

Hierarchical Short Term Load Forecasting Considering Weighting by Meteorological Region

I. C. Figueiró, A. R. Abaide, N. K. Neto, L.N. F. Silva, L. L. C dos Santos

Abstract— Activities related to the planning and operation of power systems use as premise the load forecasting, which is responsible to provide a load estimative for a given horizon that assists mainly in the electroenergetic operation of a power system. The hierarchical short-term load forecasting becomes an approach used for this purpose, where the overall forecast is performed through system partition in smaller macro regions, and soon after, is aggregated to compose a global forecast. Then, this paper presents a hierarchical short-term forecasting approach for macro-regions, with the main contribution being the proposal of an indicator that represents the Average Consumption per Meteorological Region (CERM), to be used as weighting of each Meteorological Station (EM) as their importance for the total demand of the macro-region. This indicator is used to weight the temperature variable and then, is incorporated into a Multi-layer perceptron ANN model for the load forecasting on the horizon of 7 days ahead with hourly and daily discretization. The results showed higher average performance of the variable CERM in relation to the other combination performed, and the best results were used to compose the prediction of the Multi-Region (MTR). Finally, the proposed model presented a superior performance compared to an basis aggregate model for MTR, which shows the efficiency of the proposed methodology.

Index Terms— Artificial Neural Network, Hierarchical Short Term Load Forecasting; Multi Region Forecasting, Meteorological variables weighting.

I. INTRODUÇÃO

O principal objetivo da operação e planejamento dos sistemas de potência é utilizar os recursos de forma eficiente, mantendo o sistema seguro e confiável. Para isso, a previsão de carga torna-se um componente essencial para garantir a operação ótima e econômica de um sistema de potência de grande porte[1]. Os estudos de previsão de carga estão estritamente relacionados ao horizonte de previsão, que por sua vez são definidos a partir dos objetivos pelo qual a previsão será aplicada.

Artigo submetido em 13 de abril de 2023.

I. C. Figueiró, F. A. é professor na Universidade Regional do Alto Uruguai e das Missões – URI Santo Ângelo, Engenharia Elétrica (e-mail: iuricastroff@san.uri.br).

A. R. Abaide. é professora na Universidade Federal de Santa Maria (UFSM), (e-mail: alzenira@ufsm.br).

N. K. Neto. é professor na Universidade Federal de Santa Maria (UFSM – Campus Cachoeira do Sul), (e-mail: nelson.knak@ufsm.br).

L. N. F da Silva. é aluno de pós-Doutorado na Universidade Federal de Santa Maria (UFSM), (e-mail: leo.nogueirafs@gmail.com).

L. L. C. dos Santos. é professora na Universidade Federal de Santa Maria (UFSM– Campus Cachoeira do Sul), (e-mail: laura.callai.santos@gmail.com).

A definição desses horizontes é fundamental para estabelecer as principais influências das variáveis externas a carga, garantindo a assertividade da previsão [2]. Estes horizontes podem ser divididos em curtíssimo, curto, médio e longo prazo [3], [4].

Na previsão de curto prazo, na qual se insere o assunto deste artigo, o horizonte de previsão é aplicado, por exemplo, para estudos de planejamento da operação diária eletroenergética, a fim de aumentar a segurança do suprimento de energia e diminuir os custos de geração do parque hidrotérmico-eólico.

Dentro deste contexto, a previsão de carga hierárquica vem ganhando espaço devido a sua complexidade e importância para operação e tomada de decisões em sistemas de potência que abrangem grandes áreas geográficas [5]–[8]. Neste tipo de problema, a assertividade do modelo torna-se requisito para despacho eficiente e econômico de geradores e a redução de custos de operação e manutenção (O&M) de um sistema de potência, como discutido em [9].

A previsão de carga hierárquica consiste em particionar uma grande região e realizar a previsão individual para sub-regiões menores, e logo após, agregá-las em um modelo de previsão global. Esta partição visa a redução da granularidade das características de uma região, quanto a diversidade meteorológica existente em sua área territorial. Esta diversidade, representada principalmente pela variável temperatura, torna a previsão de carga hierárquica um desafio já que se trata da variável externa que possui maior influência sobre a demanda, no horizonte de curto prazo [10]–[12].

Neste contexto, este artigo apresenta uma metodologia de previsão hierárquica de curto prazo para macrorregiões (MRs), tendo como principal contribuição a proposta de um indicador estatístico que representa o consumo médio por região meteorológica (CERM), a ser utilizado como forma de ponderação de cada Estação Meteorológica (EM) quanto a sua importância para a demanda total da macrorregião. A variável temperatura ponderada é então incorporado como entrada em um modelo de Rede Neural do tipo *Perceptron* Multicamadas (MLP) para um horizonte de previsão de 7 dias a frente.

II. PREVISÃO DE CARGA HIERÁRQUICA

A previsão de carga hierárquica vem ganhando espaço devido a sua complexidade e importância para operação e tomada de decisões em sistemas de potência que abrangem grandes áreas geográficas [5], [6], [13]. Este tipo de previsão possui duas abordagens em relação ao nível de agregação das previsões: *Bottom-up* e *Top-Down*. A primeira refere-se a uma

metodologia em que a previsão é realizada individualmente e os resultados são agregados para formar a previsão global do sistema. Já na metodologia *Top-Down*, a previsão de carga é realizada no nível mais alto de hierarquia, e logo após, a previsão é desagregada de acordo com algum critério estabelecido [14], [15].

Neste artigo, a previsão hierárquica é denominada como multirregional e é realizada por meio da partição da multirregião (MTR) em regiões menores, denominadas de Macrorregiões (MRs) utilizando a metodologia *Bottom-up*. Este tipo de abordagem metodológica mostra-se como uma tendência para a resolução de problemas de previsão de curto prazo pra grandes regiões, como observado nos trabalhos de [16]–[20].

