

Previsão de Demanda de Energia Elétrica Utilizando Modelos Lineares

José Gregório de Figueiredo Rosa * Gustavo Luís Soares *
Thiago Melo Machado-Coelho **
Marcus Henrique Soares Mendes ***
Matheus Pereira Libório * Alexei Manso Correa Machado *
Petr Iakovlevitch Ekel *

* Pontifícia Universidade Católica de Minas Gerais (e-mails:
jgfigueiredorosa@hotmail.com, gsoares@pucminas.br,
m4th32s@gmail.com, alexei@pucminas.br, ekel@pucminas.br)

** Universidade Federal de Minas Gerais (e-mail:
thmmcoelho@gmail.com)

*** Universidade Federal de Viçosa (e-mail:
marcus.henrique@gmail.com)

Abstract: Electricity consumption forecasting is essential for electricity distribution concessionaires since it can mainly assist in decisions related to the core business of these companies. This work presents linear models for the forecast of electricity demand, in the short and medium-term, of a concessionaire. Predictive models were created for each sector (industrial, commercial, residential and rural) using a temporal variable, the number of consumers and the decomposed value of seasonality. The historical data provided by the concessionaire were consumption and the number of electricity consumers in the period from January 2003 to June 2017, stratified by sectors in monthly periods. As a result, models with a determination coefficient above 0.5 for the industrial sector and above 0.9 for the commercial, residential and rural sectors were obtained.

Resumo: A previsão do consumo de eletricidade é essencial para as concessionárias de distribuição de energia elétrica uma vez que pode auxiliar, principalmente, nas decisões relacionadas ao core business dessas empresas. Este trabalho apresenta modelos lineares para a previsão de demanda de energia elétrica, a curto e médio prazos, de uma concessionária. Os modelos preditivos foram criados por setor (industrial, comercial, residencial e rural) utilizando uma variável temporal, o número de consumidores e o valor decomposto da sazonalidade. Os dados históricos fornecidos pela concessionária foram o consumo e o número de consumidores de energia elétrica no período janeiro de 2003 a junho de 2017, estratificados por setores em períodos mensais. Como resultado, obteve-se modelos com coeficiente de determinação acima de 0,5 para o setor industrial e acima de 0,9 para os setores comercial, residencial e rural.

Keywords: electricity consumption forecasting; mathematical modeling; decision making; statistical analysis; linear regression.

Palavras-chaves: previsão de consumo de eletricidade; modelagem matemática; tomada de decisão; análise estatística; regressão linear

1. INTRODUÇÃO

Nas últimas três décadas a matriz de geração de energia elétrica vem sendo alterada no Brasil e em várias partes do mundo, causando grandes mudanças no perfil de oferta de eletricidade. No Brasil, a divisão do setor elétrico compreende os sistemas de Geração, de Transmissão e de Distribuição. Compete à Agência Nacional de Energia Elétrica (ANEEL) regular o setor elétrico visando a garantia do suprimento de energia aos consumidores de forma mais confiável e com menos interrupção. O atual modelo do setor elétrico brasileiro define que a comercialização de eletricidade no mercado consumidor seja realizada no Ambiente de Contratação Regulada (ACR) e no Ambiente

de Contratação Livre (ACL). Para alcançar a modicidade tarifária, foram instituídos no modelo atual os leilões, que funcionam como instrumento de compra de energia elétrica pelas distribuidoras no ambiente regulado. Para garantir o equilíbrio do setor, além da modicidade tarifária também é considerado o equilíbrio econômico-financeiro das concessionárias de distribuição de energia elétrica. Assim, a tarifa de energia do setor elétrico é o reflexo de suas próprias características físicas, operacionais e contratuais, associadas a fatores que o influenciam e o afetam direta ou indiretamente. Neste contexto, fazer a previsão do consumo de eletricidade tornou-se um elemento fundamental para a tomada de decisão, e a sua importância e procura pela precisão vem aumentando desde a onda de desregu-

lamentação e liberalização do setor elétrico. Atualmente, a previsão de energia elétrica é um componente essencial da rede inteligente e vem atraindo progressivamente o interesse acadêmico [Wang et al., 2017a,c, Divina et al., 2017].

