

Previsão de Carga para Curtíssimo Prazo Considerando a Influência das Variáveis Climáticas

CAMILLA LEIMANN PIRES¹, DANIEL PINHEIRO BERNARDON¹, MAURICIO SPERANDIO¹, ANA PAULA CARBONI DE MELLO^{1,2},
CRICIÉLE CASTRO MARTINS¹

¹UFSM – Universidade Federal de Santa Maria
Santa Maria, RS, Brasil

²UNIPAMPA - Universidade Federal do Pampa
Alegrete, RS, Brasil

camillaleimann@gmail.com, dpbernardon@ufsm.br, mauricio.sperandio@ufsm.br, anamello@unipampa.edu.br, cricielecastro@gmail.com

Resumo — Previsão de carga é uma atividade muito importante no planejamento do Setor Elétrico, e por isso é necessário um método de projeção confiável a fim de atender a carga do sistema. Este artigo apresenta uma metodologia para previsão da carga a curtíssimo prazo, considerando as variáveis climáticas que têm influência sobre a carga, como a temperatura ambiente, umidade do ar, velocidade do vento, radiação solar e pressão atmosférica. O trabalho apresenta a análise das variáveis climáticas em função da demanda de energia e insere as variáveis de maior influência no modelo de projeção. O método para a previsão foi realizado utilizando a ferramenta VBA do Excel, através do agrupamento de dados do histórico e baseia-se na regressão linear múltipla. O algoritmo de previsão foi testado e comparado computacionalmente com base nos dados reais, apresentando resultados significativos, confirmando que as informações tem grande importância para refinar métodos de previsão de carga.

Palavras-chave – Previsão de Carga, Curtíssimo Prazo, Influências Climáticas, Regressão Múltipla.

INTRODUÇÃO

Para a realização do planejamento da expansão e operação dos sistemas elétricos de potência é necessário primeiramente entender o comportamento da carga do sistema. A previsão de carga é uma atividade de grande importância no planejamento do Setor Elétrico, e por isso é necessário um método de projeção confiável a fim de atender a carga do sistema.

Os horizontes de previsão podem variar de décadas ou minutos. A previsão de demanda para curtíssimo prazo possui um horizonte de poucos minutos até algumas horas e ela procura traduzir com maior exatidão o perfil instantâneo da carga.

Em um horizonte de curto e curtíssimo prazo, os fatores climáticos são os grandes responsáveis por mudanças nos padrões de consumo de energia podendo ocasionar ajustes na programação diária da operação do Operador Nacional do Sistema Elétrico (ONS) em relação aos valores previamente estabelecidos. Independente da técnica de estimação utilizada, a capacidade de previsão depende do nível de conhecimento do comportamento passado do sistema.

Para o planejamento correto do sistema é indispensável o estudo das variáveis que influenciam na demanda de eletricidade. Segundo [1] variáveis climáticas apresentam uma grande influência na evolução de demanda de energia elétrica no curtíssimo prazo, portanto, devem ser incorporadas no modelo de projeção. Em [2] foi identificado que o índice de desconforto (relação entre a temperatura ambiente e a umidade relativa do ar) e a sensação térmica (relação entre a temperatura e a velocidade do vento) mostraram-se indicadores eficientes para a projeção da demanda de energia elétrica a curtíssimo prazo, concluindo que os efeitos das variáveis climáticas na evolução da demanda obtiveram resultados satisfatórios.

Os efeitos da temperatura sobre a demanda podem ser variáveis, como é apresentado em [3], onde é realizada uma análise diferenciada apenas da temperatura relacionada à previsão da carga elétrica para o curto prazo, comprovando que a carga apresenta bastante sensibilidade à variação temperatura. Sabe-se que a temperatura é a variável climática que tem mais influência sobre os hábitos diários da população em geral. Métodos que analisam a influência da temperatura na demanda da energia elétrica e a sua potencialidade para o uso em fins de previsão da carga são cada vez mais difundidos, como é desenvolvido em [4], em que apresenta um modelo de previsão de demanda de energia utilizando modelos numéricos de previsão de tempo, onde o estudo mostra a influência da variação da temperatura no comportamento diário da população da Itália em relação ao uso da energia elétrica para refrigeração.

