

Previsão de Carga de Curto Prazo para grandes áreas geográficas considerando ponderação por Região Meteorológica

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

*UFMS – Universidade Federal de Santa Maria, RS, Brasil.
(Tel: +55-55-3220-8000; e-mail: iuricastroff@san.uri.br).

Abstract: This paper presents a short-term multiregional 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 EM as their importance for the total demand of the macro-region. In addition, the Variation of Load and Temperature index (IVCT) is proposed, based on the historical variation of temperature and demand. This indicator is incorporated into a model of neural network of the Multi-layer perceptron type (MLP) 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 IVCT in relation to the other combinations performed, and the best results were used to compose the prediction of the MTR. Finally, the proposed model presented a MAPE (Mean Absolute Percentage Error) lower than 1%, presenting superior performance compared to an basis aggregate model for MTR, which shows the efficiency of the proposed methodology.

Resumo: Este artigo apresenta uma abordagem de previsão Multirregional (MTR) de curto prazo para macrorregiões, tendo como principal contribuição a proposta de um indicador 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. Além disso, é proposto o índice de Variação de Carga e Temperatura (IVCT), baseado na variação histórica de temperatura e demanda. Este indicador é incorporado a um modelo de Rede Neural do tipo *Perceptron* Multicamadas (MLP) para a previsão de carga no horizonte de 7 dias à frente com discretização horária e diária. Os resultados apresentaram desempenho médio superior da variável IVCT em relação as demais combinações realizadas, e os melhores resultados foram utilizados para compor a previsão da MTR. Por fim, o modelo proposto apresentou um erro médio percentual (MAPE) inferior a 1%, apresentando desempenho superior comparado a um Modelo Agregado Base para a MTR, o que mostra a eficiência e contribuição da metodologia proposta.

Keywords: Short Term Load Forecasting; Multi Region Forecasting, Artificial Neural Network, Meteorological Station, Meteorological variables weighting.

Palavras-chaves: Previsão de carga de curto prazo; Previsão Multirregional; rede neural artificial; variáveis meteorológicas; ponderação de variáveis meteorológicas;

1. INTRODUÇÃO

Um dos principais objetivos da operação e planejamento dos sistemas de potência é utilizar os recursos de forma eficiente, mantendo o sistema seguro e confiável (Chu et al., 2011a). Para isso, a previsão de carga torna-se um requisito primário para a segurança, confiabilidade e economia da operação do sistema (Ružić, Vučković and Nikolić, 2003).

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. A definição desses horizontes é fundamental para estabelecer as principais influências das variáveis externas a carga, garantindo a assertividade da previsão (Wi, Joo and

Song, 2012). Estes horizontes podem ser divididos em curtíssimo, curto, médio e longo prazo (Qamar and Khosravi, 2015).

A previsão de curto prazo, onde se insere este artigo, é subsídio básico para estudos da operação diária eletroenergética e despacho de geradores (Clements, Hurn and Li, 2015). A programação diária de operação (PDE), tem como objetivo o estabelecimento dos programas diários de carga, geração e intercâmbios, afim de garantir a otimização energética dos recursos de geração e a segurança do Sistema Interligado Nacional (SIN) (ONS, 2015).

A previsão de carga Multirregional de curto prazo, torna-se uma das metodologias utilizadas para este fim, onde a previsão global pode ser realizada por meio da partição do sistema em

macrorregiões menores, e logo após, é agregada para compor uma previsão global. Uma macrorregião é caracterizada por possuir uma grande diversidade meteorológica em toda sua área territorial, e esta diversidade, é considerado neste artigo por meio da ponderação das Estações Meteorológicas (EMs) que melhor representam a demanda agregada da Macrorregião (MR).

Esta partição visa a redução da granularidade das características da MR, quanto a extensão e variações de temperatura. Estas variações de temperatura, ao longo do território da MR e suas influências para a demanda agregada da MR, evidenciam a principal contribuição deste trabalho.

Neste contexto, este trabalho apresenta uma metodologia de previsão Multirregional de curto prazo para macrorregiões, tendo como principal contribuição a proposta de um indicador que represente 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. Além disso, é proposto o índice de Variação de Carga e Temperatura (IVCT), baseado na variação histórica de temperatura e demanda. Este indicador é incorporado em um modelo de Rede Neural do tipo *Perceptron* Multicamadas (MLP)

2. PREVISÃO DE CARGA MULTIRREGIONAL DE CURTO PRAZO

A previsão de carga Multirregional possui duas abordagens em relação ao nível de agregação das previsões: *Bottom-up* e *Top-Down*. A primeira refere-se a uma metodologia onde 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 (Hong, 2015; Pennings and van Dalen, 2017).

