerância de erro adotada pelo usuário;
- 4) Um novo processo de previsão é inicializado, com a atualização dos 24 valores das séries de carga horária e de estimativa da geração de energia distribuída. O primeiro valor tanto da série temporal de carga horária e de estimativa da geração de energia distribuída são descartados para dar lugar ao último valor previsto anteriormente. Este processo iterativo se repete até a obtenção do último valor de previsão de carga horária do dia 01/01/2020;

Para a realização da previsão de carga de médio prazo do SIN e de seus subsistemas para o período de janeiro de 2016 a dezembro de 2020 foram seguidos os seguintes passos:

- 1) A base de dados de treinamento e validação estão descritas na Tabela 3.2 com os dados que serão imputados na rede neural. Os dados de entrada na rede neural são a série temporal de carga de energia, do período de 01/2001 a 12/2015, e a série da variável exógena estimativa da geração solar distribuída, do período de 01/2001 a 12/2015, ambas discretizadas mensalmente;
- 2) Na camada de entrada a rede neural são recebidos 12 valores consecutivos da série de carga e da variável exógena para obter na camada

de saída um valor previsto. A rede começa recebendo a série de carga de energia e a variável exógena no período entre janeiro e dezembro de 2001 que serão responsáveis por prever a carga de energia do mês de janeiro de 2002;

- 3) O valor previsto é então comparado com o valor da série temporal e a diferença entre os dois será responsável (ou não) pela alteração dos pesos associados às conexões entre os neurônios, dependendo da tolerância de erro adotada pelo usuário;
- 4) Um novo processo de previsão é inicializado, com a atualização dos 24 valores das séries de carga horária e de estimativa da geração de energia distribuída. O primeiro valor tanto da série temporal de carga horária e de estimativa da geração de energia distribuída são descartados para dar lugar ao último valor previsto anteriormente. Este processo se repete até a obtenção do último valor de previsão de carga de energia do mês de dezembro de 2020;

3.7.

Métricas de performance das redes neurais

Para avaliar a eficiência das arquiteturas nas previsões foram utilizados índices de erro bastante usados na literatura. Neste trabalho serão usados a Raiz do Erro Quadrático Médio (RMSE, sigla em inglês) e sua versão normalizada, o NRMSE, e o Erro Percentual Absoluto Médio (MAPE, sigla em inglês). O uso de diferentes métricas se deve ao fato de que cada uma apresenta suas vantagens e desvantagens ao se estabelecer uma avaliação qualitativa dos resultados obtidos, sendo que, em conjunto, poder-se-á avaliar com mais segurança.

Levando-se em consideração que \hat{y}_t e y_t representam, respectivamente, o valor de previsão e o valor real no tempo t , N sendo o número de previsões realizadas e y_{\max} e y_{\min} como sendo, respectivamente, os valores máximo e mínimo dos dados de testes; temos que eq. (3.10), eq. (3.11) e eq. (3.12) representam o RMSE, nRMSE e MAPE, respectivamente:

$$\text{RMSE} = \sqrt{\frac{\sum_{t=1}^N (\hat{y}_t - y_t)^2}{N}} \quad (3.10)$$

$$nRMSE = \frac{RMSE}{y_{m\acute{a}x} - y_{m\acute{i}n}} \quad (3.11)$$

$$MAPE = \left(\frac{1}{N} \sum_{t=1}^N \frac{|y_t - \hat{y}_t|}{|y_t|} \right) * 100 \quad (3.12)$$

3.8.

Conclusão do capítulo

Neste capítulo foi apresentado o passo a passo da metodologia usada para realizar previsões de carga desde o mapeamento das informações até a obtenção das respostas das simulações realizadas.

A revisão bibliográfica representou uma etapa importante para a escolha do modelo de previsão de carga e para a definição da fórmula matemática responsável pela estimação da geração solar fotovoltaica distribuída. Através da revisão dos trabalhos encontrados na literatura foi possível definir a arquitetura da rede neural artificial que vem apresentando ótimos resultados na área de previsão de carga e também foi possível selecionar algumas variáveis dentre as diversas relatadas na literatura que mais impactam diretamente na geração de energia solar com o objetivo de apresentar resultados satisfatórios na estimação da geração fotovoltaica.

Após a definição de todo o processo metodológico o trabalho mostrará as previsões obtidas pelo modelo de previsão que servirão como instrumento avaliador da qualidade da metodologia apresentada neste capítulo.

4 Resultados

Neste capítulo são apresentados os resultados obtidos nas previsões realizadas após a modelagem das redes neurais, bem como a avaliação da qualidade dos modelos propostos no Capítulo 3. Os gráficos e os resultados dos erros foram determinados por meio do software Microsoft Excel 2019 por conta da sua interface intuitiva e eficiente.

4.1. Previsão de carga de curto prazo

Para avaliar a qualidade da metodologia proposta por este trabalho foram realizadas 35 previsões de carga elétrica, considerando um horizonte de 24 horas de operação do SIN, em intervalos horários, como foi mostrado na Tabela 3.1. A performance do modelo de previsão de curto prazo foi avaliada levando-se em consideração a métrica dos erros associada ao dia inteiro de previsão (24 horas) e também, exclusivamente, para o período do dia de maior irradiação solar no Brasil, de forma a avaliar a importância e qualidade dos dados referentes à estimativa da geração solar fotovoltaica das MMGD. Neste trabalho foi considerado o período entre 10 horas e 15 horas como o período de maior irradiação solar.

4.1.1. Sistema Interligado Nacional

A primeira previsão de carga de curto prazo do SIN foi realizada para o dia 01/01/2020, feriado nacional de uma quarta-feira. Na Figura 4.1 pode-se perceber que há uma proximidade significativa entre os valores previstos (curva de cor azul) e os valores reais (curva de cor laranja), sendo que o erro associado à previsão de

carga se encontra ainda menor no período do dia de maior geração de energia solar fotovoltaica.

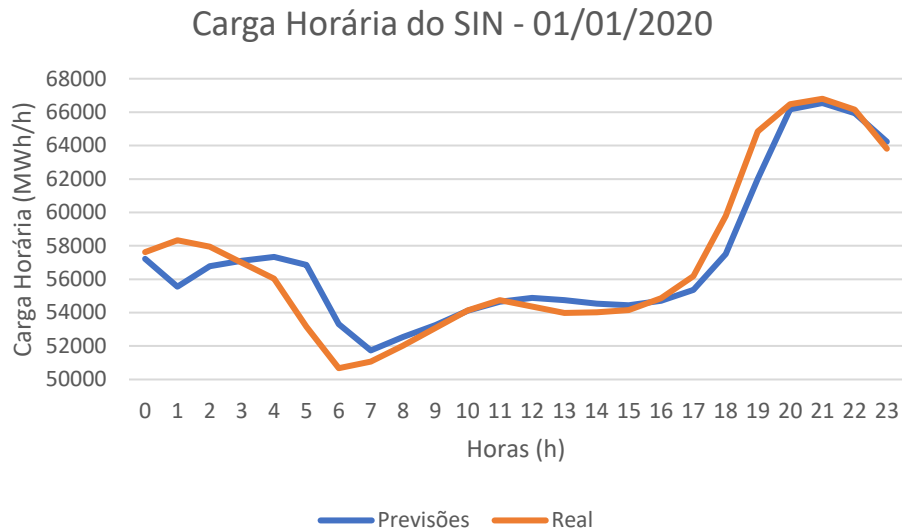


Figura 4.1 - Curvas de carga horária do SIN do dia 01/01/2020.

Fonte: o próprio autor

Para o dia 02/01/2020, quinta-feira e dia útil, os valores previstos de carga horária foram muito próximos aos valores reais, como mostra a Figura 4.2, apresentando um desempenho superior aos valores obtidos para o dia anterior. Por outro lado, a previsão durante o período entre as 10 horas e as 15 horas teve uma precisão abaixo do restante do dia e também em relação às previsões nesse mesmo período de outros dias.

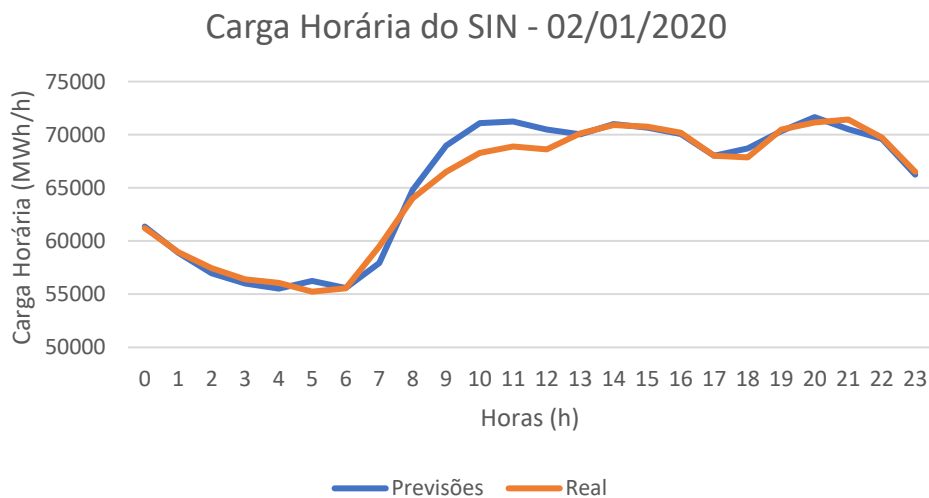


Figura 4.2 - Curvas de carga horária do SIN do dia 02/01/2020

Fonte: o próprio autor

A previsão para o dia 03/01/2020 teve desempenho inferior dentre as previsões de carga do SIN, como mostra a Figura 4.3, considerando a avaliação do erro para o dia todo, embora apresente um desempenho considerado satisfatório tendo em vista as métricas de erro. Assim como no dia 01/01/2020 o erro referente à previsão no período do dia de maior irradiação solar no Brasil se apresentou inferior comparado ao erro mensurado para todo o dia

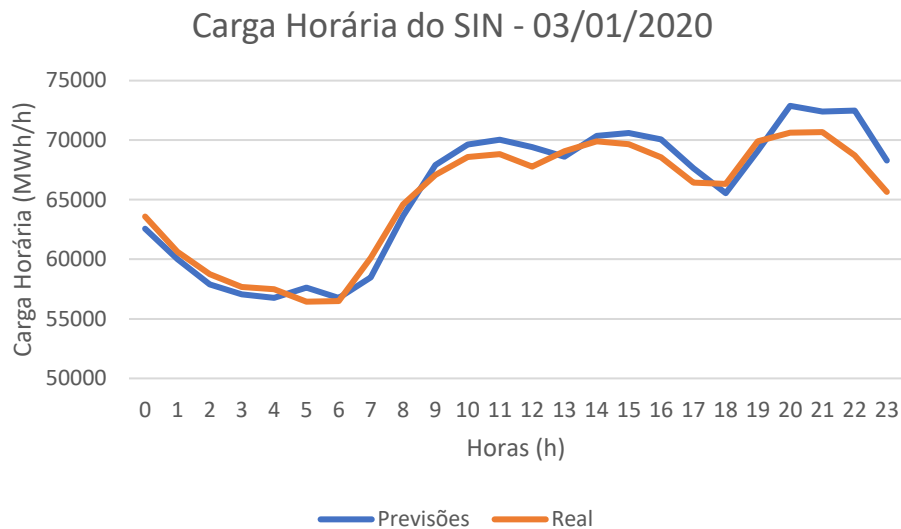


Figura 4.3 - Curvas de carga horária do SIN do dia 03/01/2020.
Fonte: o próprio autor

As previsões para os dias 04 e 05/01/2020, mostradas nas Figuras 4.4 e 4.5, dias do fim de semana, apresentaram resultados satisfatórios, mostrando que este modelo de previsão também pode ser usado em previsões para os fins de semana. As previsões realizadas no período entre 10 horas e 15 horas apresentaram performance melhor comparado com os erros observados para o dia todo.