A eletricidade pode ser vista como uma mercadoria essencial para o mundo atual. Contudo, a eletricidade gerada nas usinas de geração não é armazenável e a estabilidade do sistema de energia requer um equilíbrio constante entre produção e consumo. Para as distribuidoras de energia elétrica, o gerenciamento do lado da demanda pode tornar-se uma boa alternativa ao considerar as dificuldades enfrentadas na avaliação da expansão do mercado consumidor a curto, médio ou longo prazo. Neste caso, as previsões de consumo a curto e médio prazos podem desempenhar um importante papel na gestão do fornecimento de energia elétrica, no planejamento da energia e na formulação de políticas [Wang et al., 2017a, Divina et al., 2017, Hamzaceb e Es, 2017, Wang et al., 2017b]. A consideração de incertezas no sistema de previsão é imperativo, pois permite a avaliação de riscos na compra e venda no mercado futuro de energia elétrica reduzindo erros de planejamento da distribuidora. Como consequência, reduz-se o risco de migração de consumidores cativos da classe industrial para o mercado livre.

Considerando o cenário apresentado, surgem algumas perguntas: a) como uma distribuidora poderá comprar uma quantidade de energia elétrica que atenda ao seu mercado consumidor com o menor erro possível, ao procurar aproximar-se do equilíbrio quantitativo entre oferta e demanda?; e b) é possível fazer previsão do consumo de energia elétrica em larga escala considerando as variáveis dos dados históricos de consumo e do número de consumidores? O problema motivador deste trabalho foi encontrar modelos preditivos para esta última questão.

Este artigo está organizado da seguinte forma: a seção 2 apresenta os trabalhos relacionados; a seção 3 descreve os materiais e métodos utilizados; a seção 4 apresenta e discute os resultados obtidos; a seção 5 exhibe as considerações finais; e a seção 6 mostra os agradecimentos.

2. TRABALHOS RELACIONADOS

Wang et al. [2017c] desenvolveram técnicas de previsão linear, híbrida-linear e não-linear baseadas na teoria do modelo cinza para prever com maior precisão a demanda de energia na China e na Índia. Essas técnicas foram aplicadas para fazer a previsão do consumo de energia e quantificar a taxa de crescimento prevista para o período de 2017 a 2026. A qualidade de cada técnica de previsão proposta foi avaliada observando-se o mapa de tendência, a medida de erro e o método de ajuste. Constatou-se que os modelos propostos têm um alto grau de ajuste, uma baixa taxa de erros e alta precisão de ajuste e que podem produzir resultados confiáveis de previsão.

Wang et al. [2017a] apresentaram um novo modelo de previsão anual do consumo de energia elétrica, que obtém simultaneamente resultados com maior precisão e maior estabilidade do que métodos convencionais. Esse novo modelo híbrido baseia-se em um método de previsão modelo cinza otimizado por algoritmo multiobjetivo.

Divina et al. [2017] propuseram uma estratégia de previsão de demanda a curto prazo baseada na técnica *Ensemble Learning* (aprendizado compartilhado). As previsões decorrentes de três métodos básicos foram aplicadas em um método de nível superior para obter previsões finais com menor erro. Nesse procedimento, foram usados os dados históricos de consumo de eletricidade registrados na Espanha em mais de nove anos. No sistema proposto, os resultados que são alcançados através de métodos convencionais são combinados entre si para obter resultados mais precisos na previsão de consumo de eletricidade a curto prazo. Concluíram que através do compartilhamento entre métodos convencionais pode-se melhorar as previsões de consumo obtidas através de métodos simples.

Oliveira e Oliveira [2017] desenvolveram um método de previsão de consumo de energia elétrica a médio/longo prazos para atender com maior precisão a demanda mensal de energia elétrica requerida pelos consumidores de países desenvolvidos e em desenvolvimento. Visando promover o suprimento adequado de energia elétrica, o método consistiu na combinação de técnicas de decomposição e ensacamento (método *Bootstrap*) com métodos univariados e métodos de previsão de séries temporais. Concluiu-se que fatores externos como o PIB, que não são identificados pelos métodos de previsão univariados, interferem de maneira bastante significativa na variação do consumo mensal de energia elétrica. Os resultados finais apresentaram previsões mais precisas sobre o consumo de energia elétrica a médio e longo prazo do que métodos convencionais.