Em (Fan, Methaprayoon and Lee, 2007) o autor aborda uma metodologia de previsão de curto prazo para multi-regiões *Bottom-up* utilizando Redes Neurais Artificiais MLP *Feedforward* com algoritmo de treinamento *Levenberg-Marquardt*. Esta metodologia divide o sistema existente em 24 regiões para a previsão de carga e compara com um modelo agregado de previsão. Os resultados mostraram uma diminuição no erro percentual (MAPE) de 1,86%, comparado com o modelo agregado.

Em seu trabalho posterior (Shu Fan, Methaprayoon and Wei-Jen Lee, 2009), é proposto um sistema previsor, 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. Neste trabalho a partição ótima é encontrada de forma heurística, combinando regiões e analisando o erro de previsão da combinação comparado com o erro individual de cada uma. Os resultados mostraram que para a partição ótima (6 regiões) o MAPE obtido foi de 2,69%, contra 3,16% para as 24 regiões e 3,36% para uma região (mínima partição).

Em (Chu *et al.*, 2011b) o conceito de previsão multirregional é aplicada para a companhia de energia de Taiwan devido a grande diversidade de clima existente entre as regiões do país. No modelo proposto, a previsão de carga é realizada individualmente para 4 regiões e comparado a um modelo de previsão agregado. Os resultados mostraram redução no MAPE de 2,157% para 1,423%, tornando o método mais eficiente do que um modelo agregado.

Quando a previsão é realizada para uma grande região geográfica, 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 (Hong and Lai, 2013) onde é realizado um estudo de caso com a comparação entre diversas formas de representar a variação de temperatura no território americano de *New England*. A comparação foi realizada através 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, (Hong, Wang and White, 2015) abordam o mesmo problema estabelecendo uma metodologia para seleção das estações que melhor representam a carga para um grupo de cooperativas do 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 (Silva *et al.*, 2017), a previsão de carga para macrorregiões é realizada para o Subsistema Sul do Sistema Elétrico Brasileiro. Neste trabalho, as estações meteorológicas são selecionadas de acordo com as áreas de concessão de cada distribuidora pertencente ao Subsistema Sul. O critério para utilização do modelo de rede neural, foi a ponderação das respectivas estações pelo número de habitantes abrangidos por cada EM. Os erros obtidos ficaram abaixo de 1% para determinada estação do ano em análise.

Neste contexto, este artigo apresenta como diferencial em relação aos demais trabalhos, a abordagem de tratamento de cada estação meteorológica (EM), utilizando como base o número de consumidores e dados estatísticos de níveis de consumo por região. Além disso, é proposto o índice IVCT, que fornece um indicador para o modelo previsor baseado no comportamento histórico integrado da demanda e temperatura.

3. METODOLOGIA PROPOSTA

A metodologia proposta baseia-se em 4 etapas fundamentais. Na primeira etapa, tem-se o processo de desagregação da Multirregião (MTR j), onde dados históricos de demanda são desagregados por Macrorregiões de Consumo (MR k),

definidos pelo número de agentes de distribuição pertencentes MTR j . O Objetivo desta desagregação é obter um preditor individual para cada MR k , e logo após, realizar a agregação para a previsão da MTR j .

A divisão da MTR j em regiões é mostrada na Fig. 1, onde o universo de análise é a MTR j , as Regiões 1, 2 e i , representam i conjuntos pertencentes ao MTR j . Dentro do conjunto Regiões, há ainda k subconjuntos, que neste caso são as MRs, mencionadas na etapa de desagregação da MTR.

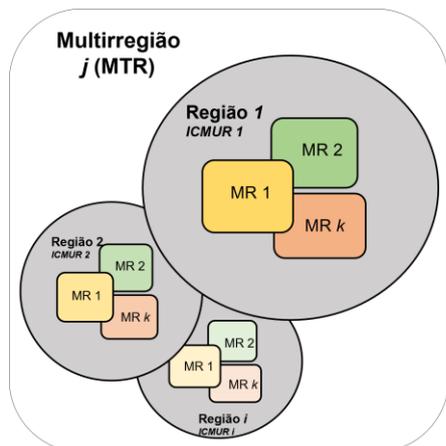


Fig. 1 Conjunto de análise da MTR j , Regiões e MRs pertencentes.