As Figuras 4.6 e 4.7 mostram as previsões para os dias 06 e 07/01/2020, respectivamente. Os resultados obtidos em ambas as previsões foram satisfatórios, mostrando uma pequena diferença entre os valores previstos e reais ao longo do dia, com destaque para o período entre 10 horas e 15 horas onde se teve uma performance ainda melhor nos dois dias de previsão.

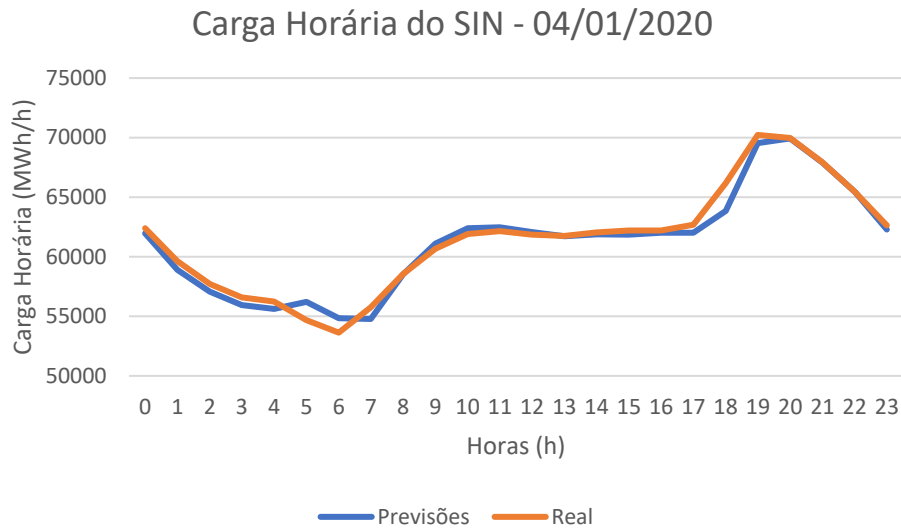


Figura 4.4 - Curvas de carga horária do SIN do dia 04/01/2020.
Fonte: o próprio autor

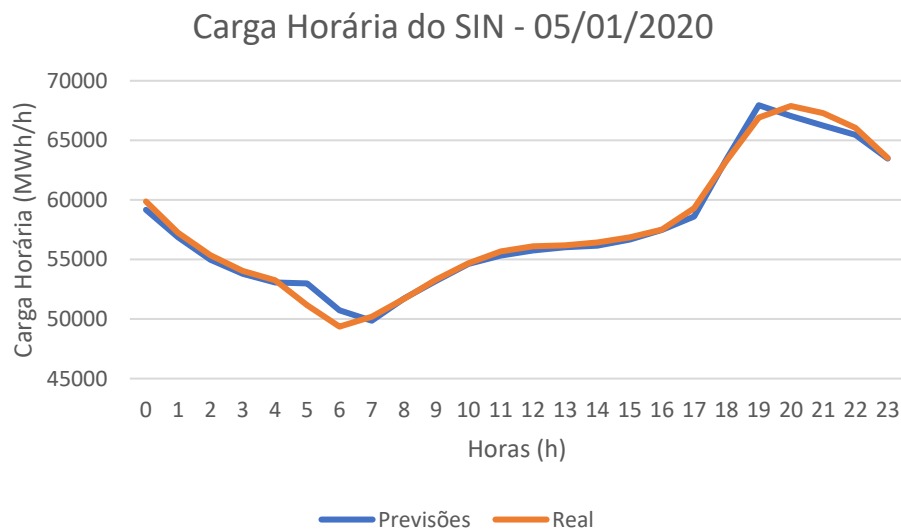


Figura 4.5 - Curvas de carga horária do SIN do dia 05/01/2020.
Fonte: o próprio autor

A Tabela 4.1 mostra a performance do modelo de previsão de carga de curto prazo por meio da apresentação de três diferentes fórmulas que mensuram o erro associado aos valores de previsão em relação aos valores reais da série temporal. Pode-se confirmar pela Tabela 4.1 o que foi observado durante a análise dos gráficos apresentados (Figuras 4.1 a 4.7): a metodologia proposta neste trabalho para a previsão de carga de curto prazo para o SIN representa uma alternativa confiável para a realização de previsões no atual contexto de crescente inserção de mini e microgeração distribuída solar fotovoltaica. A metodologia se torna ainda mais útil

quando usada para a previsão de carga de curto prazo no período entre 10 horas e 15 horas.

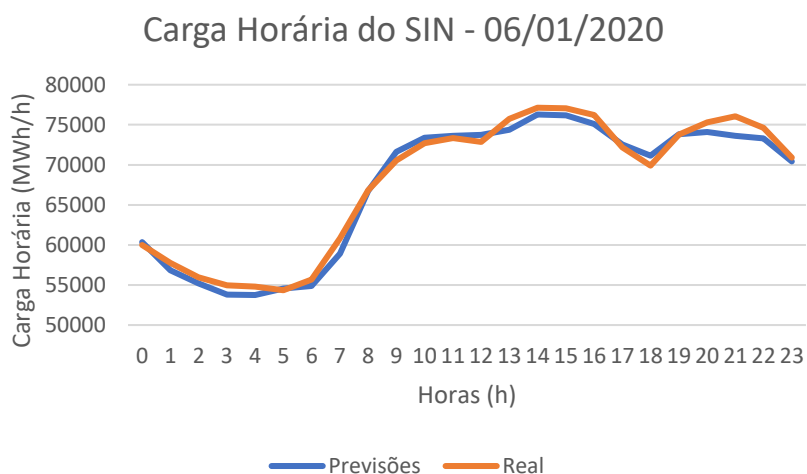


Figura 4.6 - Curvas de carga horária do SIN do dia 06/01/2020.
Fonte: o próprio autor

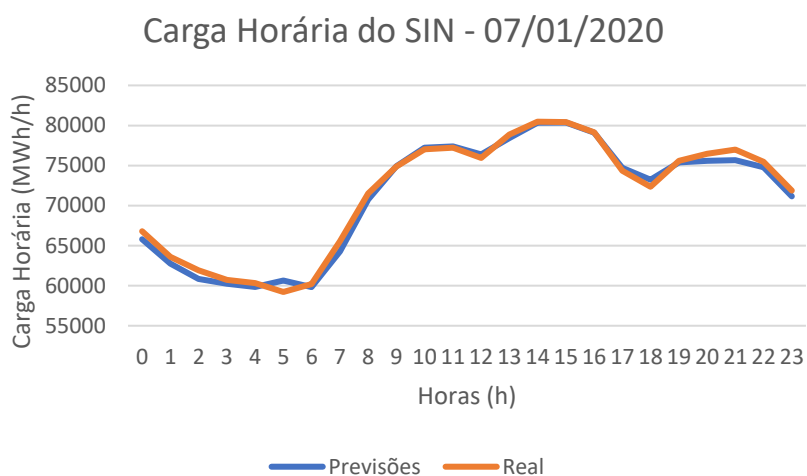


Figura 4.7 - Curvas de carga horária do SIN do dia 07/01/2020.
Fonte: o próprio autor

4.1.2. Subsistema Sudeste/Centro-Oeste

Analisando as previsões obtidas pelo modelo de previsão de curto prazo para o Subsistema Sudeste/Centro-Oeste (SE/CO) por meio da Figura 4.8 e pela Tabela 4.2 percebe-se, no geral, que os valores previstos estão bem próximos aos dados

reais, validando a metodologia apresentada neste trabalho para este caso de previsão. Comparando os erros associados às previsões de carga de cada subsistema pode-se dizer que o modelo de previsão de curto prazo do Subsistema SE/CO apresentou o terceiro melhor desempenho considerando a observação dos dados durante as 24 horas, mas considerando apenas o intervalo entre 10 horas e 15 horas, período de maior produção de energia solar fotovoltaica, a performance do modelo de previsão do Subsistema SE/CO é o melhor dentre os demais subsistemas.

Tabela 4.1 - Resultado das métricas de erros associados ao modelo de previsão de carga de curto prazo do SIN.

Fonte: o próprio autor

Performance do modelo de previsão de carga de curto prazo - SIN						
Data da previsão	24 horas			De 10h a 15h		
	MAPE (%)	RMSE (MWh/h)	nRMSE (%)	MAPE (%)	RMSE (MWh/h)	nRMSE (%)
01/01/2020	1,692	1411,505	8,753	0,665	444,731	2,758
02/01/2020	1,125	1109,958	6,854	1,757	1671,303	10,320
03/01/2020	1,838	1431,502	10,056	1,378	1033,731	7,261
04/01/2020	0,914	764,737	4,607	0,415	294,020	1,771
05/01/2020	0,819	653,796	3,530	0,411	255,513	1,380
06/01/2020	1,330	1053,060	4,622	1,094	880,157	3,863
07/01/2020	0,871	726,513	3,418	0,317	291,524	1,371

No primeiro dia do ano de 2020, feriado nacional, os resultados obtidos para o intervalo entre 0 hora e 6 horas não foram tão eficientes quanto o esperado, como mostra a Figura 4.8. Para as horas seguintes, o modelo de previsão apresentou resultados muito bons, com destaque para o período entre 7 horas e 19 horas. Mesmo diante de um baixo desempenho obtido no início do dia, no geral o modelo se comportou de maneira satisfatória já que em dias com feriado a curva de carga horária costuma apresentar um comportamento imprevisível. No dia 02/01/2020 (quinta-feira e dia útil) os valores previstos de carga foram mais precisos do que os valores obtidos na previsão do dia anterior, como pode-se perceber na Tabela 4.2 o desempenho do modelo de previsão em cada um dos dias. Nas primeiras 6 horas do dia verifica-se um erro menor entre os valores previstos e reais, diferentemente do que foi encontrado no primeiro dia. No período do dia de maior irradiação solar, entre 10 horas e 15 horas, o modelo de previsão apresentou pior desempenho em comparação com os outros 6 dias de previsão, no mesmo período.

Tabela 4.2 - Resultado das métricas de erros associados ao modelo de previsão de carga de curto prazo do Subsistema SE/CO.
Fonte: o próprio autor

Modelo de previsão de carga de curto prazo - Subsistema SE/CO						
Data da previsão	24 horas			De 10h a 15h		
	MAPE (%)	RMSE (MWh/h)	nRMSE (%)	MAPE (%)	RMSE (MWh/h)	nRMSE (%)
01/01/2020	1,507	707,117	6,713	1,069	398,709	3,785
02/01/2020	1,064	495,632	4,880	1,341	641,454	6,316
03/01/2020	1,127	504,437	5,428	0,806	423,651	4,558
04/01/2020	0,888	413,341	3,804	0,406	189,702	1,746
05/01/2020	0,797	413,341	3,372	0,394	189,702	1,611
06/01/2020	1,186	565,964	3,869	0,680	318,157	2,175
07/01/2020	0,999	498,767	3,536	0,729	410,534	2,911