Meng et al. [2017] propuseram a utilização de um algoritmo de média móvel para decompor séries temporais de consumo de energia elétrica em várias ondas periódicas e destacar as tendências de crescimento de longo prazo. Nesse procedimento usaram modelos de Rede Neural Artificial para fazer a previsão das ondas periódicas extraídas e apresentaram um novo modelo de crescimento híbrido para prever a tendência crescente de extração das ondas. O modelo proposto foi comparado com outros três modelos, efetuando-se a previsão do consumo mensal de energia elétrica da China para o período de janeiro de 2011 a dezembro de 2012. O modelo proposto apresentou melhor desempenho quanto ao erro percentual absoluto médio e ao erro percentual absoluto máximo.

Ascanio e Mate [2017] apresentaram uma comparação entre a abordagem sobre modelos de previsão vetoriais autorregressivos aplicados em séries temporais intervalares e o modelo de perceptron de camada adaptado a dados de intervalo. O objetivo do trabalho era fazer previsão de demanda mensal de energia elétrica registrada hora a hora na Espanha por um período de 2 anos. Com essa abordagem, foi possível definir qual representação de intervalo assumido pelas séries temporais intervalares (ITS) é mais precisa ao longo do dia. Por meio de comparação entre as técnicas adaptadas a ITS, foi possível identificar a eficiência dos modelos na previsão da demanda de eletricidade. Os resultados obtidos com os métodos de previsão de ITS apresentaram significativa redução do risco de erro de planejamento do sistema de energia.

Srinivasan [2017] desenvolveu um sistema modular composto por modelos de alta precisão para previsão de

demanda de eletricidade de médio prazo. O sistema foi planejado e executado separadamente por cada classe de consumidores para identificar a necessidade efetiva e fazer a previsão de demanda de energia para as classes residencial, industrial, comercial, não industrial, de entretenimento e iluminação pública. Com o objetivo de produzir melhores resultados a cada momento, a previsão mensal de energia elétrica por classe de consumidores foi processada através da comparação entre os resultados obtidos com diversos métodos de redes neurais artificiais. Por exemplo, nesse procedimento a rede neural de manipulação de dados de grupo foi mais precisa do que os modelos de regressão e séries temporais tradicionais.

Saab et al. [2017] desenvolveram um estudo de modelagem e previsão de consumo de energia elétrica para investigar diferentes metodologias de modelagem univariada e fazer a previsão do consumo mensal de energia elétrica no Líbano. O estudo compreendeu a aplicação dos seguintes modelos univariados: autorregressivo, de média móvel integrada autorregressiva e uma nova configuração combinando um AR (1) com um filtro de alta frequência. Quanto ao desempenho, o modelo de filtro AR (1) / highpass produziu a melhor previsão.

Libório et al. [2018] apresentaram um metodologia de previsão de demanda da Internet por séries temporais usando uma grande variedade de dados históricos, obtidos através da União Internacional de Telecomunicações, do Banco Mundial e de agências governamentais. A metodologia utiliza conceitos e modelos estatísticos para deduzir a relação existente entre variáveis de entrada e a taxa de largura de banda de dados, considerando o crescimento populacional e o desenvolvimento social e tecnológico. A técnica de regressão dinâmica foi o modelo escolhido para realização do trabalho. Esta técnica consegue identificar a relação comportamental existente entre a variável dependente e algumas variáveis explicativas. O agrupamento de variáveis é analisado para indicar tendências da previsão por séries temporais. A metodologia proposta também pode ser aplicada em estimativa de consumo de petróleo, energia elétrica, água, etc. Concluiu-se que fatores ligados à inovação e a tecnologia afetam a previsão anual da demanda da Internet.

3. MATERIAIS E MÉTODOS

Os estudos realizados neste trabalho foram feitos utilizando uma base em dados históricos fornecidos por uma concessionária de distribuição de energia elétrica (doravante chamada de Concessionária). O banco de dados fornecido pela Concessionária contempla o consumo (kWh) e o número de consumidores de energia elétrica registrados por classes de consumidores no período janeiro de 2003 a junho de 2017, estratificado por classes de consumidores em períodos mensais.