Na segunda etapa tem-se o processo de ponderação. Nesta etapa as variáveis meteorológicas de cada Estação Meteorológica EM p devem ser ponderadas antes de serem normalizadas e utilizadas pelo modelo de previsão como uma única variável resultante. Para este processo, é proposto neste trabalho 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, como o ajuste de pesos e neurônios do modelo de Rede Neural Artificial (RNA) *Perceptron* de Multicamadas de acordo com estudos de sensibilidade realizados. Além disso, este artigo apresenta como proposta a inserção da variável IVCT (Índice de Variação de Carga e Temperatura), responsável por fornecer características de comportamento da carga e temperatura. 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 MR.

3.1 Processo de 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 uma das contribuições deste artigo.

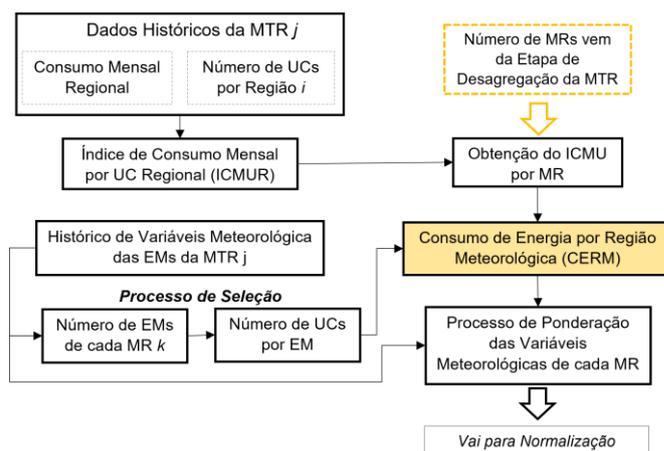


Fig. 2 Processo de Ponderação de variáveis meteorológicas.

Para a obtenção do índice CERM, primeiramente deve-se calcular Índice de Consumo Mensal por Unidade Consumidora Regional (ICMUR). Este índice é calculado com base nos dados de consumo médio mensal e número de unidades consumidoras de cada Região i pertencente a MTR j . 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 (Ministério de Minas e Energia, 2016). Os resultados deste anuário 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).

$$ICMUR_{(i,j)} = \frac{CM_{i,j}}{NUCs_i} \quad (1)$$

em que $CM_{i,j}$ representa o consumo mensal em GWh para a região i pertencente a MTR j , $NUCs_i$ representa o número de unidades consumidoras, dado em milhões, pertencentes a região i de análise. Como resultado tem-se o índice $ICMUR_{(i,j)}$ calculado para cada região i da MTR j dado em kWh/UC.mês.

Observa-se que cada região i da MTR j receberá um indicador regional (ICMUR) de acordo com o consumo e número de consumidores. Este processo é realizado como forma de aproximação para obtenção deste mesmo índice por MRs. Logo, as MRs pertencentes a Região 1, por exemplo, recebem o mesmo peso da respectiva região a qual estão inseridas para a ponderação das variáveis meteorológicas. Desta forma, cria-se o índice ICMU por MR, 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).

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

onde $CERM_{EM(p,k)}$ representa o peso dado a EM p pertencente a MR k dado em MWh/mês; $ICMU_j$ é fixo e varia de acordo com a MR j 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.

$$Tp_{(h,k)} = \sum_{k=1}^m \sum_{h=1}^{24} \left[\frac{\sum_{p=1}^n CERM_{(p,k)} T_{EM(p,h)}}{\sum_{p=1}^n CERM_{(p,k)}} \right] \quad (3)$$

em que $Tp_{(h,k)}$ representa a média 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.

3.2 Definição das variáveis de entrada e do modelo de previsão das MRs

Para a elaboração do modelo de previsão de carga, inúmeras características devem ser definidas, como a técnica a ser utilizada, parâmetros de treinamentos e escolha das variáveis envolvidas para a obtenção da previsão de carga multirregional.

Como técnica escolhida adotou-se o modelo de rede neural artificial (RNA) do tipo *Perceptron* Multicamadas (MLP) *feed-forward* mais frequentemente encontrada na literatura. 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 (Haykin, 2001). O padrão de entrada que será utilizado para cada MR obedecerá ao mostrado na Tabela 1.

Tabela 1. Variáveis de Entrada do Modelos previsoers.

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 lag de 1, 24, 48, 168 e 336 horas em relação ao dia a ser previsto.