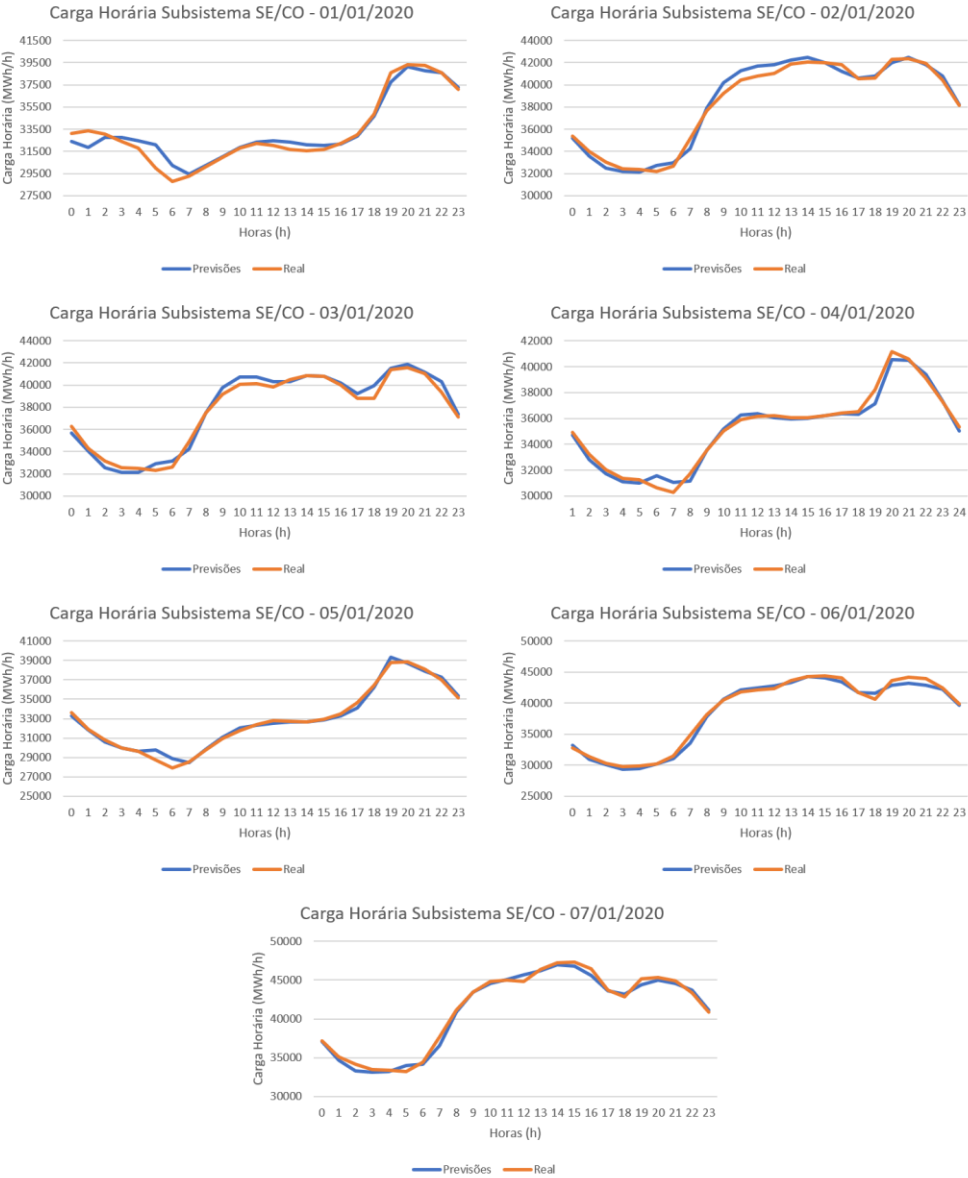


Figura 4.8 - Carga horária prevista do Subsistema SE/CO no período de 01/01/2020 a 07/01/2020
Fonte: o próprio autor

4.1.3. Subsistema Sul

Dentre todos os subsistemas analisados o Subsistema Sul apresentou o pior desempenho na previsão de carga de curto prazo, como mostram a Figura 4.9 e a Tabela 4.3. Mas pode-se considerar que a metodologia proposta neste trabalho é útil para a realização da previsão de carga horária para este subsistema, para qualquer dia da semana sendo feriado ou não, tendo em vista que as métricas usadas para avaliar a performance do modelo de previsão apresentam valores próximos aos erros observados na previsão de carga de outros subsistemas, além de possuir uma performance dentro do padrão observado na literatura a respeito da previsão de carga de curto prazo.

Tabela 4.3 - Resultado das métricas de erros associados ao modelo de previsão de carga de curto prazo do Subsistema Sul.

Fonte: o próprio autor

Modelo de previsão de carga de curto prazo - Subsistema Sul						
Data da previsão	24 horas			De 10h a 15h		
	MAPE (%)	RMSE (MWh/h)	nRMSE (%)	MAPE (%)	RMSE (MWh/h)	nRMSE (%)
01/01/2020	2,810	356,673	12,627	1,650	170,188	6,025
02/01/2020	1,675	273,409	8,523	2,001	324,226	10,107
03/01/2020	1,609	222,017	7,004	1,105	149,081	4,703
04/01/2020	1,555	205,295	5,926	0,816	94,791	2,736
05/01/2020	1,510	202,258	4,368	1,423	143,394	3,097
06/01/2020	2,247	385,522	6,668	1,947	371,954	6,433
07/01/2020	1,636	281,999	6,332	2,738	431,870	9,698

Analisando a Figura 4.9 e a Tabela 4.3 pode-se afirmar que a previsão para o dia 01/01/2020 (quarta-feira e feriado nacional) apresentou o pior resultado dentre os 7 dias previstos e o melhor resultado foi visto na previsão para o final de semana (dias 04/01/2020 e 05/01/2020) tanto na previsão considerando o dia inteiro quanto para o período entre 10 horas e 15 horas. Foi constatado também que a previsão de carga apresentou melhor desempenho no período de maior produção de energia solar fotovoltaica em 5 dos 7 dias analisados.

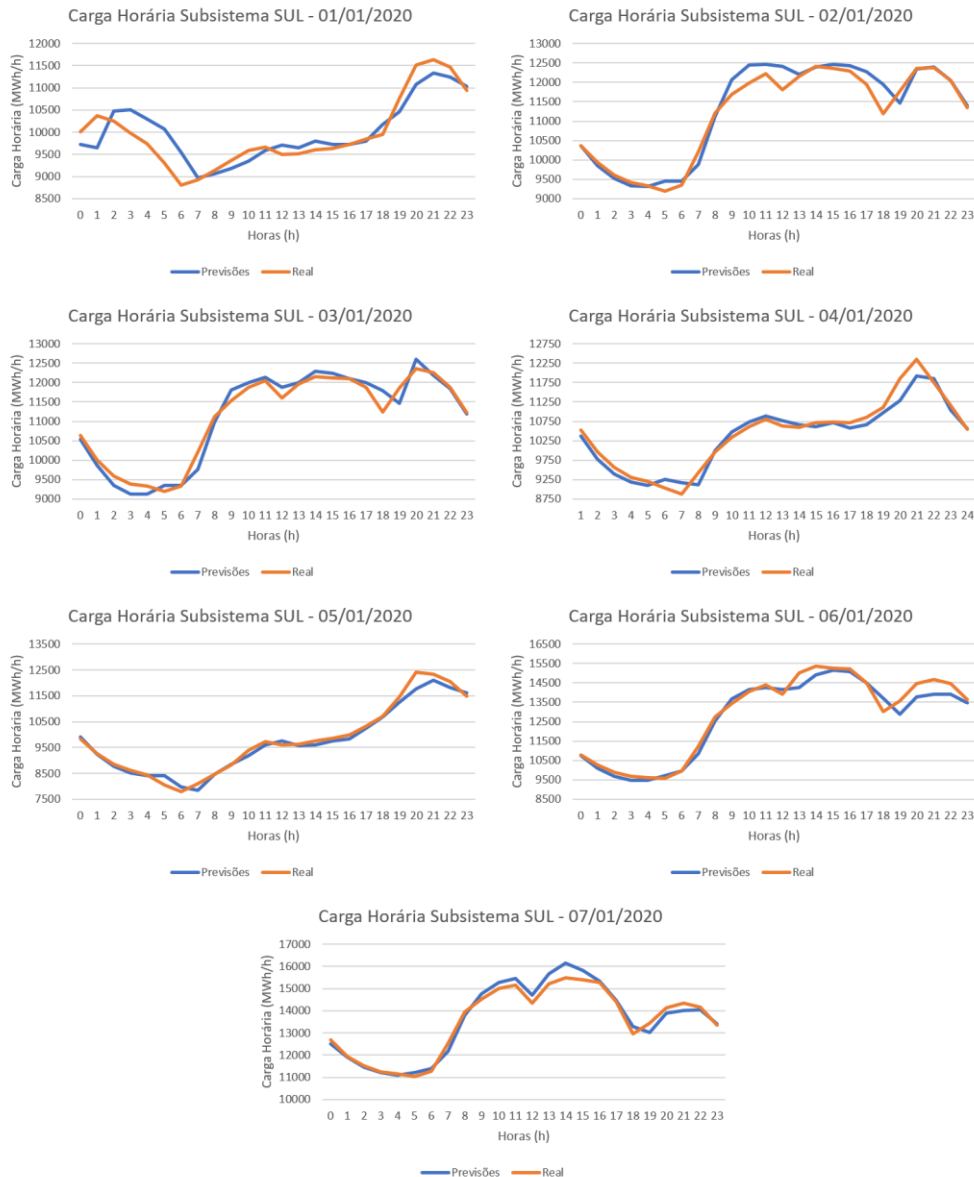


Figura 4.9 - Carga horária prevista do Subsistema Sul no período de 01/01/2020 a 07/01/2020
Fonte: o próprio autor

4.1.4. Subsistema Nordeste

Ao observar a Figura 4.10 e a Tabela 4.4 percebe-se que o desempenho da previsão de carga no dia 01/01/2020 foi abaixo do desempenho apresentado nos outros dias previstos e no dia 04/01/2020 foi relatado o melhor desempenho juntamente com os dias do fim de semana (04/01/2020 e 05/01/2020). Nos dias 02/01/2020, 04/01/2020 e 06/01/2020 os erros encontrados no período de maior geração de energia solar fotovoltaica (entre 10 horas e 15 horas) foram menores do

que os erros medidos considerando as previsões realizadas para o período de 24 horas no subsistema Nordeste (NE).

4.1.5. Subsistema Norte

Por meio de uma análise primária e superficial das previsões geradas pelo modelo de previsão de carga do subsistema Norte (NO), expressas pela Figura 4.11 e pela Tabela 4.5, é possível afirmar que na previsão de carga para o dia 07/01/2020 o modelo atingiu seu melhor desempenho em comparação com os resultados de previsões dos outros dias e o pior desempenho de previsão foi observado no dia 03/01/2020. Foi constatado também que dentre as 7 previsões realizadas em 5 ocasiões os erros associados à previsão de carga no período entre 10 horas e 15 horas foram menores em relação aos erros observados considerando a previsão para o dia inteiro.

Tabela 4.4 - Resultado das métricas de erros associados ao modelo de previsão de carga de curto prazo do Subsistema Nordeste.