Os experimentos e análises foram feitos utilizando a linguagem de programação estatística R, versão 3.6.3. Todos os modelos seguiram a fórmula $y = \beta x + \epsilon + \delta$, sendo y o valor esperado, x o vetor de variáveis, β o vetor de coeficientes angulares, ϵ o coeficiente de interceptação e δ a variável de sazonalidade referente ao mês do setor, caso aplicável. Na construção dos modelos de predição, os dados

até 2016 foram utilizados como conjunto de treinamento, e os dados de 2017 foram utilizados para teste.

A variáveis consideradas durante o estudo são mostradas na Tabela 1.

Tabela 1. Variáveis utilizadas no estudo

Abreviação	Nome da Variável
Data	Data (mês e ano)
Res..kWh.	Consumo residencial (kWh)
Ind..kWh.	Consumo industrial (kWh)
Com..kWh.	Consumo comercial (kWh)
Rural..kWh.	Consumo rural (kWh)
PP..kWh.	Consumo prédio público (kWh)
IP..kWh.	Consumo iluminação pública (kWh)
SP..kWh.	Consumo serviço público (kWh)
CP..kWh.	Consumo próprio (kWh)
NC.Res	Número de consumidores do setor residencial
NC.Ind	Número de consumidores do setor industrial
NC.Com	Número de consumidores do setor comercial
NC.Rural	Número de consumidores do setor rural
NC.PP	Número de consumidores do setor prédio público
NC.IP	Número de consumidores do setor iluminação pública
NC.SP	Número de consumidores do setor serviço público
NC.CP	Número de consumidores do setor próprio

4. RESULTADOS E ANÁLISES

A Figura 1 mostra a distribuição porcentual da média dos consumos mensais separados por setor. Nela, é possível verificar que o setor industrial é o setor responsável pela maior parte do consumo da Concessionária, com cerca de 58% do consumo mensal, seguido pelos consumos residencial, comercial e rural, que representam, juntos, 35% do consumo da concessionária. Como os três consumos públicos e o consumo da própria concessionária representam menos de 10% do consumo total, eles foram desconsiderados nas análises seguintes.




Figura 1. Gráfico das médias dos consumos mensais separados por setor

A Figura 2 mostra a matriz de correlação entre as variáveis fornecidas pela Concessionária. É possível verificar que existem correlações no consumo entre os setores, com exceção do setor industrial. Além disso, é possível verificar que existem correlações entre os números de consumidores de cada setor. Não é possível observar correlação entre o consumo industrial e as outras variáveis fornecidas pela Concessionária.




Figura 2. Matriz de correlação entre as variáveis fornecidas pela Concessionária

As Figuras 3-6 mostram os gráficos de distribuição temporal do consumo e do número de consumidores separados por setor. É possível perceber que existe uma tendência de crescimento anual nos consumos residencial, comercial e rural, assim como existe uma tendência de crescimento nos seus números de consumidores, além de existir uma tendência de crescimento no número de consumidores industriais. A Figura 7 mostra a decomposição das séries temporais dos dados de consumo, separando-os segundo sua tendência, sazonalidade e aleatoriedade.




Figura 3. Gráfico de consumo e número de consumidores mensais para o setor residencial.




Figura 4. Gráfico de consumo e número de consumidores mensais para o setor comercial.




Figura 5. Gráfico de consumo e número de consumidores mensais para o setor rural.




Figura 6. Gráfico de consumo e número de consumidores mensais para o setor industrial.




Figura 7. Decomposição das séries temporais separadas por setor. Para cada setor é mostrado, em ordem, os dados originais, a tendência, a sazonalidade e a aleatoriedade.

Considerando os dados apresentados nas Figuras 2-7, foram criados modelos lineares preditivos para cada setor utilizando a variável temporal, o número de consumidores, e o valor decomposto da sazonalidade. Para realizar previsões, foi desenvolvido um modelo linear para o número de consumidores de forma similar, e os valores previstos para 2017 foram utilizados nos modelos de consumo. As Tabelas 2-9 mostram os coeficientes dos modelos obtidos. As Figuras 8-15 mostram as previsões feitas para os modelos, sendo que as linhas pretas mostram os dados originais, as azuis os dados obtidos no treinamento, e as vermelhas os dados obtidos nos testes. A Tabela 10 mostra os resultados dos modelos obtidos.