Variáveis de Entrada	Descrição
$Tp(t-1, t-2, t-3)$	Temperatura com lag de 1, 2 e 3 horas em relação ao dia a ser previsto
IVCT	Índice de Variação de Carga e Temperatura ponderada

Como contribuição deste artigo é proposta a variável IVCT, que relaciona a variação de carga e temperatura e fornece um indicador para o modelo predictor e que será detalhada no próximo subitem.

A. Índice de Variação de carga e Temperatura (IVCT)

De forma a fornecer ao modelo de previsão de carga um indicador do comportamento da carga em função de variáveis meteorológicas, é proposto a criação do Índice de Variação de Carga e Temperatura (IVCT), mostrado no fluxograma da Fig. 3. Este índice é determinado pela análise histórica da carga e temperatura ponderada pela variável CERM e será inserido nos modelos individuais de previsão.

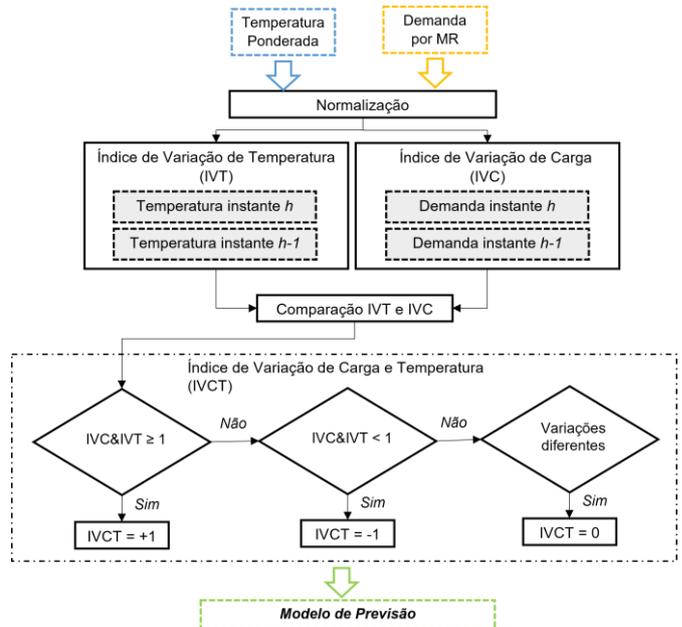


Fig. 3 Determinação do índice ICVT por MR.

Primeiramente a temperatura ponderada e demanda horária por MR são normalizados em um intervalo de 0 a 1. Logo após são calculados os Índices de Variação de Carga (IVC) e de Variação de Temperatura (IVT) para cada MR k , conforme (5) e (6).

$$IVC_{(k,h)} = \frac{D_h}{D_{(h-1)}} \quad (5)$$

$$IVT_{(k,h)} = \frac{Tp_h}{Tp_{(h-1)}} \quad (6)$$

onde D_h e Tp_h representam os dados de carga horários e da temperatura ponderada na hora (h) e $D_{(h-1)}$ e $Tp_{(h-1)}$ os dados referentes a hora anterior ($h-1$). O resultado desta divisão

resultará em um valor maior ou menor que 1. Por exemplo, caso a demanda atual (D_h) seja maior que a ocorrida previamente ($D_{(h-1)}$), então o resultado fornecido por (5) resultará um valor maior que 1, já que ocorreu um aumento da demanda. Caso contrário, receberá um valor inferior a 1. A mesma análise é válida para o indicador IVT.

Os resultados de IVT e IVC são então comparados de forma a avaliar se a variação histórica da variável temperatura gerou uma variação histórica na carga. Se ambos os índices possuírem valores superiores a 1, então IVCT receberá o valor +1, como indica a Fig. 3 para a primeira condição. Neste caso, estima-se que uma elevação da temperatura foi acompanhada por uma elevação da carga.

Por outro lado, se IVT e IVC possuírem valores inferiores a 1, IVCT receberá o valor -1, estimando então, que tanto a carga quanto a temperatura sofreram um decréscimo. A última condição reflete a situação onde as variações de IVC e IVT são contrárias, ou seja, se a demanda cair e a temperatura subir a variável IVCT receberá um peso zero.

B. Processo de Treinamento da RNA

Após a padronização das variáveis de entrada parte-se para a inicialização da RNA e definição dos parâmetros iniciais de treinamento. 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 15% do conjunto total, que representam dados que ainda não foram mostrados a rede de forma a analisar sua capacidade de generalização.