Fonte: o próprio autor

Modelo de previsão de carga de curto prazo - Subsistema Nordeste						
Data da previsão	24 horas			De 10h a 15h		
	MAPE (%)	RMSE (MWh/h)	nRMSE (%)	MAPE (%)	RMSE (MWh/h)	nRMSE (%)
01/01/2020	2,0538	241,201	10,213	2,228	190,143	8,051
02/01/2020	0,912	115,371	4,192	0,638	84,119	3,064
03/01/2020	1,393	179,629	8,264	1,563	190,545	8,762
04/01/2020	0,605	97,036	4,265	0,266	27,454	1,211
05/01/2020	0,757	98,093	4,058	0,814	78,331	3,236
06/01/2020	0,797	111,196	4,097	0,602	81,497	3,004
07/01/2020	1,004	123,885	4,934	1,053	128,887	5,138

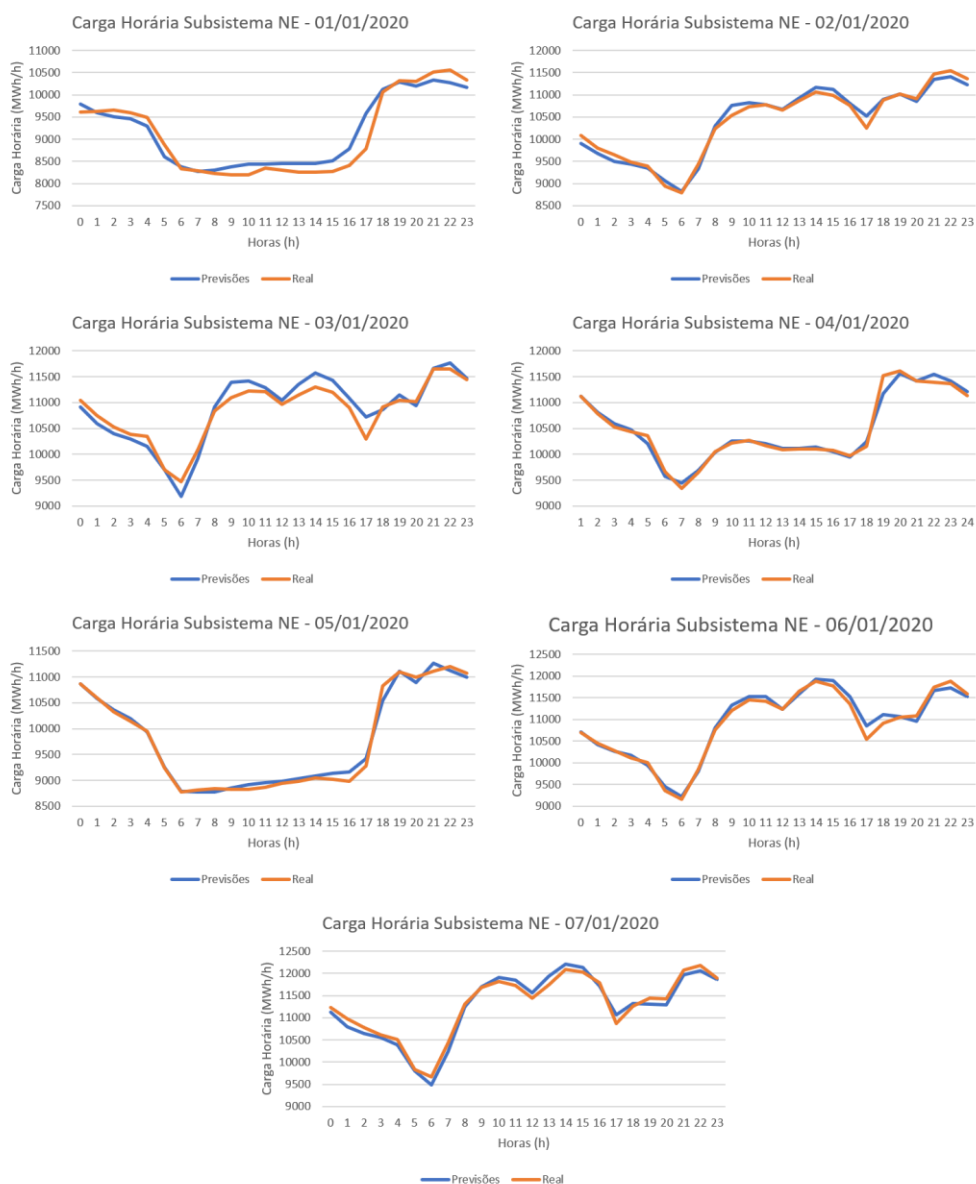


Figura 4.10 - Carga horária prevista do Subsistema Nordeste no período de 01/01/2020 a 07/01/2020
Fonte: o próprio autor

Tabela 4.5 - Resultado das métricas de erros associados ao modelo de previsão de carga de curto prazo do Subsistema Norte.

Fonte: o próprio autor

Modelo de previsão de carga de curto prazo - Subsistema Norte						
Data da previsão	24 horas			De 10h a 15h		
	MAPE (%)	RMSE (MWh/h)	nRMSE (%)	MAPE (%)	RMSE (MWh/h)	nRMSE (%)
01/01/2020	1,500	86,950	8,786	1,109	61,463	6,211
02/01/2020	0,957	68,133	7,288	1,037	61,139	6,540
03/01/2020	1,837	1431,501	10,055	1,377	1033,734	7,261
04/01/2020	0,892	56,887	6,421	0,928	55,954	6,315
05/01/2020	0,685	43,226	3,727	0,597	38,448	3,315
06/01/2020	0,754	47,912	5,721	0,743	47,973	5,728
07/01/2020	0,603	41,107	4,661	0,496	33,119	3,755

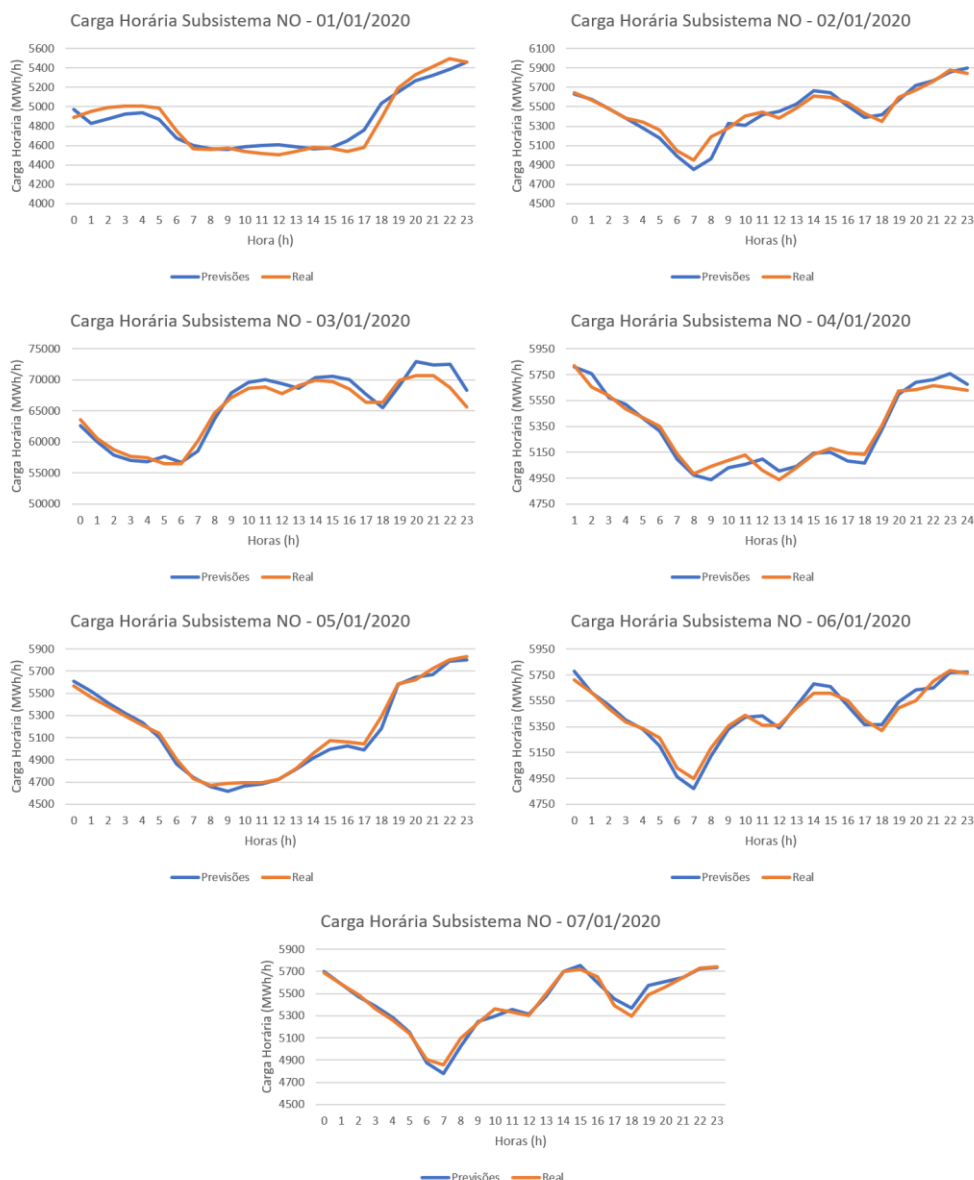


Figura 4.11 - Carga horária prevista do Subsistema Norte no período de 01/01/2020 a 07/01/2020
Fonte: o próprio autor

4.2. Previsão de carga de médio prazo

Após a realização das previsões de carga de médio prazo feitas pelo modelo de rede neural definido na metodologia apresentada no Capítulo 3 serão mostrados, nesta seção, os resultados obtidos, além de análises feitas sobre cada resultado apresentado.

Foram feitas previsões de carga do SIN e dos subsistemas que o compõe no período entre 2016 e 2020, em intervalos mensais que serão exibidas por meio de

gráficos que representam a curva de carga de energia ao longo do tempo. A análise acerca da qualidade da metodologia proposta neste trabalho será feita por meio do cálculo dos erros associados à previsão de carga em relação aos valores reais e também pela comparação entre os valores previstos pelo modelo de previsão deste trabalho e os valores previstos de carga, elaborados pela EPE e pelo ONS, para o planejamento anual da operação exibidos na 1ª Revisão Quadrimestral das Projeções da demanda de energia elétrica ciclo 2016-2020 [65].

Tais análises têm como objetivo atestar a qualidade do modelo de previsão para este tipo de tarefa, indicando se a metodologia proposta é confiável o suficiente para atender às demandas do ONS, da EPE e de outros agentes responsáveis no setor elétrico.

4.2.1. Sistema Interligado Nacional

Na previsão de carga de energia do SIN percebe-se pela Figura 4.12 e pela Tabela 4.6 que os valores previstos pelo modelo proposto neste trabalho estão mais próximos dos valores reais em comparação com os valores previstos pela EPE e ONS. Analisando os erros observados nota-se que o melhor desempenho de previsão foi alcançado após a previsão dos primeiros 24 meses, entre 2016 e 2017.

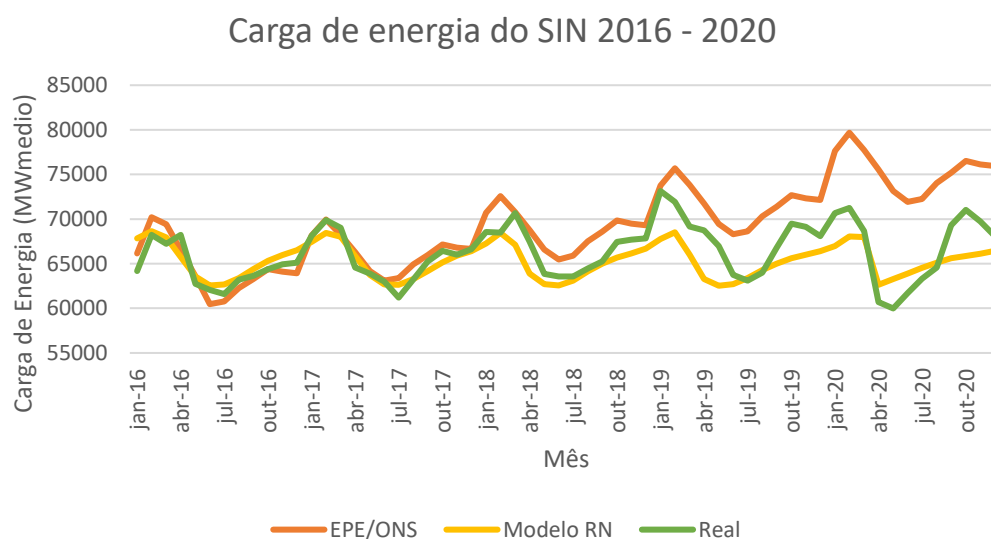


Figura 4.12 - Carga de energia prevista do SIN no período de jan/2016 a dez/2020.