Na literatura, o estudo das variáveis climáticas está fortemente relacionado com a previsão de carga no curto prazo. Raham e Hazim (1993) afirmam que, para a previsão de demanda à curto prazo, a temperatura é a variável climática mais importante para relacionar com a demanda de energia [5]. Estudos apontam que dados de demanda de energia elétrica junto a dados meteorológicos contribuem no entendimento da influência das variáveis climáticas sobre a evolução da demanda [6]. O objetivo principal deste trabalho é o desenvolvimento de uma metodologia para a projeção de demanda de energia elétrica a curtíssimo prazo que considere as variáveis climáticas que influenciam nessas aplicações para a análise dos sistemas.

INFLUÊNCIA DAS VARIÁVEIS CLIMÁTICAS NA DEMANDA DE ENERGIA

A demanda de eletricidade é conhecida por variar de acordo com a hora do dia, semana, mês, temperatura, dias úteis, finais de semana, dentre outros fatores. Para o desenvolvimento de um modelo de projeção confiável faz-se necessário o estudo das variáveis que influenciam na demanda de eletricidade.

Segundo [7] há vários fatores que influenciam no comportamento da demanda de energia elétrica, seja a nível nacional ou regional, e podem ser classificados em quatro categorias:

- *Fatores econômicos*: principalmente em regiões onde a industrialização se faz mais presente;
- *Fatores sazonais*: meses e estações do ano;
- *Efeitos aleatórios*: como aumento ou redução da demanda em função de aquecimento no mercado, eventos esportivos, dentre outros;
- *Fatores climáticos*: temperatura, umidade relativa do ar, velocidade do vento, pressão atmosférica, radiação solar, dentre outros.

As principais variáveis climáticas que podem ser relacionadas com a variação de demanda são ilustradas na figura 1.




Figura 1. Diagrama de relações causais que influenciam na demanda de energia elétrica.

Como pode-se perceber pela figura 1, muitos fatores podem influenciar na evolução da demanda de energia, então é necessária uma análise precisa em cada variável climática a fim de relacionar os efeitos das mesmas sobre a variação da carga.

Para esta análise foram obtidos valores reais de carga do ano de 2011 de uma subestação da região metropolitana do estado do Rio Grande do Sul, esses dados serão analisados com dados de uma estação meteorológica do mesmo local. As variáveis que serão analisadas neste estudo que podem ter alguma relação aos efeitos apresentados sobre a demanda de energia são: temperatura ambiente, umidade relativa do ar, velocidade do vento, radiação solar e pressão atmosférica.

Padrões de perfis diários de demanda são importantes no auxílio da compreensão do comportamento da demanda de energia elétrica ao longo do tempo. Para isso, determinaram-se perfis de carga para dias úteis e para feriados e finais de semana conforme a figura 2. Para todo o ano de 2011 a subestação

apresentou o mínimo de carga próximo aos 14MW e a máxima carga registrada quase alcançou a marca de 50MW. A partir desses dados foi possível verificar para cada variável climática a sua relação com demanda apresentada. Vale salientar que os perfis de carga são meramente ilustrativos, apenas para exemplificar o comportamento da demanda do sistema em análise.




Figura 2. Exemplo de perfil de carga diário para dia útil e final de semana dos dados da subestação.

A seguir é demonstrada a relação geral de cada variável climática com a demanda de energia através de gráficos apresentando a regressão entre a variável e a demanda. Foram realizadas análises sazonais de mês a mês, por estação do ano, e alguns comportamentos diários. Os gráficos apresentam a regressão linear entre as variáveis, onde o valor de R^2 , chamado de coeficiente de determinação, indica a porcentagem de quanto a variação da variável Y é dependente da variável X. O Valor de R^2 pode variar de 0 a 1, e quanto mais próximo de 1, maior é a indicação de que o modelo proposto é adequado para descrever o fenômeno.