O início do processo de treinamento para cada MR k considera um número inicial de neurônios na camada intermediária. Com base neste número inicial, é realizado o processo de treinamento, verificação e testes por n iterações. Definiu-se inicialmente 30 iterações para cada i neurônios da camada intermediária. Conforme resultados da simulação para cada iteração, 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 (Salgado, 2009). O MAPE é definido em (7).

$$MAPE(\%) = \frac{100}{N} \sum_{j=1}^N \frac{|x_j - y_j|}{x_j} \quad (7)$$

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. A janela de previsão sempre é deslocada a medida que novos dados são fornecidos a rede, devendo ser novamente treinada para um novo período de previsão.

Para cada conjunto de interações para i neurônios é armazenado MAPE mínimo até que seja atingido o número de

neurônios máximo especificado. Ao se atingir o número máximo de neurônios, o resultado de simulação que obtiver o menor MAPE será considerado para a MR k , que neste caso denomina-se MAPE Global.

C. Processo de Agregação dos modelos individuais para obtenção do modelo global

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).

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

em que $PMTR_{(j,h)}$ 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.

3. RESULTADOS E DISCUSSÃO

3.1 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). Este subsistema representa 17,6% de todo o consumo de energia do SIN e 22,6% do número total de unidades consumidoras, distribuídas principalmente em 5 concessionárias de distribuição de energia (Ministério de Minas e Energia, 2016). A MTR Sul é composta por 3 Regiões, subdividindo-se em 5 MRs, sendo as MR 3, 4 e 5 pertencentes a mesma Região. As principais características das MRs são mostradas na Tabela 2.

Tabela 2. Características da MTR Sul.

Parâmetros	MR 1	MR 2	MR 3	MR 4	MR 5
Região	1	2	3	3	3
Área (mil km ²)	180,0	95,35	90,72	99,51	73,63
NUC (milhões)	4,478	2,831	1,454	1,318	1,653
Tmin (°C) Inverno	0,54	1,71	-2,76	-1,75	1,21
Tmax (°C) Inverno	27,74	28,22	27,76	30,71	30,58
Tmin (°C) Verão	9,73	10,86	5,33	7,81	10,01
Tmax (°C) Verão	32,78	33,95	33,25	38,11	37,37
Número de EMs	21	19	14	9	10

Observa-se a grande amplitude térmica para as estações de inverno e verão para as 5 MRs. Por exemplo, para a MR 4, a

amplitude térmica para o período de inverno e verão chegaram aproximadamente a 30°C. Observa-se ainda que a área de concessão da MR 1 é a maior entre as cinco MRs, além de ser maior em número de unidades consumidoras. 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 um histórico de dados de demanda e temperatura compreendido entre 1º de junho de 2012 até 31 de dezembro de 2013. Os dados de demanda são oriundos da base histórica de operação do ONS e os dados de temperatura foram obtidos através do histórico de leitura de Estações Automáticas Meteorológicas (EMs) pertencentes ao Instituto Nacional de Meteorologia (INMET)(INMET, 2017).

Particionou-se este histórico em 2 conjuntos de treinamento: o primeiro compreendido em 1º de junho de 2012 à 8 de julho de 2013, e o segundo, compreendido entre 1º de outubro de 2012 à 4 de novembro de 2013. Adotou-se esta partição de modo a avaliar a robustez dos modelos em períodos diferentes de demanda e temperatura de cada MR.

Para o primeiro conjunto, denominado de *Conjunto 1(C1)*, os testes são realizados para previsão do período de 9 de julho à 5 de agosto de 2013, que refere-se a estação de inverno para as MRs. Para o segundo conjunto de testes, denominado de *Conjunto 2(C2)*, a previsão é realizada para o período de 5 de novembro à 2 de dezembro de 2013, correspondendo ao período de primavera na região. Ressalta-se que a previsão é realizada com um horizonte de 7 dias, com discretização diária e horária. A cada deslocamento de janela de simulação (janela de 7 dias), novos dados são inseridos para o retreinamento da nova rede.

3.1 Análise dos resultados das MRs individuais

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 visto em (1) o índice ICMUR por Região, mostrado na Tabela 3.

Tabela 3. 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

Após o cálculo do ICMUR por região, obtêm-se o índice ICMU de acordo com a região onde cada MR se encontra. 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). Logo após esta ponderação, a variável IVCT é calculada conforme fluxograma da Fig. 3 e Equações (5) e (6).

Além do padrão fixo dos dados de entrada, destacados na Tabela 1, são realizados testes para avaliar o desempenho da variável IVCT (S1) nos modelos, comparando-a com a análise considerando somente a temperatura ponderada (S4) ou a demanda agregada da MR (S5). Com base no treinamento realizado, a Tabela 4 mostra os resultados de previsão para cada MR que obtiveram o menor MAPE médio mensal para C1 e C2.