Em [21], a previsão de carga de curto prazo é abordada em um modelo *bottom-up* para grandes áreas geográficas. Neste sentido, o autor desenvolve uma metodologia de previsão de curto prazo para multirregiões utilizando Redes Neurais Artificiais MLP *Feedforward* de 3 camadas, particionando o sistema existente em 24 regiões, o que, de acordo com os autores, foi decisivo para diminuição do erro de previsão comparados a um modelo agregado.

Em seu trabalho posterior, [16] propõe um sistema predictor, baseado em Máquinas de Vetores de Suporte (SVM), analisando a partição e/ou combinação ótima de regiões do sistema da concessionária em análise para a previsão de carga, considerando tanto características meteorológicas quanto de demanda. De acordo com os autores, houve uma diminuição dos erros, à medida que se particionava o sistema em regiões menores. Esta mesma abordagem é realizada em [22], na qual os autores realizam a partição do sistema em macrorregiões para a realização da previsão global. Além disso, reafirmam a necessidade de um modelo desagregado para obtenção de menores erros de previsão.

Quando a previsão é realizada para uma grande região geográfica ou multirregião (MTR), normalmente tem-se a partição em macrorregiões de consumo, ou seja, a previsão é realizada individualmente para cada macrorregião considerando as respectivas variáveis meteorológicas da região em análise. No entanto, deve-se estabelecer quantas e quais Estações Meteorológicas (EMs) devem ser consideradas nesta macrorregião.

Este desafio é abordado em [23] em que é realizado um estudo de caso com a comparação entre diversas formas de representar a variação de temperatura. A comparação foi realizada através da realização da média aritmética entre 5 estações meteorológicas. Os resultados demonstraram que houve redução no MAPE em relação a utilização de apenas uma estação meteorológica para representar todo o território de *New England*.

Na sequência [24] abordam o mesmo problema estabelecendo uma metodologia para seleção das estações que melhor representam a carga no estado da Carolina do Norte. De acordo com os autores, algumas premissas são importantes na seleção das estações, como histórico e consistência dos dados, quão perto estará a estação do território de análise e a proximidade em relação a outras estações. Por exemplo, estações com pouco histórico de dados são ignoradas e retiradas da análise.

No trabalho de [25], a previsão de carga para macrorregiões é realizada para o Subsistema Sul do Sistema Elétrico Brasileiro. Neste trabalho, as estações meteorológicas (EM) são selecionadas de acordo com as áreas de concessão de cada distribuidora e ponderadas em relação ao número de habitantes abrangidos por cada EM. Ainda, em seu trabalho posterior, é realizado a análise de autocorrelação de dados para determinação das *lags* mais representativas para o modelo, além da análise variáveis como temperatura, conforto térmico e umidade [23]. De acordo com os autores, as variáveis Temperatura e Sensação térmica apresentaram bom desempenho em comparação a umidade.

Dentro deste contexto da previsão de carga para multirregiões (MTRs), é importante destacar que, apesar da tendência de partição da MTR em regiões menores para resolução do problema de previsão de carga, levando em consideração critérios como carga ou dimensões territoriais, a temperatura é tratada como uma informação única, isolada e representativa daquela região. Por exemplo, nos trabalhos de [24] e [22] é considerada apenas média aritmética entre as EMs presentes na região. Já no trabalho de [19] é realizada uma ponderação considerando o número de habitantes, mas não se observa uma relação direta com a demanda. Neste artigo, a principal contribuição é a proposição inovadora de uma variável que considera o número de unidades consumidoras (UCs) abrangidas pela EM e um índice estatístico relacionando o número de UCs e o consumo de energia médio na região abrangida pela EM. Ressalta-se que este tipo de abordagem não é apresentado nos demais trabalhos na literatura, e que servirá como índice para ponderação da variável temperatura e inserção no modelo de previsão de Redes Neurais.

III. METODOLOGIA PROPOSTA

A metodologia proposta baseia-se em 4 etapas fundamentais. Na primeira etapa, tem-se o processo de desagregação da MTR, onde dados históricos de demanda são desagregados por Macrorregiões de Consumo (MR k), definidos pelos número de agentes de distribuição pertencentes MTR. A divisão da MTR em regiões é mostrada na Fig. 1.

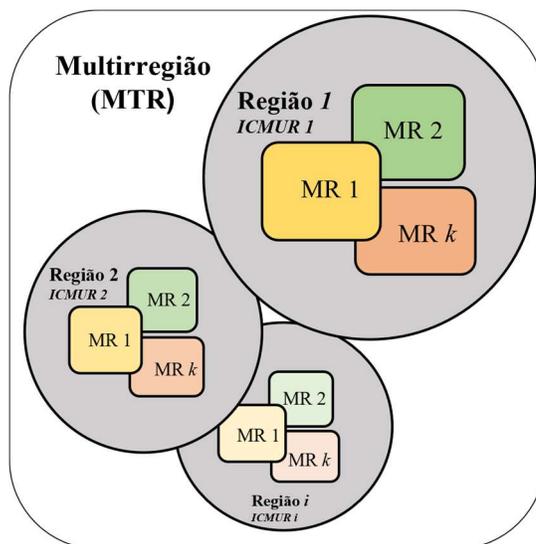


Fig. 1. Conjunto de análise da MTR, Regiões e MRs.

Na Fig. 1 o universo de análise é a MTR, as Regiões 1, 2 e i , representam i conjuntos pertencentes a MTR. Dentro do conjunto Regiões, há ainda k subconjuntos, que neste caso são as MRs, mencionadas na etapa de desagregação da MTR. O objetivo desta desagregação é obter um previsor individual para cada MR k , e logo após, realizar a agregação para a previsão da MTR. Espera-se, assim, um melhor gerenciamento das relações entre carga e temperatura para o processamento da previsão de carga.

Na segunda etapa tem-se o processo de ponderação. Nesta etapa as variáveis meteorológicas de cada EM p devem ser ponderadas antes de serem normalizadas e utilizadas pelo modelo de previsão como uma única variável resultante. Para este processo, é proposta a variável Consumo de Energia por Região Meteorológica (CERM), o qual representa a contribuição de cada EM p dentro da MR k individual.