A. Relação entre a demanda e temperatura

Para consumidores residenciais a temperatura ambiente é sem dúvida a variável climática que tem a maior influência sobre a carga elétrica de um sistema. Segundo [2] um pequeno desvio da temperatura em relação a seu valor normal (no Brasil considerado como 23°C) já é suficiente para gerar uma variação significativa no consumo de energia.

A figura 3 demonstra a variação de temperatura (em °C) em função da demanda de energia (em MW) para a subestação em análise. Os pontos representam os dados obtidos, e a linha contínua é a linha de tendência de uma variável em relação a outra.

Para a base de dados em análise, pode-se perceber que a temperatura teve uma correlação positiva entre a carga elétrica demandada, e apresentou um valor significativo para o coeficiente do R^2 , confirmando que a temperatura ambiente afeta o consumo de energia elétrica.




Figura 3. Regressão da temperatura e demanda de energia.

B. Relação entre a demanda e umidade relativa do ar

A umidade relativa do ar também é outra variável influente sobre a demanda elétrica. Através da figura 4 pode-se verificar a relação das duas variáveis assim como o seu coeficiente de determinação. Analisando o gráfico, percebe-se que a umidade do ar apresentou uma correlação inversa com a demanda de eletricidade e o valor do R^2 confirma a sua influência sobre a carga consumida.




Figura 4. Regressão da umidade relativa do ar e demanda de energia.

C. Relação entre a demanda e velocidade do vento

Pelo gráfico da figura 5 pode-se perceber que a velocidade do vento não possui grande influência como a temperatura e a umidade, porém essa variável climática é muito considerada em estudos que relacionam a sensação térmica com a demanda de energia.




Figura 5. Regressão entre a velocidade do vento e a demanda de energia.

D. Relação entre a demanda e radiação solar

Através da figura 6 pode-se verificar o comportamento da radiação solar com a demanda, onde o coeficiente de determinação obteve um valor razoável. Trabalhos como o de [6] é um dos poucos exemplos que utilizam essa variável para previsão de demanda de energia no curto prazo.




Figura 6. Regressão entre a radiação solar e a demanda de energia.

E. Relação entre a demanda e pressão atmosférica

A pressão atmosférica, expressa em hPa, e seus efeitos sobre demanda de energia são poucos significativos, conforme a figura 7, e pode-se perceber que ela não apresenta uma influência aparente sobre a demanda.




Figura 7. Regressão entre a pressão atmosférica e a demanda de energia.

METODOLOGIA PROPOSTA PARA A PREVISÃO

Há vários métodos usados para a previsão da demanda de energia. Este trabalho apresenta a proposta de uma nova metodologia para a previsão da carga utilizando o modelo de regressão múltipla, agrupamento das variáveis e tratamento estatístico dos dados.

A. Modelo de Regressão Múltipla

A regressão múltipla é uma metodologia estatística de previsão de valores de uma ou mais variáveis dependentes (y) através de um conjunto de variáveis independentes (x). Sua aplicação é importante porque permite que se estime o valor de uma variável com base em um conjunto de outras variáveis.

Segundo [8] os modelos de regressão assumem que a carga elétrica pode ser dividida em uma componente normalizada e uma

componente dependente de algumas variáveis explicativas, e pode ser descrito por:

$$y(t) = b(t) + \sum_{i=1}^n a_i \cdot x_i(t) + \varepsilon(t) \quad (1)$$

Onde $b(t)$ é a carga normalizada, $\varepsilon(t)$ é uma componente de ruído branco, $x_i(t)$ são as variáveis explicativas independentes, por exemplo, a temperatura, umidade, radiação, vento e a hora do dia, e $a_i(t)$ são os coeficientes angulares da i -ésima variável.