Tabela 4. Resultados de previsão individual das MRs quanto ao MAPE médio mensal.

MR	Teste (C1)	MAPE _{C1} (%)	Teste (C2)	MAPE _{C2} (%)
1	S5	2,42	S1	2,48
2	S1	2,75	S1	2,90
3	S1	2,86	S4	2,73
4	S1	2,92	S1	3,03
5	S1	2,32	S1	2,57

Observa-se que a variável proposta neste artigo (S1) apresentou o melhor resultado médio para os conjuntos 1 e 2 de testes. Estes resultados são evidenciados na Tabela 5, onde é mostrado o ranking para os 2 melhores resultados médios para ambos os conjuntos.

Tabela 5. Ranking dos resultados de previsão individual das MRs.

Ranking	Testes	MR1	MR2	MR3	MR4	MR5
1º	C1	S5	S1	S1	S1	S1
2º		S4	S4	S4	S4	S4
3º		S1	S5	S5	S5	S5
1º	C2	S1	S1	S4	S1	S1
2º		S4	S5	S5	S4	S4
3º		S5	S4	S1	S5	S5

Observa-se que a variável IVCT (S1), proposto neste trabalho, apresentou os melhores resultados para as MRs, tanto para o Conjunto 1 quanto para Conjunto 2 de testes, o que representa uma das contribuições deste artigo. Além disso, observa-se que a previsão individual somente com a temperatura ponderada (CERM) resultou em um desempenho superior a previsão considerando somente a demanda agregada das MRs, mostrando uma tendência positiva da utilização da ponderação das EMs ao longo do território das MRs.

3.2 Análise dos Resultados da Previsão 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. A agregação é realizada em (8), considerando a soma das previsões diárias em MW dos modelos com melhor desempenho médio para cada MR.

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 (MPA). 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 do Modelo Agregado utiliza somente dados de demanda

normalizados de toda MTR Sul. Os resultados oriundos deste modelo são descritos como $MAPE_{MPA1}$ e $MAPE_{MPA2}$, correspondendo aos resultados para os Conjuntos 1 e 2, respectivamente. A Tabela 6 mostra o desempenho quanto ao MAPE mínimo, médio e máximo para cada dia da semana dos Conjuntos 1 e 2.

Percebe-se na Tabela 6 que a metodologia proposta apresentou desempenho superior em relação ao Modelo Agregado (MPA) para os dias de semana e fins de semana. Por exemplo, o MAPE máximo encontrado entre as quintas-feiras do Conjunto 1 foi de 1,10% e 1,71%, para o Modelo Proposto e MPA, respectivamente. Para o feriado, a metodologia proposta obteve um MAPE de 1,06% em relação 2,60% obtido pelo MPA. A Fig. 4 mostra a previsão realizada para a semana dos dias 12 de novembro a 18 de novembro de 2013 com destaque para o feriado no dia 15/11/2013.

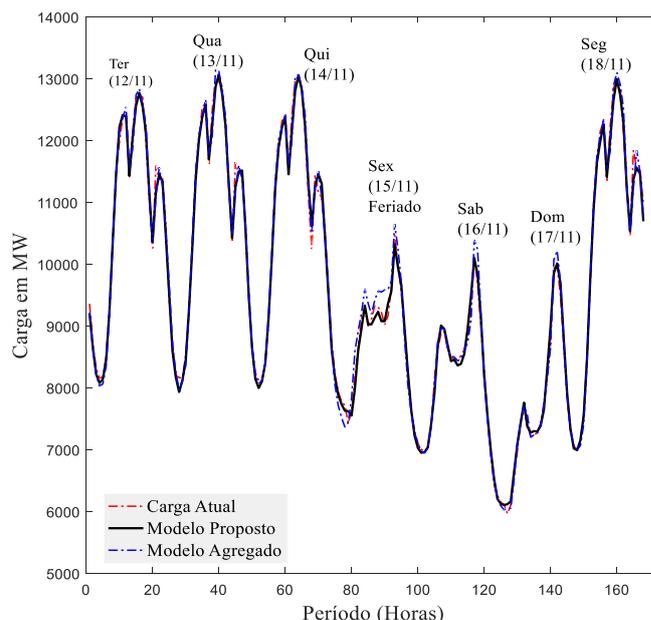
Observa-se pela Fig. 5 que ambos os modelos se aproximam da curva de carga real, o que corrobora as informações apresentadas na Tabela 6 quanto a comparação do MAPE diário. Por exemplo, ao analisar o dia 13/11/2013 (quarta-feira) percebe-se que o modelo proposto apresenta um MAPE de 0,95% em relação a 1,26% do MPA. Esta diferença é mais notável para o feriado, onde o modelo proposto possui uma melhor aproximação em relação a curva real, justificando também o MAPE mostrado na Tabela 6 para este dia de previsão de forma a analisar a distribuição do MAPE horário para ambos os modelos. A Tabela 7 apresenta a comparação entre os modelos considerando a distribuição de frequência dos erros horários obtidos para os Conjuntos 1 e 2.