Na terceira etapa tem-se a seleção das entradas para o modelo de previsão. Estes dados então passam por uma fase de treinamento, com o ajuste de pesos e neurônios do modelo de Rede Neural Artificial (RNA) *Perceptron* de Multicamadas de acordo com estudos de sensibilidade realizados. Por fim, na etapa de resultados, é realizada a previsão Multirregional horária e semanal por meio da agregação das previsões individuais de cada MR k . Apesar do foco ser a previsão de multirregiões, esta metodologia pode fornecer resultados de previsões individuais, que podem ser utilizadas como subsídio para diversos estudos dentro de cada macrorregião.

A. Ponderação das Variáveis Meteorológicas

O processo de ponderação é mostrado na Fig. 2. O foco principal deste fluxograma é a determinação do índice de Consumo de Energia por Região Meteorológica (CERM), a qual representa a contribuição deste artigo. Para a obtenção do índice CERM, primeiramente deve-se calcular Índice de Consumo Mensal por Unidade Consumidora Regional (ICMUR).

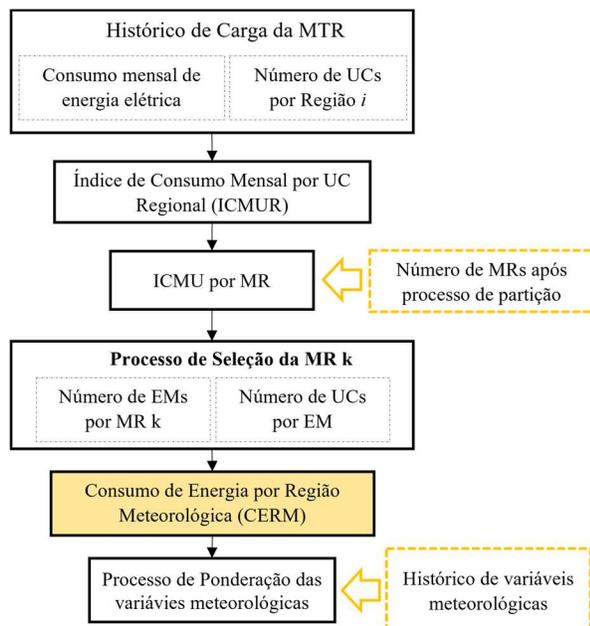


Fig. 2. Processo de ponderação das variáveis meteorológicas.

Este índice é calculado com base nos dados estatísticos de consumo médio mensal e número de unidades consumidoras de cada Região i pertencente a MTR. Neste caso, estes dados foram obtidos do Anuário Estatístico de Energia Elétrica elaborado pela Empresa de Pesquisa Energética (EPE) no ano de 2016, e segregados por regiões geográficas e Estados [26]. Os resultados de consumo são disponibilizados anualmente para consulta, o que permite a atualização dos dados para ponderação das variáveis meteorológicas do modelo ano a ano. O índice ICMUR é calculado em (1).

$$ICMUR_i = \frac{CM_i}{NUCS_i} \quad (1)$$

em que CM_i representa o consumo mensal em GWh para a região i pertencente a MTR, $NUCS_i$ representa o número de unidades consumidoras, dado em milhões, pertencentes a região i de análise. Como resultado tem-se o índice $ICMUR_i$ calculado para cada região i da MTR dado em kWh/(UC.mês). Observa-se que cada região i receberá um indicador regional (ICMUR) de acordo com a energia consumida e número de consumidores.

Este processo é realizado como forma de aproximação para obtenção deste mesmo índice por MRs. Neste sentido de aproximação poderá haver dois cenários, um no qual a Região é formada por uma única MR, e outro por n MRs. Em ambos os casos as MRs assumem o ICMUR como ICMU. Desta forma, cria-se o índice ICMU por macrorregião, o qual representa o consumo mensal por unidade consumidora da MR, também dado em kWh/(UC.mês).

Como em cada MR pode-se ter inúmeras EMs, e conseqüentemente, um grande volume de dados meteorológicos disponíveis, deve-se identificar o número de EMs a serem selecionadas para o estudo. Neste artigo, foram selecionadas todas as EMs disponíveis de cada MR e com dados válidos no período considerado. Em (2) é obtido o peso final para ponderação das EMs, denominado de Consumo de Energia por Região Meteorológica (CERM).

$$CERM_{EM(p,k)} = ICMU \times UC_{EM(p,k)} \quad (2)$$

onde $CERM_{EM(p,k)}$ representa o peso dado a EM p pertencente a MR k dado em MWh/mês; ICMU é fixo e varia de acordo com a MR onde está situado a EM p . Por fim, a variável $UC_{EM(p,k)}$ representa o número de unidades consumidoras abrangidas pela EM p da MR k , dado que fornece uma estimativa de consumo de energia da região de abrangência da EM. Por critério, adotou-se como região de abrangência, o próprio município de localização da EM.

Em (3) é realizado o processo final de ponderação. Neste artigo considerou-se apenas a variável temperatura para ponderação. No entanto, ressalta-se que esta ponderação poderá ser aplicada para qualquer variável meteorológica.

$$Tp_{(h)} = \frac{\sum_{p=1}^n CERM_{(p,k)} T_{EM(p,h)}}{\sum_{p=1}^n CERM_{(p,k)}} \quad (3)$$

em que $Tp_{(h)}$ representa a série ponderada final para a variável temperatura (T) na hora (h) para a MR k . A variável $T_{EM(p,h)}$

representa a variável T de cada EM p a ser ponderada hora (h), com o respectivo peso $CERM_{(p,k)}$. O índice (p) depende do número de EMs selecionadas de cada MR k . Esta média ponderada é realizada para toda a série histórica de temperatura utilizada para treinamento e operação do modelo.

B. Modelo de Previsão e Variáveis de Entrada

Como observado em [27] um grande número de técnicas vem sendo empregadas para previsão de carga de curto prazo. No entanto, técnicas de Inteligência artificial merecem destaque devido as suas potencialidades quanto a modelagem da carga. Dentre os métodos de IA aplicados atualmente estão as Redes Neurais Artificiais (RNAs), lógica *Fuzzy*, sistemas adaptativos Neuro-*Fuzzy*, Algoritmos Genéticos (AG) e Máquina de Vetores de Suporte (SVM) [5], [28]–[30].