Fonte: o próprio autor

Tabela 4.6 - Resultado das métricas de erros associados ao modelo de previsão de carga de médio prazo do SIN

Fonte: o próprio autor

Período de previsão	Modelo de previsão de médio prazo - SIN					
	Modelo RN			EPE/ONS		
	MAPE (%)	RMSE (MW _{medio})	nRMSE (%)	MAPE (%)	RMSE (MW _{medio})	nRMSE (%)
jan/16 a dez/16	1,79	1491,98	22,49	1,84	1358,33	20,47
jan/16 a dez/17	1,47	1242,81	14,27	1,51	1210,47	13,90
jan/16 a dez/18	1,64	1428,74	15,09	2,13	1723,05	18,19
jan/16 a dez/19	2,25	2068,26	17,31	3,03	2528,71	21,16
jan/16 a dez/20	2,57	2261,71	17,19	5,15	4735,11	35,99

4.2.2. Subsistema Sudeste/Centro-Oeste

Na Figura 4.13 e na Tabela 4.7 tem-se, respectivamente, as curvas de carga de energia e os erros dos valores previstos pelo grupo EPE/ONS e pelo modelo proposto neste trabalho. Percebe-se que nas primeiras 24 previsões (2 anos) os valores obtidos tanto pela metodologia da EPE e do ONS quanto pela metodologia deste trabalho apresentado no Capítulo 4 estão bem próximos dos valores reais observados. Mas a partir do ano de 2018 vê-se uma vantagem do modelo de rede neural, apresentando melhores resultados do que as previsões feitas pela EPE. Constatou-se também que o desempenho do modelo de RN nas previsões de carga de energia para este subsistema é superior ao desempenho apresentado para outros subsistemas.

4.2.3. Subsistema Sul

Dentre todas as previsões realizadas pela rede neural LSTM, o subsistema Sul obteve os piores resultados em comparação com o desempenho apresentado pelas previsões feitas pela rede neural em outros subsistemas e no SIN. Por meio da

Figura 4.14 e da Tabela 4.8 nota-se também que a partir do segundo ano de previsão o desempenho de previsão da rede neural cai consideravelmente em relação ao desempenho da metodologia apresentada pela EPE/ONS.

Tabela 4.7 - Resultado das métricas de erros associados ao modelo de previsão de carga de médio prazo do subsistema SE/CO
Fonte: o próprio autor

Modelo de previsão de médio prazo - subsistema SE/CO						
Período de previsão	Modelo RN			EPE/ONS		
	MAPE (%)	RMSE (MWme-dio)	nRMSE (%)	MAPE (%)	RMSE (MWme-dio)	nRMSE (%)
jan/16 a dez/16	1,70	850,26	17,37	1,83	863,84	17,65
jan/16 a dez/17	1,51	746,29	13,31	1,96	894,66	15,95
jan/16 a dez/18	1,66	846,55	12,98	2,63	1228,48	18,84
jan/16 a dez/19	2,29	1211,61	15,38	3,59	1725,11	21,90
jan/16 a dez/20	2,66	1348,84	15,62	5,79	2991,07	34,63

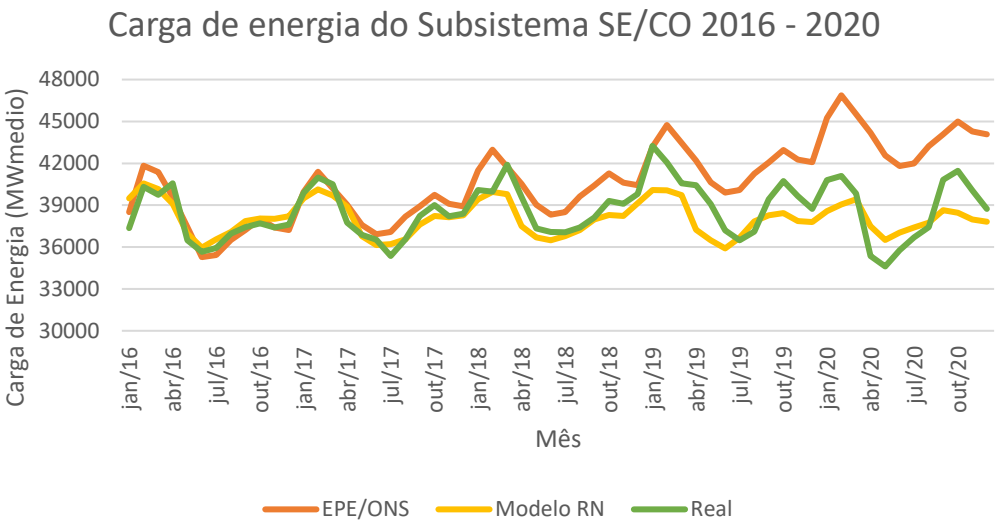


Figura 4.13 - Carga de energia prevista do subsistema SE/CO no período de jan/2016 a dez/2020
Fonte: o próprio autor

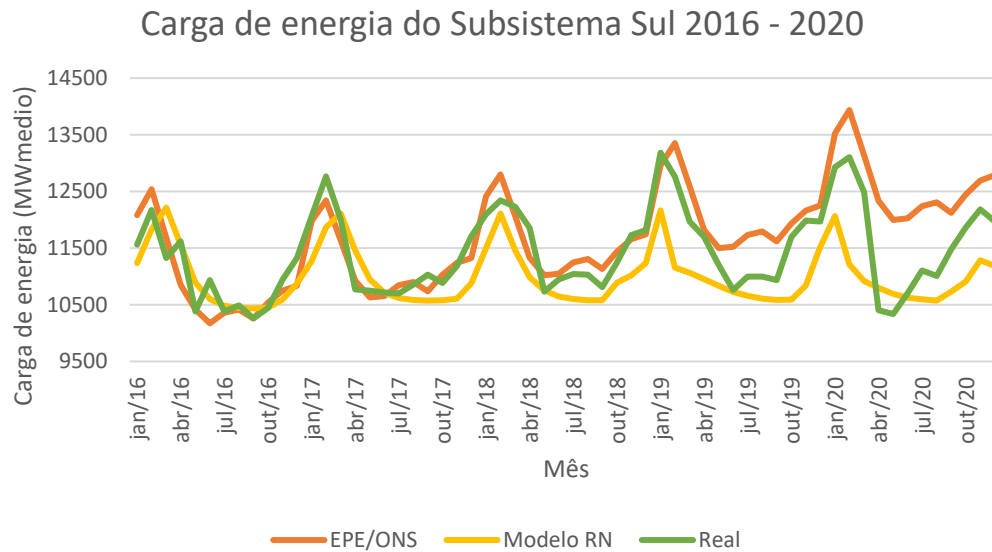


Figura 4.14 - Carga de energia prevista do subsistema Sul no período de jan/2016 a dez/2020.

Fonte: o próprio autor

Tabela 4.8 - Resultado das métricas de erros associados ao modelo de previsão de carga de médio prazo do subsistema Sul

Fonte: o próprio autor

Período de previsão	Modelo de previsão de médio prazo - subsistema Sul					
	Modelo RN			EPE/ONS		
	MAPE (%)	RMSE (MWmedio)	nRMSE (%)	MAPE (%)	RMSE (MWmedio)	nRMSE (%)
jan/16 a dez/16	2,70	382,91	20,02	2,72	408,52	21,36
jan/16 a dez/17	3,23	462,12	18,44	2,19	332,15	13,25
jan/16 a dez/18	3,48	482,93	19,27	2,18	317,21	12,66
jan/16 a dez/19	4,08	588,91	20,15	2,64	379,52	12,98
jan/16 a dez/20	4,57	671,75	22,98	3,89	595,53	20,37

4.2.4. Subsistema Nordeste

O resultado da previsão de carga realizada pelo modelo para o subsistema Nordeste se encontra na Figura 4.15 e na Tabela 4.9. A partir do quarto ano de previsão de carga o desempenho do modelo de rede neural cai, apresentando ao longo das previsões desempenho semelhante ao mostrado pelas previsões feitas

pela EPE/ONS, mas ao final dos 5 anos de previsão o modelo de proposto por este trabalho apresentou erros menores, tornando-o uma melhor opção para a realização de previsões de carga de médio prazo.

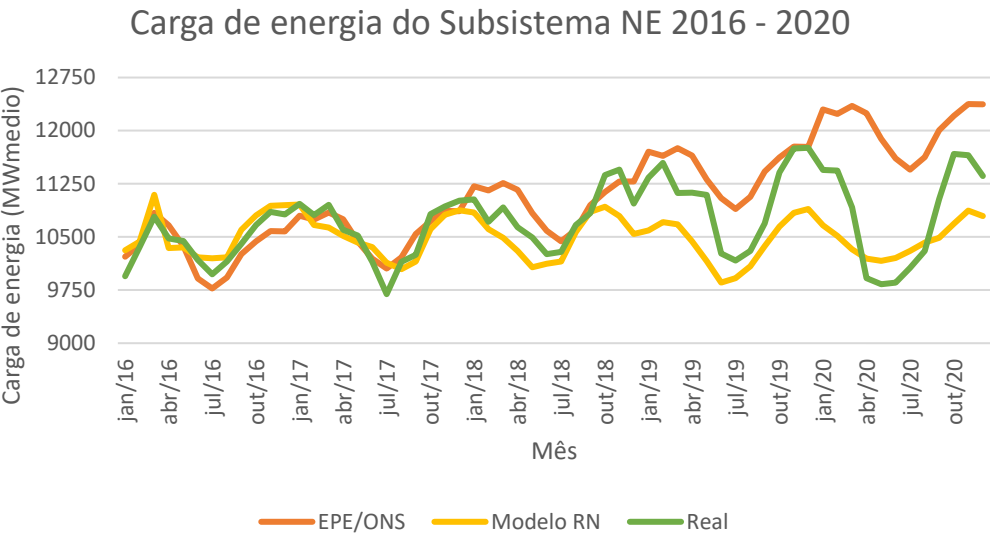


Figura 4.15 - Carga de energia prevista do subsistema NE no período de jan/2016 a dez/2020.
Fonte: o próprio autor

Tabela 4.9 - Resultado das métricas de erros associados ao modelo de previsão de carga de médio prazo do subsistema Nordeste
Fonte: o próprio autor

Modelo de previsão de médio prazo - subsistema Nordeste						
Período de previsão	Modelo RN			EPE/ONS		
	MAPE (%)	RMSE (MWmedio)	nRMSE (%)	MAPE (%)	RMSE (MWmedio)	nRMSE (%)
jan/16 a dez/16	1,49	183,18	20,13	1,76	200,57	22,04
jan/16 a dez/17	1,53	191,13	14,48	1,54	184,39	13,97
jan/16 a dez/18	1,88	250,08	14,24	1,86	229,36	13,06
jan/16 a dez/19	2,78	397,57	19,24	2,39	324,82	15,72
jan/16 a dez/20	3,20	446,76	21,63	4,32	678,59	32,85

4.2.5. Subsistema Norte

A Figura 4.16 mostra a curva de carga de energia obtida através do modelo de rede neural proposto neste trabalho, além da curva de carga estimada pela EPE e pelo ONS e também a curva de energia real verificada pelo ONS. Na Tabela 4.10 verifica-se que as previsões obtidas pela rede neural no período entre 2016 e 2017 são menos precisas do que as estimativas feitas pela EPE. Mas partir de 2018 nota-se maior precisão das previsões feitas pela rede neural em comparação com as estimativas feitas pela EPE e pelo ONS.