Observa-se na Tabela 7, que para ambos os conjuntos de simulação, há uma maior concentração de erros inferiores a 1% para o Modelo proposto do que para o Modelo Agregado. Nota-se ainda, que erros superiores a 2,5% ocorreram com mais frequência para o Modelo Agregado, corroborando então a eficácia da metodologia proposta neste artigo no que diz respeito a desempenho em ambos os conjuntos de testes.

Tabela 7. Distribuição de frequência do MAPE horário para os Modelos Agregado e Proposto.

Frequência MAPE Horário (%)	Modelo Proposto		Modelo Agregado	
	C1	C2	C1	C2
< 1%	68,15%	65,47%	53,57%	49,25%
>2,5%	3,57%	5,35%	10,86%	12,94%

Fig. 4 Resultados da previsão da MTR Sul: (a) Previsão para o Conjunto 2; (b) Previsão realizada para o feriado.



6. CONCLUSÕES

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

Tabela 6. Comparação do MAPE para o modelo proposto(C) e agregado (MPA) para os conjuntos 1 e 2.

	MAPE _{C1} (%)			MAPE _{MPA1} (%)			MAPE _{C2} (%)			MAPE _{MPA2} (%)		
	Mín	Méd	Máx	Mín	Méd	Máx	Mín	Méd	Máx	Mín	Méd	Máx
TER	0,66	0,78	0,90	0,88	1,19	1,71	0,75	0,89	1,03	1,14	1,33	1,60
QUA	0,61	0,84	1,10	0,75	1,17	1,90	0,71	0,85	1,03	1,26	1,34	1,51
QUI	0,66	0,90	1,10	0,66	1,20	1,71	0,63	0,87	1,08	1,05	1,16	1,43
SEX	0,72	0,82	0,97	0,87	1,06	1,34	0,81	0,90	1,06	1,12	1,64	1,60
SÁB	0,63	0,89	1,10	0,62	1,02	1,22	0,84	0,94	1,01	0,94	1,07	1,30
DOM	0,72	0,93	1,23	0,73	1,29	1,69	0,81	0,97	1,14	0,98	1,27	1,80
SEG	0,67	0,73	0,76	0,83	1,14	1,46	0,79	0,97	1,17	0,84	1,26	1,65
FERIADO								1,06			2,60	

Como parte da metodologia, a previsão multirregional proposta busca particionar uma MTR em macrorregiões, realizar a previsão individual de cada MR, e por fim, agregar as previsões para compor um modelo global com maior assertividade. Esta partição visa a redução da granularidade das características da MR, quanto a extensão e variações de temperatura. Estas variações de temperatura, ao longo do território da MR e suas influências para a demanda agregada da MR, leva a principal contribuição deste trabalho.

Neste sentido, foi proposto o indicador de Consumo de Energia Médio por Região Meteorológica (CERM) de forma a ponderar as EMs e a variável IVCT para fornecer um indicador do comportamento histórico de carga e temperatura. Os resultados foram avaliados considerando dois conjuntos de testes, com mesma janela de treinamento, mas em períodos de inverno (Conjunto 1) e primavera (Conjunto 2). Desta forma, observou-se que o indicador IVCT proposto apresentou os melhores desempenhos médios para as MRs nos períodos de análise. Além disso, a realização da previsão considerando apenas a demanda apresentou desempenho inferior a IVCT e temperatura ponderada.

Logo após as previsões individuais, a previsão da MTR é realizada por meio da agregação dos modelos previsores com melhores desempenho de cada MR. Através desta abordagem, obteve-se um MAPE médio inferior a 1% para os Conjuntos 1 e 2, mostrando desempenho superior ao MPA. Além disso, quando analisado a distribuição do MAPE horário para ambos os conjuntos, nota-se que o MPA apresentou menor concentração de erros na faixa de 1% e maior concentração de erros superiores a 2,5%, o que mostra o desempenho superior da metodologia proposta em relação ao agregado. Por fim, a abordagem proposta neste artigo se mostrou eficiente no que diz a previsão de carga multirregional, fornecendo uma estimativa da carga com erro reduzido e podendo ser aplicada com desempenho satisfatório para problemas deste tipo.