Como técnica escolhida adotou-se o modelo de rede neural artificial (RNA) do tipo *Perceptron* Multicamadas (MLP) *feed-forward* [13]. Ainda, em [31] os autores destacam que a capacidade de generalizar e capturar relações não-lineares complexas, torna as RNAs muito atrativas para problemas de previsão de carga.

As redes MLP utilizadas nos modelos de previsão deste artigo, possuem uma camada de entrada com um número de neurônios que corresponde ao número de variáveis entradas do modelo. Além disso, possui uma camada intermediária que utiliza a função sigmoide logística, e uma camada de saída, que representa a variável a ser prevista, que utiliza a função linear de ativação [32].

Para o processo de treinamento e inicialização de rede adotou-se como partição um conjunto de 75% dos dados para o treinamento da rede, onde o mesmo é realizado por Batch. Para a validação utilizou-se 25%, avaliando o erro médio quadrático do resultado. Por fim, o conjunto de testes corresponde a dados que ainda não foram apresentados a rede de forma a analisar sua capacidade de generalização.

O processo de treinamento para cada MR k considera uma faixa de variação entre 10 a 50 neurônios na camada intermediária. Para cada configuração da camada intermediária, é realizado o processo de treinamento, verificação e testes por n rodadas de treinamento e testes. Definiu-se inicialmente 30 iterações para cada i neurônios da camada intermediária.

Conforme resultados da simulação para cada rodada de treinamento e testes, é verificada a eficiência da previsão utilizando o Erro Percentual Absoluto Médio (MAPE) entre as cargas observadas x_j e as estimadas na previsão y_j [33]. O MAPE é definido em (4).

$$MAPE(\%) = \frac{100}{N} \sum_{j=1}^N \frac{|x_j - y_j|}{x_j} \quad (4)$$

onde N depende do horizonte de previsão (MAPE diário, no caso de $N=24$, ou MAPE semanal para $N=168$). Como se trata de previsão de curto prazo, considerou-se um horizonte máximo de uma semana a frente com discretização horária e diária.

Para cada roda de treinamento e testes é armazenado MAPE mínimo até que seja atingido o número de neurônios máximo especificado. Ao se atingir o número máximo de neurônios, a

RNA treinada, cujo o resultado de simulação obtiver o menor MAPE será considerado para a MR k . Após este procedimentos, são calculadas os demais indicadores de performance em (5) e (6).

$$MAE = \frac{1}{N} \sum_{j=1}^N |x_j - y_j| \quad (5)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{j=1}^N (x_j - y_j)^2} \quad (6)$$

em que MAE (*Mean Absolut Error*) representa a média absoluta dos erros e RMSE (*Root Mean Squared Error*) a raiz quadrática dos erros médios. Ambas as métricas possuem escala de acordo com os dados de carga (MW) e são amplamente utilizadas na literatura [13].

O padrão de entrada que será utilizado para cada MR obedecerá ao mostrado na Tabela I.

TABELA I
VARIÁVEIS DE ENTRADA

| Variáveis de Entrada | Descrição |
|-----------------------------------|--|
| Mês | Código referente ao mês |
| Hora | Código referente a hora |
| Dia | Código referente ao dia |
| D(t-1, t-24, t-48, t-168, t-336)) | Demanda com <i>lag</i> de 1, 24, 48, 168 e 336 horas em relação ao dia a ser previsto. |
| Tp(t-1, t-2, t-3) | Temperatura com <i>lag</i> de 1, 2 e 3 horas em relação ao dia a ser previsto |

Destaca-se que para a determinação das *lags* mais representativas para os modelos de previsão foram realizados estudos de Autocorrelação conforme [34], caracterizado pela equação (7).

$$r_k = r(X_t, X_{t-k}) = \frac{\sum_{t=k+1}^n (X_t - \bar{X}) \cdot (X_{t-k} - \bar{X})}{\sum_{t=1}^n (X_t - \bar{X})^2} \quad (7)$$

em que X_t representa o valor observado na hora (h), \bar{X} a média de toda a série de dados analisada (carga) e r_k o coeficiente de autocorrelação que mede o grau de correlação entre observações separadas por k atrasos

C. Modelo Global de Previsão de Carga

A obtenção da previsão para a MTR é realizada por meio da agregação das previsões individuais de cada MR k que resultaram em menor MAPE Global. Antes de realizar a agregação os dados são denormalizados e então agregadas, conforme (8).

$$PMTR_{(j)} = \sum_{k=1,2,3,\dots}^{k \text{ máx}} PMR_{(k,h)} \quad (8)$$

em que $PMTR_{(j)}$ representa a previsão multiregional horária para a MTR j para um horizonte N de previsão. A PMTR leva em consideração a soma das previsões individuais de cada MR k , denominada de $PMR_{(k,h)}$. Ressalta-se que além desta metodologia fornecer a previsão multiregional agregada, ainda pode-se obter a previsão individual de cada MR pertencentes a

MTR, podendo auxiliar em diversas atividades de planejamento dentro de cada MR. Este processo por ser repetido a outras MTRs j , que possuem k MRs.

IV. RESULTADOS E DISCUSSÕES

A. Premissas para o Estudo de Caso

A metodologia proposta neste artigo é avaliada para a MTR Sul (Subsistema Sul), pertencente ao Sistema Interligado Nacional Brasileiro (SIN). Assim como os demais subsistemas do SIN, o Subsistema Sul apresenta grande diversidade meteorológica devido a sua extensão territorial. A MTR Sul é composta por 5 MRs, definidas pelas áreas de concessão dos agentes de distribuição de energia. A Tabela II mostra algumas características das MRs pertencente a MTR Sul.