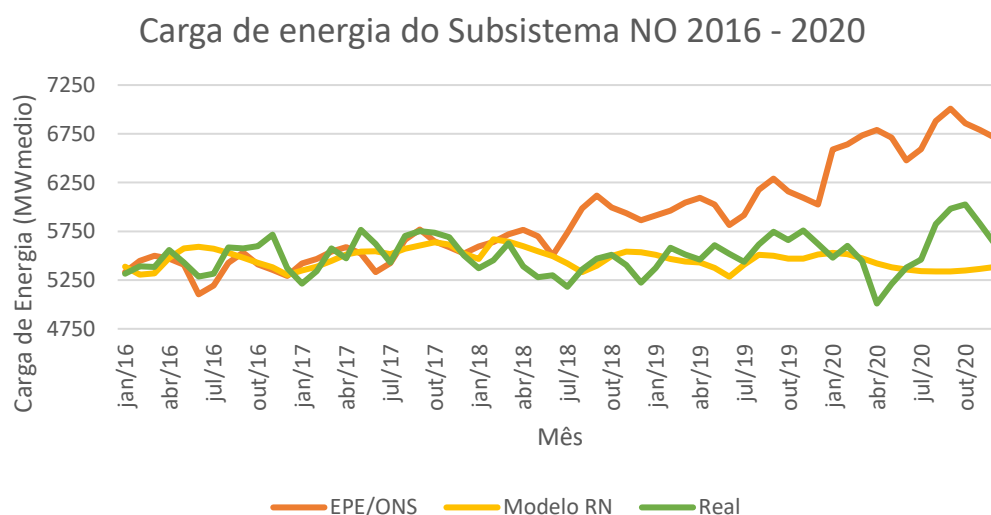


Figura 4.16 - Carga de energia prevista do subsistema NO no período de jan/2016 a dez/2020
Fonte: o próprio autor

4.3. Conclusão do capítulo

Neste capítulo foi apresentado a última etapa da metodologia apresentada no Capítulo 3: a exibição dos resultados de previsão tanto para o curto prazo quanto para o médio prazo.

Pode-se perceber pelos resultados que a metodologia proposta é capaz de gerar resultados satisfatórios para previsões de curto e médio prazos tanto para o SIN quanto para cada um dos subsistemas que o compõe.

Tabela 4.10 - Resultado das métricas de erros associados ao modelo de previsão de carga de médio prazo do subsistema Norte

Fonte: o próprio autor

Modelo de previsão de médio prazo - subsistema Norte						
Período de previsão	Modelo RN			EPE/ONS		
	MAPE (%)	RMSE (MWme- dio)	nRMSE (%)	MAPE (%)	RMSE (MWme- dio)	nRMSE (%)
jan/16 a dez/16	2,65	173,49	40,25	2,17	150,23	34,85
jan/16 a dez/17	2,23	147,03	26,56	2,05	145,12	26,21
jan/16 a dez/18	2,42	158,74	27,09	3,95	288,94	49,31
jan/16 a dez/19	2,48	161,62	27,58	5,07	346,17	59,07
jan/16 a dez/20	2,97	218,02	21,45	8,27	613,87	60,41

5 Conclusões

Esta dissertação propôs, por meio das análises feitas sobre a geração distribuída no Brasil (Capítulo 2), apresentar uma metodologia de previsão de carga que estabelecesse uma relação entre a estimativa de energia solar fotovoltaica proveniente da mini e microgeração distribuída e o comportamento da curva de carga do sistema elétrico brasileiro, com o objetivo de apresentar aos agentes do setor elétrico mais uma opção confiável de previsão de carga. As previsões de carga foram feitas para o SIN e para cada um dos subsistemas que o compõe tanto para o curto prazo, tendo como horizonte o dia seguinte de operação do sistema, quanto para o médio prazo, tendo como horizonte a operação do sistema pelos próximos cinco anos, em intervalos mensais.

Para se obter uma conclusão segura acerca da qualidade da metodologia aplicadas à previsão de carga de curto prazo foram realizadas sete previsões de carga de curto prazo para cada subsistema elétrico e também para o SIN (35 previsões, ao todo) que tiveram seus erros de previsão comparados com os erros encontrados nos trabalhos [42, 58] para se ter uma avaliação mais segura dos resultados.

Analisando-se os resultados exibidos no Capítulo 4 nota-se que a metodologia proposta neste trabalho é capaz de prever com boa precisão o perfil da curva de carga para qualquer dia da semana, sendo feriado ou não. Por meio da Figura 5.1 pode-se atestar a eficiência do modelo de previsão ao verificar-se os baixos valores de MAPE e nRMSE, com destaque para as previsões realizadas para os subsistemas SE/CO e Nordeste. Verificou-se também que em grande parte das previsões realizadas a rede neural apresentou melhor desempenho ao prever os valores de carga no período entre 10 horas e 15 horas, momento do dia de maior geração de energia solar fotovoltaica no Brasil, revelando que a estimação da geração de energia solar fotovoltaica implicou numa melhora do desempenho do modelo de previsão de carga, tornando o modelo ainda mais útil em aplicações onde se deseja prever o comportamento da carga elétrica para esse mesmo período do dia.

Para analisar a qualidade da metodologia aplicada à previsão de carga de médio prazo foram realizadas cinco previsões de carga, uma para cada subsistema elétrico e para o SIN, no período entre 2016 e 2020, que foram comparadas com as estimativas de carga de energia feitas pela EPE e pelo ONS. Na Figura 5.2 nota-se que há um melhor desempenho da metodologia proposta neste trabalho, evidenciando que o modelo é útil ao realizar previsões de médio prazo, com horizonte de cinco anos. Mas vale ressaltar que apesar de ter exibido menores erros de previsão em relação à metodologia usada pela EPE/ONS a metodologia deste trabalho apresentou uma perda expressiva de qualidade partir do terceiro ano de previsão, necessitando de uma avaliação mais criteriosa quanto ao seu uso por parte dos agentes responsáveis pelos estudos de previsões de carga do setor elétrico.

Diante dos resultados obtidos a partir do uso da metodologia nas previsões de carga feitas neste trabalho pode-se concluir que o modelo de previsão está apto para ser usado com garantia de bons resultados pelos usuários. O objetivo deste trabalho não foi de apresentar o melhor modelo de previsão existente, porque não há o melhor modelo de previsão, mas aquele que melhor se adequa aos dados investigados. Neste sentido pode-se afirmar que este trabalho apresentou mais um bom preditor de carga que pode ser usado futuramente em conjunto com os mais variados modelos já existentes.

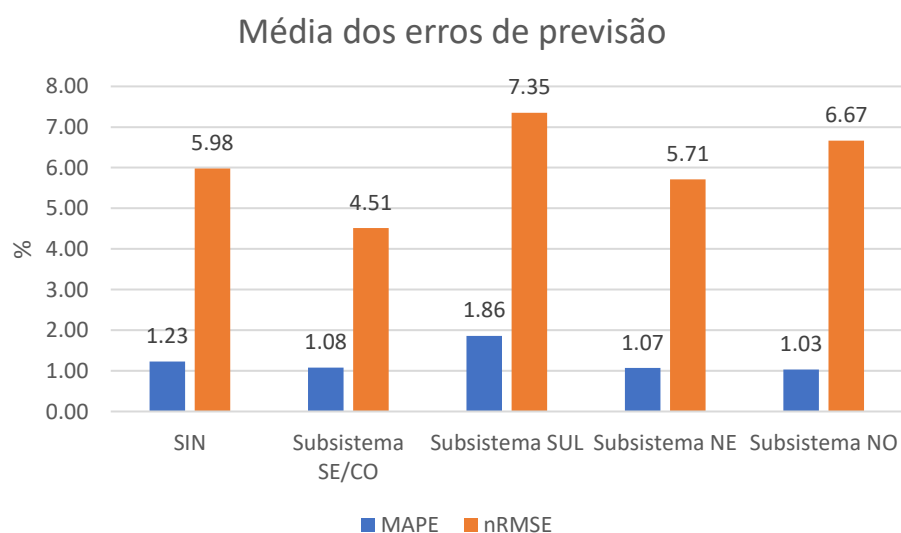


Figura 5.1 - Média dos erros das previsões de carga de curto prazo

Fonte: o próprio autor

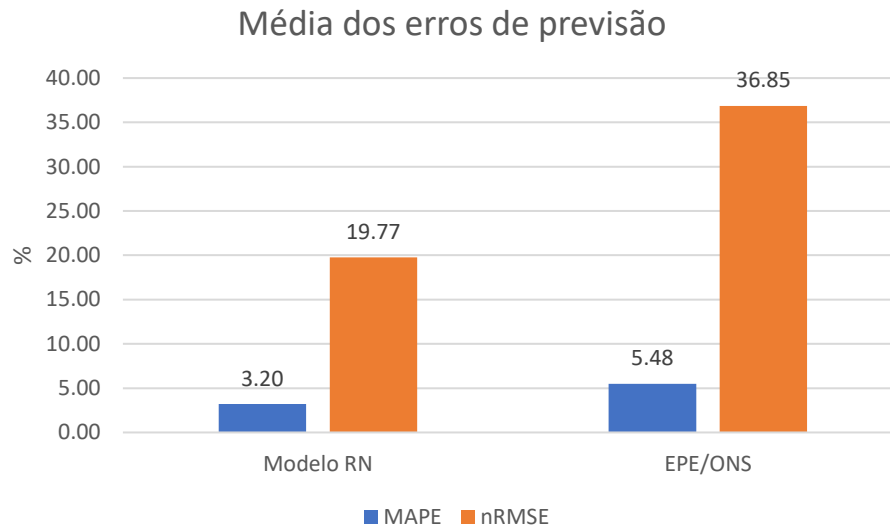


Figura 5.2 - Média dos erros das previsões de carga de médio prazo
Fonte: o próprio autor

5.1. Trabalhos futuros

Após a verificação da qualidade da metodologia apresentada neste trabalho para a realização de previsões de carga, seguem algumas sugestões de trabalhos futuros que podem contribuir para o aprimoramento deste trabalho, levando aos agentes interessados uma metodologia capaz de atender melhor aos desafios inerentes à previsão de carga diante do contínuo crescimento da mini e microgeração distribuída na matriz elétrica brasileira:

- Uso de outras equações matemáticas que expressem com mais precisão a energia gerada pelos painéis fotovoltaicos;
- Estimação da geração solar fotovoltaica a nível municipal, garantindo maior precisão na realização da previsão de carga;
- Introdução de outras fontes de energia pertencentes à mini e micro geração distribuída definida pela ANEEL para a realização do cálculo de energia gerada pela mini e microgeração distribuída;
- Uso da metodologia em previsões de carga para diferentes horizontes e intervalos de previsão para atender as mais variadas necessidades do ONS e dos demais agentes envolvidos;

- Exploração de outros modelos de inteligência computacional ou modelos estatísticos que podem realizar previsões de carga;
- Abordagens mais eficientes para o tratamento dos dados faltantes e *outliers* para que se tenha dados mais próximos da realidade;
- Utilização desta metodologia de previsão para avaliação do impacto no planejamento e programação da operação do Sistema Interligado Nacional e os subsistemas que o compõe;
- Verificar a aplicabilidade do modelo em sistemas elétricos com alta penetração de geração distribuída conectada à rede de distribuição, como no caso do estado da Califórnia, nos Estados Unidos da América;
- Verificação do ganho de precisão com a introdução da estimação da geração solar fotovoltaica como variável exógena nas previsões de carga;
- Comparação entre a metodologia apresentada neste trabalho com as metodologias já existentes usadas pelos agentes do setor elétrico, como o ONS;
- Considerar extensão do modelo apresentado neste trabalho para a previsão de carga para os diferentes perfis de carga horária (finais de semana e feriados);
- Introduzir outras variáveis exógenas para a realização das previsões de carga, como a temperatura do ar, por exemplo.

5.2. Conclusão do capítulo

Neste capítulo foi mostrado os resultados obtidos a partir das respostas do modelo de previsão de carga. Levando-se em consideração a análise dos erros obtidos durante as previsões pode-se concluir que a metodologia apresentada neste trabalho é considerada confiável para o uso pelos agentes do setor elétrico brasileiro, como o ONS e as concessionárias de energia elétrica.