Tabela 2. Modelo de previsão de número de consumidores residenciais

Variável	Valor Estimado	Erro Padrão	Valor p
ϵ	-6.036e05	4.073e04	2e-16
Data	4.238e02	2.777e00	<2e-16




Figura 8. Modelo de previsão de número de consumidores residenciais

Tabela 3. Modelo de previsão de número de consumidores comerciais

Variável	Valor Estimado	Erro Padrão	Valor p
ϵ	-9.976e04	1.263e04	3.69e-13
Data	4.885e01	8.611e-01	< 2e-16




Figura 9. Modelo de previsão de número de consumidores comerciais

Tabela 4. Modelo de previsão de número de consumidores rurais

Variável	Valor Estimado	Erro Padrão	Valor p
ϵ	-5.523e05	2.720e04	<2e-16
Data	7.477e01	1.855e00	<2e-16




Figura 10. Modelo de previsão de número de consumidores rurais

Tabela 5. Modelo de previsão de número de consumidores industriais

Variável	Valor Estimado	Erro Padrão	Valor p
ϵ	4.407e04	1.121e03	<2e-16
Data	2.011e00	7.641e-02	<2e-16




Figura 11. Modelo de previsão de número de consumidores industriais

Tabela 6. Modelo de previsão de consumo residencial

Variável	Valor Estimado	Erro Padrão	Valor p
ϵ	-1.364e05	3.451e04	0.000115
Data	-5.238e01	1.835e01	0.004864
δ	1.015e00	1.149e-01	1.51e-15
NC.Res	2.792e-01	4.314e-02	1.07e-09




Figura 12. Modelo de previsão de consumo residencial

Tabela 7. Modelo de previsão de consumo comercial

Variável	Valor Estimado	Erro Padrão	Valor p
ϵ	-3.847e05	1.396e04	< 2e-16
Data	2.286e01	3.663e00	3.57e-09
δ	1.030e00	6.180e-02	< 2e-16
NC.Com	7.544e-01	7.313e-02	< 2e-16




Figura 13. Modelo de previsão de consumo comercial

Tabela 8. Modelo de previsão de consumo rural

Variável	Valor Estimado	Erro Padrão	Valor p
ϵ	-2.177e05	2.615e04	3.11e-14
Data	2.696e01	3.137e00	6.30e-15
δ	9.937e-01	4.325e-02	< 2e-16
NC.Rural	6.320e-02	3.994e-02	0.116




Figura 14. Modelo de previsão de número de consumo rural

Tabela 9. Modelo de previsão de consumo industrial

Variável	Valor Estimado	Erro Padrão	Valor p
ϵ	4.770e05	5.383e05	0.376974
Data	5.911e02	1.257e02	5.55e-06
δ	5.735e-01	2.492e-01	0.022644
NC.Ind	2.719e01	7.444e00	0.000352
NC.Res	-1.267e00	2.825e-01	1.41e-05
NC.Com	-3.127e00	8.340e-01	0.000248
NC.Rural	-3.380e-01	3.963e-01	0.395087
Res..kWh.	-2.417e-01	4.590e-01	0.599272
Com..kWh.	3.598e-01	6.582e-01	0.585432
Rural..kWh.	1.065e00	4.418e-01	0.017108




Figura 15. Modelo de previsão de consumo industrial

Tabela 10. Estatísticas dos modelos

Modelo	R ²	R ² (adj)	RMSE Treino	RMSE Teste	df	Valor p
NC.Res	0.9929	0.9929	52814.23	18304.91	166	2.2e-16
NC.Com	0.9509	0.9506	16377.46	26189.631	166	2.2e-16
NC.Rural	0.9073	0.9068	35272.26	39541.08	166	2.2e-16
NC.Ind	0.8067	0.8055	1453.195	3751.051	166	2.2e-16
Res.kWh.	0.9218	0.9204	29174.28	35109.71	164	2.2e-16
Com.kWh	0.9723	0.9718	15337.26	47936.46	164	2.2e-16
Rural.kWh	0.9118	0.9102	18024.94	22067.2	164	2.2e-16
Ind.kWh	0.5537	0.5283	117608.8	76144.12	158	2.2e-16

É possível perceber, analisando as figuras e tabelas, que o modelo de previsão de número de consumidores residenciais foi muito próximo do valor real, tendo somente uma variação no ano de 2004. Os modelos de número e consumidores comercial e rural também podem ser considerados boas aproximações. O modelo de número de consumidores industriais precisa de ser analisado com mais variáveis.