TABELA II
CARACTERÍSTICAS DA MTR SUL

| Parâmetro | MR 1 | MR 2 | MR 3 | MR 4 | MR 5 |
|--------------------------------|-------|------|------|------|------|
| Região | 1 | 2 | 3 | 3 | 3 |
| Amplitude Térmica (Inv. - °C) | 27,2 | 26,5 | 30,4 | 32,4 | 29,3 |
| Amplitude Térmica (Verão - °C) | 23 | 23,1 | 27,9 | 30,3 | 27,3 |
| D _{min} (MW) | 2071 | 1456 | 568 | 567 | 1456 |
| D _{max} (MW) | 5127 | 4127 | 1937 | 1967 | 1920 |
| Área (km ²) | 180,0 | 95,3 | 90,7 | 99,5 | 73,6 |
| NUC (milhões) | 4,4 | 2,8 | 1,4 | 1,3 | 1,6 |
| EMs | 21 | 19 | 14 | 9 | 10 |

Observa-se que as MRs possuem características diferentes quanto a demandas máximas registradas, extensão territorial, número de consumidores e amplitude térmica. Essa grande variação sazonal influencia diretamente nas demandas registradas, assim como no perfil de carga de cada MR. Além disso, o número de EMs também foi selecionado para utilização na etapa de ponderação da variável temperatura.

Como forma de avaliar os modelos de previsão para cada MR, considerou-se a partição do histórico em 2 conjuntos de treinamento: o primeiro (C1) compreendido entre 1º de junho de 2012 a 8 de julho de 2013, e o segundo (C2), compreendido entre 1º de outubro de 2012 e 4 de novembro de 2013. Adotou-se esta partição de modo a avaliar a robustez dos modelos em períodos diferentes de demanda e temperatura. Os testes são realizados para previsão do período de 9 de julho a 5 de agosto de 2013 (C1) e para o período de 5 de novembro à 2 de dezembro de 2013 (C2). Ressalta-se que ambos os conjuntos possuem características semelhantes quanto a dias úteis, fins de semana e feriados.

Os dados de demanda são oriundos da base histórica de operação do Operador Nacional do Sistema Elétrico (ONS) e os dados de temperatura foram obtidos através do histórico de leitura de Estações Automáticas Meteorológicas (EMs) pertencentes ao Instituto Nacional de Meteorologia [35].

Com base na metodologia descrita, a MTR Sul é particionada e as MRs são selecionadas para a previsão de curto prazo, tendo

os dados de demanda importados do banco de dados e normalizados. Na Etapa de Ponderação, primeiramente é calculado, conforme (1), o índice ICMUR por Região, mostrado

TABELA III
ICMU POR REGIÃO

| Regiões | Consumo mensal (GWh/mês) | Número de UCs (milhões) | ICMUR kWh/(UC.mês) |
|----------|--------------------------|-------------------------|--------------------|
| Região 1 | 2.478,6 | 4.650,487 | 532,97 |
| Região 2 | 1.920,8 | 7.121,656 | 269,70 |
| Região 3 | 2.435,0 | 6.020,604 | 404,44 |

na Tabela III.

Após o cálculo do ICMUR por região, obtêm-se o índice ICMU de acordo com a região onde cada MR se encontra. Na Tabela II é mostrada a região a qual pertence cada MR. Por fim calcula-se o índice CERM para cada EM de acordo com (2). Este índice é utilizado então para a ponderação de cada EM de acordo com (3).

Como forma de avaliar os resultados de previsão, foram realizadas as seguintes análises de sensibilidade: um modelo de previsão com temperatura ponderada proposta (S1) e outro que considera somente a demanda agregada de cada macrorregião (S2). Com base no treinamento realizado, a Tabela IV mostra os resultados de previsão para cada MR quanto ao MAPE

TABELA IV
RESULTADOS MRS PARA C1 E C2

| Conj. | Testes | MAPE (%) | MR1 | MR2 | MR3 | MR4 | MR5 | |
|-------|--------|----------|------|------|------|------|------|------|
| C1 | S1 | DU | 2,33 | 2,55 | 2,31 | 2,74 | 2,51 | |
| | | DNU | 3,05 | 4,26 | 3,01 | 3,91 | 4,06 | |
| | S2 | DU | 2,12 | 2,35 | 2,35 | 2,80 | 2,53 | |
| | | DNU | 3,20 | 4,11 | 2,98 | 3,55 | 4,1 | |
| | C2 | S1 | DU | 2,09 | 3,03 | 2,36 | 2,65 | 2,05 |
| | | | DNU | 3,38 | 3,53 | 2,84 | 4,14 | 3,86 |
| S2 | | Feriado | 4,79 | 4,21 | 5,78 | 7,19 | 5,84 | |
| | | DU | 2,20 | 3,30 | 2,62 | 2,83 | 2,09 | |
| | S2 | DNU | 3,10 | 3,79 | 3,07 | 4,16 | 3,90 | |
| | | Feriado | 5,75 | 5,16 | 5,85 | 7,48 | 6,42 | |

médio para dias úteis (DU), não úteis (DNU) e feriados.

Pode-se observar na Tabela IV que o processo de ponderação proposto neste artigo teve uma maior eficiência no período C2 (Primavera) do que em C1 (Inverno). No caso de C1, nota-se um desempenho médio superior de S2 levando-se em consideração dias úteis e não úteis. Este resultado pode estar relacionado a uma maior ou menor correlação entre temperatura e demanda em cada período de teste[36]. Como critério de agregação adotou-se para C1 os resultados de S2.