REFERÊNCIAS

- Chu, W.-C. et al. (2011a) 'Multiregion Short-Term Load Forecasting in Consideration of HI and Load/Weather Diversity', *IEEE Transactions on Industry Applications*, 47(1), pp. 232–237. doi: 10.1109/TIA.2010.2090440.
- Chu, W.-C. et al. (2011b) 'Multiregion Short-Term Load Forecasting in Consideration of HI and Load/Weather Diversity', *IEEE Transactions on Industry Applications*, 47(1), pp. 232–237. doi: 10.1109/TIA.2010.2090440.
- Clements, A. E., Hurn, A. S. and Li, Z. (2015) 'Forecasting day-ahead electricity load using a multiple equation time series approach', *European Journal of Operational Research*, 251, pp. 522–530. doi: 10.1016/j.ejor.2015.12.030.
- Fan, S., Methaprayoon, K. and Lee, W. J. (2007) 'Short-term Multi-Region Load Forecasting Based on Weather and Load Diversity Analysis', in *2007 39th North American Power Symposium*. IEEE, pp. 562–567. doi: 10.1109/NAPS.2007.4402366.
- Haykin, S. (2001) *Redes neurais artificiais: princípios e prática*. 2a Edição, Bookman. 2a Edição. Edited by Bookman. Porto Alegre: Tradução Paulo Martins Engel.
- Hong, T. (2015) 'Load Forecasting Case Study'. Available at: <https://pubs.naruc.org/pub.cfm?id=536E10A7-2354-D714-5191-A8AAFE45D626>.
- Hong, T. and Lai, S. (2013) *When One Size No Longer Fits All – Electric Load Forecasting with a Geographic Hierarchy*. Disponível em: <http://assets.fiercemarkets.com/public/sites/energy/reports/electricloadforecasting.pdf>.
- Hong, T., Wang, P. and White, L. (2015) 'Weather station selection for electric load forecasting', *International Journal of Forecasting*. Elsevier B.V., 31(2), pp. 286–295. doi: 10.1016/j.ijforecast.2014.07.001.
- INMET (2017) Instituto Nacional de Meteorologia. Available at: <http://www.inmet.gov.br/portal/index.php?r=estacoes/estacoesautomaticas>.
- Ministério de Minas e Energia (2016) 'Anuário Estatístico de Energia Elétrica 2016'. Available at: www.epe.gov.br.
- ONS, O. N. do S. E. (2015) Submódulo 8.1 - Programação diária da operação eletroenergética.
- Pennings, C. L. P. and van Dalen, J. (2017) 'Integrated hierarchical forecasting', *European Journal of Operational Research*. Elsevier B.V., 263(2), pp. 412–418. doi: 10.1016/j.ejor.2017.04.047.
- Qamar, M. and Khosravi, A. (2015) 'A review on artificial intelligence based load demand forecasting techniques for smart grid and buildings', *Renewable and Sustainable Energy Reviews*. Elsevier, 50, pp. 1352–1372. doi: 10.1016/j.rser.2015.04.065.
- Ruzić, S., Vučković, A. and Nikolić, N. (2003) 'Weather Sensitive Method for Short Term Load Forecasting in Electric Power Utility of Serbia', *IEEE Transactions on Power Systems*, 18(4), pp. 1581–1586. doi: 10.1109/TPWRS.2003.811172.
- Salgado, M. (2009) *Sistema de Suporte à Decisão para Análise e Previsão de Carga por Barramento*. Universidade Estadual de Campinas.
- Shu Fan, Methaprayoon, K. and Wei-Jen Lee (2009) 'Multiregion Load Forecasting for System With Large Geographical Area', *IEEE Transactions on Industry Applications*, 45(4), pp. 1452–1459. doi: 10.1109/TIA.2009.2023569.
- Silva, L. N. et al. (2017) '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)*. IEEE, pp. 1–6. doi: 10.1109/UPEC.2017.8231864.
- Wi, Y., Joo, S. and Song, K. (2012) 'Holiday Load Forecasting Using Fuzzy Polynomial Regression With Weather Feature Selection and Adjustment', *IEEE Transactions on Power Systems*, 27(2), pp. 596–603. doi: 10.1109/TPWRS.2011.2174659.