Diante do cenário atual e da perspectiva apresentada em relação ao paradigma do setor elétrico brasileiro nos capítulos anteriores, a busca por novas metodologias de previsão de carga se torna necessária para contornar os desafios inerentes a alta penetração de fontes intermitentes no sistema elétrico. Tendo em vista que a metodologia apresentada neste trabalho representa uma boa solução para as necessidades

atuais, o aprimoramento desta ferramenta de previsão, conforme foi sugerido na seção anterior de trabalhos futuros, também poderá trazer resultados satisfatórios que atendam as condições futuras de operação do sistema elétrico

6

Referências bibliográficas

- 1 WORLD ENERGY COUNCIL. **World Energy Scenarios**: Composing energy futures to 2050. Londres: WEC, 2013. 44 p. ISBN 978-0-946121-33-5. Disponível em: <https://www.worldenergy.org/assets/downloads/World-Energy-Scenarios_Composing-energy-futures-to-2050_Full-report1.pdf>. Acesso em: 10 jan. 2021.
- 2 ALFUHAID, A. S. *et al.* Cascaded artificial neural networks for short-term load forecasting. **IEEE Transactions on Power Systems**, [S. l.], v. 12, p. 1524-1529, 1 novembro 1997.
- 3 ROSER, M.; RITCHIE, H. **Renewable Energy**. [S. l.]: Our World in Data, 2020. Disponível em: <<https://ourworldindata.org/renewable-energy#citation>>. Acesso em: 10 jan. 2021.
- 4 RENEWABLE ENERGY POLICY NETWORK FOR THE 21ST CENTURY. **Renewables 2020**: Global Status Report. Paris: REN21. 367 p. ISBN 978-3-948393-00-7. Disponível em: <https://www.ren21.net/wp-content/uploads/2019/05/gsr_2020_full_report_en.pdf>. Acesso em: 10 jan. 2021.
- 5 INTERNATIONAL RENEWABLE ENERGY AGENCY. **Renewable power generation costs in 2019**. Abu Dhabi: IEA, 2020. 144 p. ISBN 978-92-9260-244-4. Disponível em: <https://www.irena.org/-/media/Files/IRENA/Agency/Publication/2020/Jun/IRENA_Power_Generation_Costs_2019.pdf>. Acesso em: 10 jan. 2021.
- 6 INTERNATIONAL ENERGY AGENCY. **Renewable electricity net capacity additions by technology, main and accelerated cases, 2013-2022**. Paris: IEA, 2020. Disponível em: <<https://www.iea.org/data-and-statistics/charts/renewable-electricity-net-capacity-additions-by-technology-main-and-accelerated-cases-2013-2022>>. Acesso em: 10 jan. 2021.
- 7 CASTRO, Nivalde José de; DANTAS, Guilherme (org.). **Experiências Internacionais em geração distribuída**: motivações, impactos e ajustes. Rio de Janeiro: Publit, 2018. 442 p.
- 8 MASSON, G.; KAIZUKA, I. **IEA PVPS**: Trends in Photovoltaic Applications. 16. ed. [S. l.]: G. Masson, 2020. 88 p. ISBN 978-3-907281-01-7. Disponível em: <https://iea-pvps.org/wp-content/uploads/2020/11/IEA_PVPS_Trends_Report_2020-1.pdf>. Acesso em: 10 jan. 2021.

- 9 INTERNATIONAL RENEWABLE ENERGY AGENCY. **Future of Solar Photovoltaic**: Deployment, investment, technology, grid integration and socio-economic aspects (A Global Energy Transformation: paper). Abu Dhabi: IRENA, 2019. 73 p. ISBN 978-92-9260-156-0. Disponível em: <https://www.irena.org/-/media/Files/IRENA/Agency/Publication/2019/Nov/IRENA_Future_of_Solar_PV_2019.pdf>. Acesso em: 10 jan. 2021.
- 10 INTERNATIONAL ENERGY AGENCY. **Outlook for electricity**: World Energy Outlook 2020. World Energy Outlook 2020. Paris: IEA, 2021. Disponível em: <<https://www.iea.org/reports/world-energy-outlook-2020/outlook-for-electricity#abstract>>. Acesso em: 10 jan. 2021.
- 11 BRASIL (País). Ministério de Minas e Energia. **Relatório: Programa de Desenvolvimento da Geração Distribuída de Energia Elétrica - ProGD**. Brasília: [s. n.], 2019. 210 p. Disponível em: <<http://antigo.mme.gov.br/documents/20182/6dac9bf7-78c7-ff43-1f03-8a7322476a08>>. Acesso em: 10 jan. 2021.
- 12 MAKRIDAKIS, Spyros *et al.* The M4 Competition: Results, findings, conclusion and way forward. **International Journal of Forecasting**, [S. l.], v. 34, p. 802-808, dezembro 2018.
- 13 LI, Haoen; GAO, Shan. The mid and long-term load forecast method based on synthesis best fitting forecasting model. In: 2008 THIRD INTERNATIONAL CONFERENCE ON ELECTRIC UTILITY DEREGULATION AND RESTRUCTURING AND POWER TECHNOLOGIES, 3., 2008, Nanjing. **Proceedings [...]**. [S.L.]: IEEE, 2008. p. 1493-1498.
- 14 TAYLOR, J. W.; MCSHARRY, P. E. Short-Term Load Forecasting Methods: An Evaluation Based on European Data. **IEEE Transactions on Power Systems**, [S. l.], v. 22, p. 2213-2219, novembro 2007.
- 15 CHEN, S. -T. *et al.* Weather sensitive short-term load forecasting using non-fully connected artificial neural network. **IEEE Transactions on Power Systems**, [S. l.], v. 7, p. 1098-1105, agosto 1992.
- 16 HARROUZ, A. *et al.* Social Acceptance of Renewable Energy dedicated to Electric Production. In: 2020 9TH INTERNATIONAL CONFERENCE ON RENEWABLE ENERGY RESEARCH AND APPLICATION (ICRERA), 9., 2020, Glasgow. **Proceedings [...]**. [S.L.]: IEEE, 2020. p. 283-288.
- 17 HO, K. L. *et al.* Short term load forecasting using a multilayer neural network with an adaptive learning algorithm. **IEEE Transactions on Power Systems**, [S. l.], v. 7, p. 141-149, fevereiro 1992.
- 18 FIOROTTI, Rodrigo. **Metodologia para determinar a potência firme das unidades de geração distribuída e sua aplicação no processo de previsão de demanda das redes de distribuição de energia elétrica**. Orientador: Jussara Farias Fardin. 2015. 82 f. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal do Espírito Santo, Vitória, 2015.

- 19 XIAOJING, Hu *et al.* Load forecasting techniques for networks with distributed generation (DG) sources. In: 2016 CHINESE CONTROL AND DECISION CONFERENCE (CCDC), 28., 2016, Yinchuan, China. **Proceedings [...]**. Yinchuan, China: IEEE, 2016. p. 6232-6237.
- 20 SONG, Y. *et al.* Medium and long term load forecasting considering the uncertainty of distributed installed capacity of photovoltaic generation. In: IEEE CONFERENCE ON INDUSTRIAL ELECTRONICS AND APPLICATIONS (ICIEA), 13., 2018, Wuhan, China. **Proceedings [...]**. [S. l.]: IEEE, 2018. p. 1691-1696.
- 21 IZZATILLAEV, J.; YUSUPOV, Z.. Short-term Load Forecasting in Grid-connected Microgrid. In: 2019 7TH INTERNATIONAL ISTANBUL SMART GRIDS AND CITIES CONGRESS AND FAIR (ICSG), 7., 2019, Istambul. **Proceedings [...]**. [S. l.]: IEEE, 2019. p. 71-75.
- 22 HASAN, Hafidh; MUNAWAR, Muhammad Ridha; SIREGAR, Ramdhan Halid. Neural network-based solar irradiance forecast for peak load management of grid-connected microgrid with photovoltaic distributed generation. In: 2017 INTERNATIONAL CONFERENCE ON ELECTRICAL ENGINEERING AND INFORMATICS (ICELTICS), 1., 2017, Banda Achém, Indonésia. **Proceedings [...]**. [S.L.]: IEEE, 2017. p. 87-90.
- 23 EMPRESA DE PESQUISA ENERGÉTICA. **Balanço Energético Nacional 2020**: Ano base 2019. Rio de Janeiro: EPE, 2020. 292 p. Disponível em: <https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-479/topico-528/BEN2020_sp.pdf>. Acesso em: 10 jan. 2021.
- 24 INTERNATIONAL ENERGY AGENCY. **Electricity Information: Overview**. Paris, jul 2020. Disponível em: <<https://www.iea.org/reports/electricity-information-overview>>. Acesso em: 10 jan. 2021.
- 25 BRASIL. Congresso. Câmara dos Deputados. **ENERGIA SOLAR NO BRASIL: SITUAÇÃO E PERSPECTIVAS**. Brasília: Consultoria Legislativa, 2017. 46 p. Disponível em: <[https://bd.camara.leg.br/bd/bitstream/handle/bdcamara/32259/energia_solar_limp.pdf?sequence=1#:~:text=O%20Brasil%2C%20conforme%20MME%20\(2017,57%20MWp%20%20C3%A0%20gera%C3%A7%C3%A3o%20distribu%C3%ADa](https://bd.camara.leg.br/bd/bitstream/handle/bdcamara/32259/energia_solar_limp.pdf?sequence=1#:~:text=O%20Brasil%2C%20conforme%20MME%20(2017,57%20MWp%20%20C3%A0%20gera%C3%A7%C3%A3o%20distribu%C3%ADa)>. Acesso em: 10 jan. 2021.
- 26 AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. **Geração distribuída**. [S. l.], 2021. Disponível em: <<https://app.powerbi.com/view?r=eyJrIjojZjM4NjM0OWYtN2IwZS00YjViLTl1MjItN2E5MzBkN2ZlMzVkIiwidCI6IjQwZDZmOWI4LWVjYTctNDZhMi05MmQ0LWVhNGU5YzAxNzBIMSIsImMiOiR9>>. Acesso em: 10 jan. 2021.

- 27 AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. **RESOLUÇÃO NORMATIVA Nº 482, DE 17 DE ABRIL DE 2012**. [S. l.], 17 abr. 2012. Disponível em: <<http://www2.aneel.gov.br/cedoc/ren2012482.pdf>>. Acesso em: 10 jan. 2021.
- 28 EMPRESA DE PESQUISA ENERGÉTICA. **Plano Decenal de Expansão 2029**. Rio de Janeiro: EPE, 2019. Disponível em: <<https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-422/PDE%202029.pdf>>. Acesso em: 10 jan. 2021.
- 29 DE CASTRO, Nivalde *et al.* **Perspectivas e desafios da difusão da micro e da mini geração solar fotovoltaica no Brasil**. Rio de Janeiro: Publit, 2016. 46 p.
- 30 DE CASTRO, Nivalde *et al.* **Impactos sistêmicos da micro e minigeração distribuída**: TDSE nº 79. Rio de Janeiro: Publit, 2017. 64 p.
- 31 DRIESEN, J.; BELMANS, R.. Distributed generation: challenges and possible solutions. In: 2006 IEEE POWER ENGINEERING SOCIETY GENERAL MEETING, 1., 2006, Montreal, Qc, Canada. **Proceedings [...]**. [S.L.]: IEEE, 2006. p. 1-8.
- 32 FRUNT, J. *et al.* Effects of Further Integration of Distributed Generation on the Electricity Market. In: 41ST INTERNATIONAL UNIVERSITIES POWER ENGINEERING CONFERENCE, 41., 2006, Newcastle Upon Tyne, Uk. **Proceedings [...]**. [S.L.]: IEEE, 2006. p. 1-5.
- 33 DE CASTRO, Nivalde; DANTAS, Guilherme (org.). **Geração distribuída: experiências internacionais e análises comparadas**. Rio de Janeiro: Publit, 2018. 240 p. ISBN 978- 85-525-0083-4.
- 34 OPERADOR NACIONAL DO SISTEMA ELÉTRICO. **Histórico da operação**. [S. l.], 2021. Disponível em: <<http://www.ons.org.br/paginas/resultados-da-operacao/historico-da-operacao>>. Acesso em: 10 jan. 2021.
- 35 OPERADOR NACIONAL DO SISTEMA ELÉTRICO. **Procedimentos de rede**. [S. l.], 2021. Disponível em: <<http://www.ons.org.br/paginas/resultados-da-operacao/historico-da-operacao>>. Acesso em: 10 jan. 2021.
- 36 INSTITUTO NACIONAL DE METEOROLOGIA. **INMET BDMEP**. [S. l.], 2021. Disponível em: <<https://bdmep.inmet.gov.br/>>. Acesso em: 10 jan. 2021.
- 37 GONÇALVES, Silvia Regina dos Santos. **Metodologia para mensuração do impacto do potencial de geração fotovoltaica no planejamento da operação energética de médio prazo**. Orientador: Rodrigo Flora Calili. 2017. 141 f. Dissertação (Mestrado em Metrologia) - PUC-Rio, [S. l.], 2017.