B. Análise de Resultados da MTR Sul

Após a previsão individual de cada MR, realiza-se a etapa de agregação para compor a previsão global de carga da MTR Sul. Como o objetivo deste artigo é a realização da previsão de carga de uma MTR, adotou-se como critério de agregação das previsões, conforme (8), a variável com melhor performance em cada período de teste. Neste sentido, a variável temperatura ponderada foi considerada somente para C2. Como critério de comparação do modelo proposto, elaborou-se um modelo de previsão considerando a demanda agregada total da MTR Sul,

denominado Modelo de Previsão Agregado (MP). A elaboração deste modelo seguiu as mesmas premissas de treinamento propostos e com a mesma janela de treinamento e mesma técnica de RNA. O padrão de entrada de MP utiliza somente dados de demanda normalizados de toda MTR Sul. Os resultados oriundos deste modelo são descritos como $MAPE_{MP1}$ e $MAPE_{MP2}$, correspondendo aos resultados para os Conjuntos 1 e 2, respectivamente. A Tabela V mostra o desempenho quanto ao MAPE médio para cada dia da semana dos Conjuntos

TABELA V
SÍNTESE DOS RESULTADOS DA PREVISÃO GLOBAL

| | $MAPE_{C1}(\%)$ | $MAPE_{MP1}(\%)$ | $MAPE_{C2}(\%)$ | $MAPE_{MP2}(\%)$ |
|-----------|-----------------|------------------|-----------------|------------------|
| Ter | 0,71 | 1,19 | 0,89 | 1,33 |
| Qua | 0,70 | 1,17 | 0,86 | 1,34 |
| Qui | 0,72 | 1,20 | 0,84 | 1,16 |
| Sex | 0,73 | 1,06 | 0,82 | 1,32 |
| Sáb | 0,79 | 1,02 | 0,66 | 1,07 |
| Dom | 0,88 | 1,29 | 0,87 | 1,27 |
| Seg | 0,77 | 1,14 | 0,88 | 1,26 |
| Med | 0,76 | 1,15 | 0,83 | 1,25 |
| Feriado | - | - | 1,28 | 2,60 |
| MAE (MW) | 74,41 | 115,05 | 86,26 | 130,84 |
| RMSE (MW) | 98,59 | 151,22 | 109,84 | 169,71 |

1 e 2, assim como o MAE e RMSE médio para cada conjunto.

Percebe-se na Tabela V que a metodologia proposta apresentou um MAPE médio superior em relação ao Modelo MP para ambos os conjuntos de testes. Por exemplo, o MAPE médio encontrado entre as quintas-feiras do Conjunto 1 foi de 0,72% e 1,20%, para o modelo proposto e MP, respectivamente. Para o feriado, a metodologia proposta obteve um MAPE de 1,28% em relação 2,60% obtido pelo MP. Ainda, de acordo com a Tabela V, observa-se que o modelo proposto apresentou uma média de erros (MAE e RMSE) inferior ao modelo MP. Esta dispersão de erros é evidenciada na Fig. 3 onde observa-se uma maior dispersão dos erros para o Modelo MP em relação ao proposto.

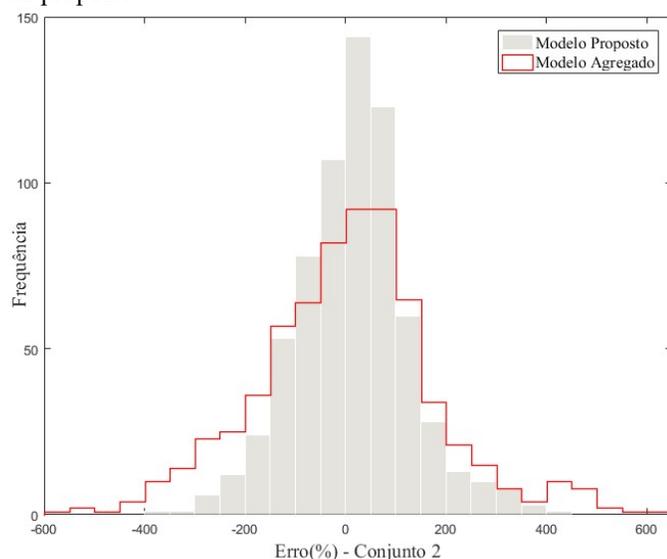


Fig. 3. Dispersão de erros para o Conjunto 2.

Por fim, na Tabela VI é mostrado a concentração de erros positivos (subprevisão) e negativos (sobrepresiação) em relação a curva real observada para o Conjunto 2.

TABELA VI
DISPERSÃO DE ERROS PARA O CONJUNTO 2

| Tipo de Erro | Modelo Proposto | | Modelo Agregado MP | |
|--------------------|-----------------|---------|--------------------|---------|
| | Total | <100 MW | Total | <100 MW |
| Subprevisão (+) | 58% | 68,5% | 52,5% | 52,1% |
| Sobrepresiação (-) | 42% | 65,6% | 47,5% | 45,8% |
| Total | 100% | - | 100% | - |

Observa-se na Tabela VI, que a concentração de erros de subprevisão para o conjunto C2 é maior no modelo proposto (58%) do que no agregado (52,5%). No entanto, como se observa na Fig. 3 e com base nos erros inferiores a 100MW para o modelo proposto, 68,5% dos erros estão concentrados nesta faixa (0 a 100 MW). Enquanto para o modelo MP, 52,1% dos erros são inferiores a 100 MW. Quanto aos erros de sobrepresiação, o modelo proposto apresenta uma melhor performance geral. Esta informação, associado aos demais resultados apresentados, evidencia a eficiência da metodologia proposta neste artigo, quanto a proposição do processo de ponderação pela variável CERM, além de mostrar a aplicabilidade do modelo considerando a metodologia *Bottom-up* de previsão de carga hierárquica.

V. CONCLUSÕES

Este trabalho apresentou o desenvolvimento de uma metodologia como contribuição para a previsão de carga hierárquica de curto prazo. A abordagem realizada buscou contribuir para a elaboração de modelos para macrorregiões de consumo, onde se tem o desafio de realizar a previsão global de um sistema com grande dimensão territorial e diversidade meteorológica.

Neste sentido, foi proposto o indicador CERM de forma a realizar a ponderação da variável meteorológica temperatura para ser inserido nos modelos de previsão. Esta variável, quando inserida nos modelos de previsão apresentou performance superior para o período C2 (primavera), enquanto, para C1 (primavera), a temperatura ponderada apresentou desempenho inferior.