Quanto aos modelos de consumo, é possível perceber que o modelo de consumo comercial sofreu *overfit*, devido à variação do RMSE de teste e de treino. Além disso, é possível perceber que a variação no consumo rural é principalmente sazonal, sendo que ele não necessita do número de consumidores, como pode ser visto pelo valor p da variável NC.Rural do modelo. O modelo de consumo industrial é influenciado pelas variáveis temporal e sazonal, número de consumidores residencial, comercial e industrial, e pelo consumo rural. No entanto, é necessário analisar mais variáveis para melhorar o modelo do consumo.

5. CONSIDERAÇÕES FINAIS

O trabalho apresentou modelos para a previsão de demanda de energia elétrica em diferentes classes de consumo de energia elétrica. A análise de comportamento futuro poderá orientar a distribuidora de energia no gerenciamento das incertezas do mercado. Como resumo dos

resultados, os modelos de consumos das classes residencial e comercial dependem dos seus números de consumidores, com variações sazonais que podem ser previstas de acordo com o mês. O modelo de consumo da classe rural não depende do número de consumidores, e a previsão pode ser feita utilizando somente as variáveis temporais. Os modelos desses setores possuem R^2 acima de 0,9. Por outro lado, o modelo da classe industrial depende de mais variáveis, e possui R^2 em torno de 0,5.

Como continuação do trabalho, pretende-se criar novos modelos utilizando técnicas mais aprimoradas de modelagem, como Redes Neurais e Programação Genética. Além disso, pretende-se utilizar variáveis macroeconômicas, como PIB, IPCA e Taxa de Desemprego, para tentar aprimorar a qualidade dos modelos, principalmente o de consumo industrial.

6. AGRADECIMENTOS

Estudo financiado em parte pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) - Fin. Cód. 001, Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) - No. 311032/2016-8 e 406011/2016-8, e Companhia Vale - P&D 2019-2022 “Pesquisa em Planejamento e Suporte a Tomada de Decisão”.

REFERÊNCIAS

- Ascanio, C.G. e Mate, C. (2017). Electric power demand forecasting using interval time series: A comparison between var and impl. *Energy Policy*.
- Divina, F., Gilson, A., F. G. Vela, M.G.T., e Torres, J.F. (2017). Stacking ensemble learning for short-term electricity consumption forecasting. *Energies*.
- Hamzaceb, C. e Es, H.A. (2017). Forecasting the annual electricity consumption of turkey using an optimized grey model. *Energy*.
- Libório, M., Coelho, T.M., Bernardes, P., Machado, A., Ekel, P., e Soares, G. (2018). Forecasting internet demand using public data: a case study in brazil. *IEEE Access*.
- Meng, M., Niu, D., e Sun, W. (2017). Forecasting monthly electric energy consumption using feature extraction. *Energies*.
- Oliveira, E.M. e Oliveira, F.L.C. (2017). Forecasting mid-long term electric energy consumption through bagging arima and exponential smoothing methods. *Energy*.
- Saab, S., Badr, E., e Nasr, G. (2017). Univariate modeling and forecasting of energy consumption: the case of electricity in lebanon. *Energy*.
- Srinivasan, D. (2017). Energy demand prediction using gmdh networks. *Neurocomputing*.
- Wang, J., Du, P., Lu, H., Yang, W., e Niu, T. (2017a). An improved grey model optimized by multi-objective ant lion optimization algorithm for annual electricity consumption forecasting. *Applied Soft Computing*.
- Wang, J., Zhu, W., Zhang, W., e Sun, D. (2017b). A trend fixed on firstly and seasonal adjustment model combined with the epsilon-svr for short-term forecasting of electricity demand. *Energy Policy*.
- Wang, Q., Li, S., e Li, R. (2017c). Forecasting energy demand in china and india: Using single-linear, hybrid-linear, and non-linear time series forecast techniques. *Energy*.