- 38 Oliveira, F. L. C. (2010). **Nova abordagem para Geração de Cenários de Afluências no Planejamento da Operação Energética de Médio Prazo**. Dissertação de Mestrado, Departamento de Engenharia Elétrica, PUC-Rio.
- 39 GRADY, W. Mack; LIBBY, Leslie. A cloud shadow model and tracker suitable for studying the impact of high-penetration PV on power systems. In: 2012 IEEE ENERGYTECH, 2., 2012, Cleveland, EUA. **Proceedings [...]** . [S.L.]: IEEE, 2012. p. 1-6.
- 40 EBAD, Mehdi; GRADY, William Mack. A cloud shadow model for analysis of solar photovoltaic power variability in high-penetration PV distribution networks. In: 2016 IEEE POWER AND ENERGY SOCIETY GENERAL MEETING (PESGM), 14., 2016, Boston, EUA. **Proceedings [...]** . [S.L.]: IEEE, 2016. p. 1-5.
- 41 LIU, Fuguang *et al.* A Method of Calculating the Daily Output Power Reduction of PV Modules Due to Dust Deposition on Its Surface. **IEEE Journal Of Photovoltaics**. Golden, EUA, p. 881-887. 09 maio 2019.
- 42 LIANGYU, Ma *et al.* Output power attenuation rate prediction for photovoltaic panels considering dust deposition in hazy weather. In: 2017 36TH CHINESE CONTROL CONFERENCE (CCC), 36., 2017, Dalian, China. **Proceedings [...]** . [S.L.]: IEEE, 2017. p. 4099-4102.
- 43 DESMET, J *et al.* Power injection by distributed generation and the influence of harmonic load conditions. In: ENERGY SOCIETY GENERAL MEETING, 8., 2010, Minneapolis, EUA. **Proceedings [...]** . [S.L.]: IEEE, 2010. p. 1-6.
- 44 JORDAN, D. C.; KURTZ, S. R.. Photovoltaic Degradation Rates: an analytical review. In: NATIONAL RENEWABLE ENERGY LABORATORY. **Photovoltaic in progress: research and applications**. 23. ed. Nova Jersey, Eua: John Wiley & Sons, 2013. Cap. 2. p. 12-29. Disponível em: <https://doi.org/10.1002/pip.1182>. Acesso em: 10 jan. 2021.
- 45 RIFFONNEAU, Yann *et al.* Optimal Power Flow Management for Grid Connected PV Systems With Batteries. **IEEE Transactions On Sustainable Energy**. Charlotte, EUA, p. 309-320. jul. 2011.
- 46 CHEN, Jiann-Fuh; WANG, Wei-Ming; HUANG, Chao-Ming. Analysis of an adaptive time-series autoregressive moving-average (ARMA) model for short-term load forecasting. **Electric Power Systems Research**. Amsterdã, Holanda, p. 187-196. set. 1995.
- 47 HAGAN, Martin T.; BEHR, Suzanne M.. The Time Series Approach to Short-Term Load Forecasting. **IEEE Power Engineering Review**. [S.I.], p. 56-57. ago. 1987.
- 48 YANG, Hong-Tzer; HUANG, Chao-Ming; HUANG, Ching-Lien. Identification of ARMAX model for short term load forecasting: an

- evolutionary programming approach. **IEEE Transactions On Power Systems**. [S.I.], p. 403-408. fev. 1996.
- 49 GASPARIN, Alberto; LUKOVIC, Slobodan; ALIPPI, Cesare. Deep Learning for Time Series Forecasting: The Electric Load Case. **Swiss Competence Center For Energy Research On The Electrical Infrastructure**. [S. I.], p. 1-26. jul. 2019. Disponível em: <https://www.researchgate.net/publication/334624519_Deep_Learning_for_Time_Series_Forecasting_The_Electric_Load_Case>. Acesso em: 10 jan. 2021.
 - 50 HIPPERT, H.S.; PEDREIRA, C.E.; SOUZA, R.C.. Neural networks for short-term load forecasting: a review and evaluation. **IEEE Transactions On Power Systems**. [S. I.], p. 44-55. fev. 2001.
 - 51 BANDA, E.; FOLLY, K. A.. Short Term Load Forecasting Using Artificial Neural Network. In: 2007 IEEE POWER TECH, 4., 2007, Lausana, Suíça. **2007 IEEE Lausanne Power Tech**. [S.L.]: IEEE, 2008. p. 108-112.
 - 52 PARK, D. C. *et al.* Electric load forecasting using an artificial neural network. **IEEE Transactions On Power Systems**. [S. I.], p. 442-449. maio 1991.
 - 53 NIU, Dong-Xiao; WANQ, Qiang; LI, Jin-Chao. Short term load forecasting model using support vector machine based on artificial neural network. In: 2005 INTERNATIONAL CONFERENCE ON MACHINE LEARNING AND CYBERNETICS, 9., 2005, Guangzhou, China. **Proceedings [...]**. [S.L.]: IEEE, 2005. p. 4260-4265.
 - 54 YUANCHENG, Li; TINGJIAN, Fang; ERKENG, Yu. Short-term electrical load forecasting using least squares support vector machines. In: INTERNATIONAL CONFERENCE ON POWER SYSTEM TECHNOLOGY, 4., 2002, Kunming, China. **Proceedings [...]**. [S.L.]: IEEE, 2002. p. 230-233.
 - 55 GUO, Ying-Chun; NIU, Dong-Xiao; CHEN, Yan-Xu. Support Vector Machine Model in Electricity Load Forecasting. In: 2006 INTERNATIONAL CONFERENCE ON MACHINE LEARNING AND CYBERNETICS (ICMLC), 5., 2006, Dalian, China. **Proceedings [...]**. [S.L.]: IEEE, 2009. p. 2892-2896.
 - 56 KUO, Ping-Huan; HUANG, Chiou-Jye. A High Precision Artificial Neural Networks Model for Short-Term Energy Load Forecasting. **Energies** **2018**. [S. I.], p. 1-14. jan. 2018.
 - 57 AMARASINGHE, Kasun; MARINO, Daniel L.; MANIC, Milos. Deep neural networks for energy load forecasting. In: 2017 IEEE 26TH INTERNATIONAL SYMPOSIUM ON INDUSTRIAL ELECTRONICS (ISIE), 26., 2017, Edinburgh, Reino Unido. **Proceedings [...]**. [S.L.]: IEEE, 2017. p. 1483-1488.

- 58 KIM, Kwang-Ho; YOUN, Hyoun-Sun; KANG, Yong-Cheol. Short-term load forecasting for special days in anomalous load conditions using neural networks and fuzzy inference method. **IEEE Transactions on Power Systems**. [S. I.], p. 559-565. maio 2000.
- 59 PAPADAKIS, S. E. *et al.* A novel approach to short-term load forecasting using fuzzy neural networks. **IEEE Transactions on Power Systems**. [S.I.], p. 480-492. maio 1998.
- 60 MARVUGLIA, Antonino; MESSINEO, Antonio. Using Recurrent Artificial Neural Networks to Forecast Household Electricity Consumption. In: 2011 2ND INTERNATIONAL CONFERENCE ON ADVANCES IN ENERGY ENGINEERING (ICAEE), 2., 2011, Bangkok, Thailand. **Energy Procedia**. [S. I.]: Elsevier, 2011. v. 14, p. 45-55.
- 61 TIAN, Chujie *et al.* A deep neural network model for short-term load forecast based on long short-term memory network and convolutional neural network. **Energies** **2018**. [S. I.], p. 1-13. 14 dez. 2018.
- 62 WILMS, Henning; CUPELLI, Marco; MONTI, Antonello. Combining auto-regression with exogenous variables in sequence-to-sequence recurrent neural networks for short-term load forecasting. In: 2018 IEEE 16TH INTERNATIONAL CONFERENCE ON INDUSTRIAL INFORMATICS (INDIN), 16., 2018, Porto, Portugal. **Proceedings [...]**. [S.L.]: IEEE, 2018. p. 673-679.
- 63 TANG, Lingling; YI, Yulin; PENG, Yuexing. An ensemble deep learning model for short-term load forecasting based on ARIMA and LSTM. In: 2019 IEEE INTERNATIONAL CONFERENCE ON COMMUNICATIONS, CONTROL, AND COMPUTING TECHNOLOGIES FOR SMART GRIDS (SMARTGRIDCOMM), 10., 2019, Beijing, China. **Proceedings [...]**. [S.L.]: IEEE, 2019. p. 1-6.
- 64 HE, Wan. Load Forecasting via Deep Neural Networks. In: INTERNATIONAL CONFERENCE ON INFORMATION TECHNOLOGY AND QUANTITATIVE MANAGEMENT, 5., 2017, Nova Delhi, Índia. **Procedia Computer Science**. [S.L.]: Elsevier B.V, 2017. v. 122, p. 308-314.
- 65 BIANCHI, Filippo Maria *et al.* **Recurrent Neural Networks for Short-Term Load Forecasting: an overview and comparative analysis**. [S.I]: Springer, 2017. 72 p.
- 66 N., Siddarameshwara; YELAMALI, Anup; BYAHATTI, Kshitiz. Electricity Short Term Load Forecasting Using Elman Recurrent Neural Network. In: 2010 INTERNATIONAL CONFERENCE ON ADVANCES IN RECENT TECHNOLOGIES IN COMMUNICATION AND COMPUTING (ARTCOM), 2., 2010, Kottayam, India. **Proceedings [...]**. [S.L.]: IEEE, 2010. p. 351-354.

- 67 KHAN, Idris *et al.* Photovoltaic power forecasting based on Elman Neural Network software engineering method. In: IEEE INTERNATIONAL CONFERENCE ON SOFTWARE ENGINEERING AND SERVICE SCIENCE (ICSESS), 8., 2017, Beijing, China. **Proceedings [...]**. [S.L.]: IEEE, 2017. p. 747-750.
- 68 WANG, Yixing *et al.* Short-term load forecasting with multi-source data using gated recurrent unit neural networks. **Energies** **2018**. [S. I.], p. 1-19. maio 2018. Disponível em: <https://doi.org/10.3390/en11051138>. Acesso em: 10 jan. 2021.
- 69 BOUKTIF, Salah *et al.* Optimal deep learning LSTM model for electric load forecasting using feature selection and genetic algorithm: comparison with machine learning approaches. **Energies** **2018**. [S. I.], p. 1-20. jun. 2018.
- 70 HOCHREITER, Sepp; SCHMIDHUBER, Jürgen. Long Short-Term Memory. **Neural Computation**. [S. I.], p. 1735-1780. 15 nov. 1997.
- 71 KANG, Eugene. **Long Short-Term Memory (LSTM): concept**. Concept. 2017. Disponível em: <https://medium.com/@kangeugine/long-short-term-memory-lstm-concept-cb3283934359#:~:text=LSTM%20is%20a%20recurrent%20neural,time%20lags%20of%20unknown%20duration.&text=RNN%20cell%20takes%20in%20two,and%20observation%20at%20time%20%3D%20t..> Acesso em: 02 jan. 2021.
- 72 RUSSELL, Stuart J.; NORVIG, Peter. **Artificial intelligence: a modern approach**. Englewood Cliffs, EUA: Pearson Prentice Hall, 1995. 946 p.