Com base nos resultados individuais, o modelo proposto é comparado a um modelo de previsão agregado (MP), onde obteve-se um MAPE médio inferior a 1% para C1 e C2, mostrando desempenho superior ao MP. Além disso, quando analisada a dispersão dos erros horários para C2, por exemplo, nota-se uma maior dispersão dos erros no período, evidenciado também pelos resultados de RMSE médio.

Por fim, a abordagem proposta neste artigo se mostrou eficiente no que diz a previsão de carga hierárquica, fornecendo uma estimativa da carga com erro reduzido e podendo ser aplicada com desempenho satisfatório para problemas deste tipo. Além disso, ressalta-se que o sistema de previsão proposto neste artigo, poderá considerar a presença ou não de variáveis meteorológicas, o que dependerá das características e o nível de informação de cada MR. Como trabalhos futuros ressalta-se a possibilidade de se considerar a análise da região de abrangência da EM para obtenção da variável CERM, já que para este estudo considerou-se como critério somente dados do município de localização da EM, o que pode vir a influenciar nos resultados de ponderação e na eficiência do modelo de

previsão. Além disso, como a metodologia de treinamento e testes das RNAs considerou todos os valores possíveis dentro do número de neurônios considerados, sugere-se como trabalhos futuros a possibilidade da aplicação de um método de otimização afim de otimizar o tempo de processamento desta etapa da metodologia.

REFERÊNCIAS

- [1] A. M. Tudose, I. I. Picioroaga, D. O. Sidea, C. Bulac, and V. A. Boicea, "Short-Term Load Forecasting Using Convolutional Neural Networks in COVID-19 Context: The Romanian Case Study," *Energies*, vol. 14, no. 13, p. 4046, Jul. 2021.
- [2] Y. Wi, S. Joo, and K. Song, "Holiday Load Forecasting Using Fuzzy Polynomial Regression With Weather Feature Selection and Adjustment," *IEEE Trans. Power Syst.*, vol. 27, no. 2, pp. 596–603, May 2012.
- [3] M. Q. Raza and A. Khosravi, "A review on artificial intelligence based load demand forecasting techniques for smart grid and buildings," *Renew. Sustain. Energy Rev.*, vol. 50, pp. 1352–1372, Oct. 2015.
- [4] V. Veeramsetty, D. R. Chandra, and S. R. Salkuti, "Short-term electric power load forecasting using factor analysis and long short-term memory for smart cities," *Int. J. Circuit Theory Appl.*, vol. 49, no. 6, pp. 1678–1703, Jun. 2021.
- [5] S. N. Fallah, M. Ganjkhani, S. Shamshirband, and K. wing Chau, "Computational intelligence on short-term load forecasting: A methodological overview," *Energies*, vol. 12, no. 3, 2019.
- [6] X. Sun *et al.*, "An Efficient Approach to Short-Term Load Forecasting at the Distribution Level," pp. 1–12, 2015.
- [7] Y. Sakuma and H. Nishi, "Hierarchical Multiobjective Distributed Deep Learning for Residential Short-Term Electric Load Forecasting," *IEEE Access*, vol. 10, no. June, pp. 69950–69962, 2022.
- [8] B. Auder, J. Cugliari, Y. Goude, and J.-M. Poggi, "Scalable Clustering of Individual Electrical Curves for Profiling and Bottom-Up Forecasting," *Energies*, vol. 11, no. 7, p. 1893, Jul. 2018.
- [9] L. N. Silva, A. R. Abaide, V. G. Negri, and A. G. Dornelles, "Proposal for the Study of Short-Term Load Forecasting Multi-Regional Error Impact in the Operation Planning," *Proc. - 2018 53rd Int. Univ. Power Eng. Conf. UPEC 2018*, pp. 1–6, 2018.
- [10] P. Lusic, K. R. Khalilpour, L. Andrew, and A. Liebman, "Short-term residential load forecasting: Impact of calendar effects and forecast granularity," *Appl. Energy*, vol. 205, no. July, pp. 654–669, 2017.
- [11] J. Vaish, S. S. Datta, and K. Seethalekshmi, "Short Term Load Forecasting using ANN and Ensemble Models Considering Solar Irradiance," in *2020 International Conference on Electrical and Electronics Engineering (ICEE3)*, 2020, no. i, pp. 44–48.
- [12] K. Shahare, A. Mitra, D. Naware, R. Keshri, and H. M. Suryawanshi, "Performance analysis and comparison of various techniques for short-term load forecasting," *Energy Reports*, vol. 9, pp. 799–808, Mar. 2023.
- [13] A. Román-Portabales, M. López-Nores, and J. J. Pazos-Arias, "Systematic Review of Electricity Demand Forecast Using ANN-Based Machine Learning Algorithms," *Sensors*, vol. 21, no. 13, p. 4544, Jul. 2021.
- [14] C. L. P. Pennings and J. van Dalen, "Integrated hierarchical forecasting," *Eur. J. Oper. Res.*, vol. 263, no. 2, pp. 412–418, Dec. 2017.
- [15] T. Hong, "Load Forecasting Case Study," 2015.
- [16] Shu Fan, K. Methaprayoon, and Wei-Jen Lee, "Multiregion Load Forecasting for System With Large Geographical Area," *IEEE Trans. Ind. Appl.*, vol. 45, no. 4, pp. 1452–1459, Jul. 2009.
- [17] W.-C. Chu, Y.-P. Chen, Z.-W. Xu, and W.-J. Lee, "Multiregion Short-Term Load Forecasting in Consideration of HI and Load/Weather Diversity," *IEEE Trans. Ind. Appl.*, vol. 47, no. 1, pp. 232–237, Jan. 2011.
- [18] T. Hong, P. Wang, and L. White, "Weather station selection for electric load forecasting," *Int. J. Forecast.*, vol. 31, no. 2, pp. 286–295, Apr. 2015.
- [19] L. N. Silva, A. R. Abaide, I. C. Figueiro, J. O. Silva, J. Rigodanzo, and J. P. Sausen, "Development of Brazilian multi region short-term load forecasting model considering climate variables weighting in ANN model," in *2017 52nd International Universities Power Engineering Conference (UPEC)*, 2017, pp. 1–6.
- [20] M. Brégère and M. Huard, "Online hierarchical forecasting for power consumption data," *Int. J. Forecast.*, vol. 38, no. 1, pp. 339–351, Jan. 2022.
- [21] S. Fan, K. Methaprayoon, and W. J. Lee, "Short-term Multi-Region Load Forecasting Based on Weather and Load Diversity Analysis," in *2007 39th North American Power Symposium*, 2007, pp. 562–567.
- [22] S. Fan, Y. Wu, W.-J. Lee, and C. Lee, "Comparative study on load forecasting technologies for different geographical distributed loads," in *2011 IEEE Power and Energy Society General Meeting*, 2011, pp. 1–8.
- [23] T. Hong and S. Lai, "When One Size No Longer Fits All – Electric Load Forecasting with a Geographic Hierarchy," 2013.
- [24] T. Hong, P. Wang, and L. White, "Weather station selection for electric load forecasting," *Int. J. Forecast.*, vol. 31, no. 2, pp. 286–295, 2015.
- [25] L. N. Silva, A. R. Abaide, I. C. Figueiro, J. O. Silva, J. Rigodanzo, and J. P. Sausen, "Development of Brazilian multi region short-term load forecasting model considering climate variables weighting in ANN model," in *2017 52nd International Universities Power Engineering Conference (UPEC)*, 2017, vol. 2017-Janua, pp. 1–6.
- [26] Ministério de Minas e Energia, "Anuário Estatístico de Energia Elétrica 2016." 2016.
- [27] S. Fallah, M. Ganjkhani, S. Shamshirband, and K. Chau, "Computational Intelligence on Short-Term Load Forecasting: A Methodological Overview," *Energies*, vol. 12, no. 3, p. 393, Jan. 2019.
- [28] R. Mamlook, O. Badran, and E. Abdulhadi, "A fuzzy inference model for short-term load forecasting," *Energy Policy*, vol. 37, no. 4, pp. 1239–1248, Apr. 2009.
- [29] L. Suganthi and A. a. Samuel, "Energy models for demand forecasting—A review," *Renew. Sustain. Energy Rev.*, vol. 16, no. 2, pp. 1223–1240, Feb. 2012.
- [30] K. Zor, O. Timur, and A. Teke, "A state-of-the-art review of artificial intelligence techniques for short-term electric load forecasting," in *2017 6th International Youth Conference on Energy (IYCE)*, 2017, pp. 1–7.
- [31] T. Ahmad and H. Chen, "Deep learning for multi-scale smart energy forecasting," *Energy*, 2019.
- [32] S. Haykin, *Redes neurais artificiais: princípios e prática*, 2ª Edição. Porto Alegre: Tradução Paulo Martins Engel., 2001.
- [33] M. Salgado, "Sistema de Suporte à Decisão para Análise e Previsão de Carga por Barramento," Universidade Estadual de Campinas, 2009.
- [34] I. Koprinska, M. Rana, and V. G. Agelidis, "Correlation and instance based feature selection for electricity load forecasting," *Knowledge-Based Syst.*, vol. 82, pp. 29–40, Jul. 2015.
- [35] INMET, "Instituto Nacional de Meteorologia," 2017. [Online]. Available: <http://www.inmet.gov.br/portal/index.php?r=estacoes/estacoesautomaticas>.
- [36] L. N. Silva, A. R. Abaide, V. G. Negri, M. Capeletti, and L. F. Lopes, "Impact Evaluation of Feature Selection to Short-Term Load Forecasting Models considering Weather Inputs and Load History," in *2019 54th International Universities Power Engineering Conference (UPEC)*, 2019, pp. 1–6.