B. Agrupamento de variáveis

A metodologia desenvolvida para previsão de carga a curtíssimo prazo foi realizada através da criação de uma ferramenta computacional que leve em consideração as variáveis climáticas, o algoritmo para a previsão foi realizado utilizando a ferramenta VBA do Excel. Foram armazenados os dados históricos de demanda total e seus respectivos dados climáticos para cada hora dos 365 dias do ano de 2011, em seguida foi atribuído a cada hora do banco de dados uma atribuição (letra) referente a cada variável, conforme a figura 8, que é dividida em faixa de valores, criando agrupamento dos dados do histórico que possuem faixas iguais.

Hora		Carga		Temperatura	
0	A	10 a 15	A	0 a 5	A
1	B	15 a 20	B	5 a 10	B
2	C	20 a 25	C	10 a 15	C
3	D	25 a 30	D	15 a 20	D
4	E	30 a 35	E	20 a 25	E
5	F	35 a 40	F	25 a 30	F
6	G	40 a 45	G	30 a 35	G
7	H	45 a 50	H	35 a 40	H
8	I				
9	J				
10	K	Umidade		Vento	
11	L	0 a 20	A	0 a 2	A
12	M	20 a 40	B	2 a 4	B
13	N	40 a 60	C	4 a 6	C
14	O	60 a 80	D	6 a 8	D
15	P	80 a 100	E		
16	Q				
17	R	Radiação			
18	S	de -5 a 1000	A		
19	T	1000 a 2000	B		
20	U	2000 a 3000	C		
21	V	3000 a 4000	D		
22	X	>4000	E		
23	Z				

Figura 8. Atribuição das variáveis em faixa de valores para a previsão da carga.

O método para a previsão consiste primeiramente no agrupamento dos dados do histórico, em que, conforme a figura 8 atribui uma faixa para cada hora do histórico, formada pelas letras em que os valores de carga e variáveis climáticas se encaixam.

Após as etapas de agrupamento das variáveis e da regressão múltipla, é calculada a carga a prevista de hora em hora. Para cada hora do período a ser projetado, o programa lê os dados da carga e das variáveis climáticas da hora anterior e atribui uma faixa para o período de acordo com a figura 8. Com isso o programa busca faixas iguais à faixa gerada e armazena os dados da carga do

histórico de cada faixa para 24 horas à frente (que é o período de previsão).

Em seguida é realizado por análise estatística o cálculo do desvio padrão das cargas das faixas iguais e calculado limites inferiores e superiores para filtrar eventos aleatórios do histórico. Então é calculada, para cada faixa do histórico, a porcentagem de variação da carga de hora em hora, e por fim, é realizado o cálculo da média de todas as variações do histórico e aplica-se essa porcentagem de variação na hora a ser prevista, resultando no valor da carga projetada. O programa é atualizado a cada hora, a fim de minimizar os erros e obter uma melhor estimativa. A figura 9 expressa as etapas do algoritmo desenvolvido para realizar a projeção.




Figura 9. Etapas da previsão.

C. Cálculo do erro

Para poder avaliar o desempenho da metodologia proposta neste trabalho determina-se o erro percentual médio segundo [8], que pode ser calculado por:

$$E_m = \frac{1}{N} \sum_{i=1}^N \left[\frac{x_i^R - x_i^F}{x_i^R} \right] \times 100 \quad (\%) \quad (2)$$

Onde N é o horizonte de previsão, x_i^R é o i -ésimo valor da carga real e x_i^F é o i -ésimo valor da carga projetada.

RESULTADOS DA PREVISÃO

A fim de testar a eficiência do algoritmo de projeção desenvolvido, foram realizadas simulações computacionais. Após comparou-se os resultados obtidos com valores reais da demanda de energia elétrica para um horizonte de 24 horas à frente. O período de análise dos dados refere-se ao ano de 2011, e os resultados apresentados das simulações são referentes à previsão da demanda para o mês de dezembro do mesmo ano. O intervalo de leitura dos dados de carga e das variáveis climáticas é de uma hora, e os valores lidos são referentes aos valores instantâneos de hora em hora, para todas as variáveis.

Smart Grid podem ser capazes de aperfeiçoar métodos de previsão de carga a curtíssimo prazo quando há atualização horária dos dados. Os métodos de previsão a curtíssimo prazo tornam-se mais adaptativos quando os dados da previsão são atualizados de hora e hora, fazendo com que os erros diminuam, ocasionando maior confiabilidade na projeção.

Foram realizadas quatro tipos de simulações considerando diferentes variáveis climáticas, também foram obtidas simulações que consideram só a média das variações do histórico sem o desvio padrão e outras foram realizadas com o cálculo do desvio como descrito no item anterior. Os diferentes tipos de projeção foram realizados a fim de comparar os resultados e verificar as previsões que possuem menor erro. Os resultados referem-se a um dia típico do mês de análise.

A. Previsão da Carga considerando a Temperatura, Umidade, Velocidade do Vento e Radiação Solar sem Desvio Padrão

A primeira previsão foi realizada considerando todas as variáveis climáticas analisadas, exceto a pressão atmosférica que obteve os resultados menos significativos na análise da regressão múltipla, considerando que essa variável não influencia no resultado da previsão. Na figura 10 há a comparação dos dois tipos de previsão realizados. Foi simulada a projeção da carga para 24 horas a frente com base no primeiro horário do dia (Previsão 1), e também foi simulada a projeção da carga com a atualização dos dados de hora em hora (Previsão 2).




Figura 10. Previsão de carga com e sem atualização horária de dados.

O cálculo da projeção mostrado na figura 10 foi feito com base na variação horária média do histórico, sem o cálculo do desvio padrão. O erro médio percentual encontrado para a Previsão 1 foi de 3,24% enquanto o erro médio para a Previsão 2 foi de 1,89%.

B. Previsão da Carga considerando a Temperatura, Umidade, Velocidade do Vento e Radiação Solar com Desvio Padrão

Nessa previsão foram consideradas as mesmas variáveis que a simulação anterior, mas utiliza o cálculo do desvio padrão das variáveis do histórico com a atualização dos dados de hora em hora. Pode-se perceber, pela figura 11, que a previsão da carga

realizada obteve resultados mais robustos para o dia em análise, onde o erro médio encontrado foi de 1,78% para o dia em questão.




Figura 11. Projeção da demanda com desvio padrão das variações do histórico.

C. Previsão da Carga considerando a Temperatura

Também foi simulada a projeção da carga utilizando somente a variável climática que possui a maior influência, a temperatura. A figura 12 apresenta a projeção da carga utilizando somente dados do histórico da carga, temperatura e hora do dia, o erro percentual médio encontrado para essa previsão foi de 2,08%.




Figura 12. Projeção da demanda com desvio padrão usando a temperatura e hora do dia.

D. Previsão da Carga considerando a Temperatura e Umidade do ar

Pela análise do item II, a umidade também se mostrou muito influente sobre a carga. A figura 13 apresenta a projeção da carga considerando a temperatura e a umidade do ar, que são as duas variáveis de maior influência. O resultado do erro para essa previsão foi de 2,07%.




Figura 13. Projeção da demanda com desvio padrão usando a temperatura, umidade do ar e hora do dia.

CONCLUSÃO

Este trabalho desenvolve uma metodologia para previsão de carga a curtíssimo prazo, através da criação de uma ferramenta computacional que leve em consideração as variáveis climáticas que têm influência sobre a demanda de energia elétrica. Os dados históricos de demanda total e das variáveis climáticas foram armazenados através de um programa que realize o agrupamento dos dados, utilizando a plataforma VBA do Excel. Permitindo a realização das previsões de carga a curtíssimo prazo, através da análise de transições dos agrupamentos ao longo do tempo.

Foram obtidos dados de carga de uma subestação da região metropolitana do estado do Rio Grande do Sul, analisados com dados de uma estação meteorológica da região. A análise das variáveis climáticas em relação à demanda de energia elétrica apresentou resultados importantes para serem considerados nos métodos de previsão.