Iuri Castro Figueiro is graduated in Electrical Engineering (2011) from Universidade Federal do Pampa (UNIPAMPA) and master in electrical engineering with emphasis on energy systems (2013) from Universidade Federal de Santa Maria (UFSM). He is currently a professor at the Universidade Regional Integrada do Alto Uruguai e das Missões, campus Santo Ângelo (URI Santo Ângelo) and PhD in the graduate program in Electrical Engineering, Center of Excellence in Energy and Power Systems (CEESP). He has

experience in electrical engineering with emphasis on power systems.



Alzenira da Rosa Abaide is a professor in the Department of Electromechanics and Power Systems at the Federal University of Santa Maria (UFSM). She earned a PhD in electrical engineering from UFSM in 2005. She completed her bachelor's and master's degrees at UFSM. She coordinated the electrical engineering course for 10 years. She is a PQ (Research Productivity) at

CNPq (National Council for Scientific and Technological Development) and was associate editor of IEEE Latin America Transactions. She works on research and development projects with companies, currently coordinating three R&D projects. She advises doctoral and master's students in the Graduate Program in Electrical Engineering at UFSM, and participates in the Center of Excellence in Energy and Power System.



Nelson Knak Neto is a professor at the Federal University of Santa Maria. He holds bachelor's, master's, and doctorate degrees in electrical engineering from the Federal University of Santa Maria. He was a PhD Student Guest at the Institute for Systems and Computer Engineering, Technology and Science, Porto, Portugal. His research interests are planning and operation of

distribution systems, reliability, distributed energy resources, electric mobility and artificial intelligence applied to power systems.



Leonardo Nogueira Fontoura da Silva is a Postdoctoral Researcher (2023-now) working at the Center of Excellence in Energy and Power Systems (CEESP), related to the Federal University of Santa Maria, Brazil. His interests include Power Systems planning and reliability, Load Forecasting, Smart Grids, Artificial Intelligence, Optimization Methods,

Distributed Energy Resources, and Electric Vehicles.



Laura Lisiane Callai dos Santos is a professor at the Federal University of Santa Maria. She is graduated in Electrical Engineering (2012) from Universidade Regional do Noroeste do Estado do Rio Grande do Sul. She holds master's and doctorate degrees in electrical engineering from the Federal University of Santa Maria. His research interests are planning and

operation of distribution systems, reliability and distributed energy resources.