Após a realização dos diferentes tipos de previsão pode-se perceber que todas as simulações apresentaram erros percentuais baixos. O menor erro médio encontrado foi de 1,78%, o método considerou a influência da temperatura, umidade do ar, velocidade do vento e radiação solar, e utilizou o desvio padrão no tratamento estatístico. Outra previsão que teve os melhores resultados foi a previsão que considerou as mesmas variáveis, mas não utilizou o tratamento com desvio padrão, e obteve um erro de 1,89%, confirmando que as variáveis climáticas consideradas tem grande importância para refinar métodos de previsão de carga, fundamental para o planejamento de sistemas. Já a previsão da carga que obteve o maior erro, porém também um erro baixo de 3,24%, foi a que não fez a previsão para 24 horas à frente, sem a atualização horária dos resultados, concluindo que Smart Grid ajuda no refinamento dos dados das previsões.

As previsões realizadas somente com a temperatura e a umidade do ar também apresentaram erros muito baixos na previsão, a simulação utilizando somente a temperatura obteve um erro de 2,08%, e para a simulação utilizando a temperatura e a umidade do ar o erro foi de 2,07%, o que confirma que essas duas variáveis são as que possuem maior dependência sobre a carga, e que a temperatura é a variável climática mais importante na aplicação do modelo, pois aplicando a projeção somente com ela os resultados já se mostram significativos. Porém pode-se concluir também que as simulações realizadas com todas as variáveis de influência refinam o método de projeção da carga, obtendo resultados ainda mais precisos.

AGRADECIMENTOS

Os autores agradecem o apoio técnico e financeiro do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), Fundação de Amparo à Pesquisa do Estado do Rio Grande do Sul (FAPERGS), e da concessionária de energia elétrica AES Sul Distribuidora Gaúcha de Energia SA pelo projeto “Solução Inovadora para Gerenciamento Ativo de Sistemas de Distribuição” (P&D/ANEEL).

REFERÊNCIAS

- [1] M. O. Oliveira, D. P. Marzec, G. Bordin, A. S. Bretas e D. P. Bernardon, “Análise do efeito das variáveis climáticas sobre a evolução da demanda de energia elétrica,” *XVIII Congresso Brasileiro de Automática*, pp. 4553-4559, 12 a 16 Setembro 2010.
- [2] S. Bordignon, “Metodologia para previsão de carga de curtíssimo prazo considerando variáveis climáticas e auxiliando na programação de despacho de pequenas centrais hidrelétricas”, Dissertação de Mestrado, Universidade Federal do Pampa, Alegrete, 2012.
- [3] L. F. S. Souza, R. S. Wazlawick, C. M. de Oliveira, L. A. D. de Luca, “A influência da temperatura no comportamento da carga elétrica de curto prazo e na precisão da sua previsão”. *Simpósio Brasileiro de Automação Inteligente*, Outubro, 2013. Available: <http://www.sbai2013.ufc.br/pdfs/5106.pdf>.
- [4] M. D. Felice, A. Alessandri, P. M. Ruti, “Electricity demand forecasting over Italy: Potential benefits using numerical weather prediction models”. *Electric Power Systems Research*, 104, pg 71-79, 2013.
- [5] S. Rahman, O. A. Hazim, “Generalized Knowledge-Based Short-Term Load Forecasting Technique”. *IEEE Transactions on Power Systems*, v. 8, p. 508-514, 1993.
- [6] M. Becalli, et al. “Forecasting Daily Urban Electric Load Profiles using Artificial Neural Networks”. *Energy Conversion and Management*, v. 45, p. 2879-2900, 2004.
- [7] M. J. Alves, “Estudo da influência das variações de temperatura e umidade no comportamento da demanda de energia elétrica e formação do custo marginal de operação no Brasil”. Dissertação de Mestrado, Escola Politécnica da Universidade de São Paulo, São Paulo, 2008.
- [8] P. Murto, “Neural network models for short-term load forecasting,” Helsinki University of Technology, Department of Engineering Physics and Mathematics, 92 p., Helsinki, January, 1998.