



Grupo de Estudo de Planejamento de Sistemas Elétricos-GPL

Método de geração de cenários de longo prazo para a carga horária

**GUILHERME MEIRELLES BODIN DE MORAES(1); RAPHAEL AUGUSTO SAAVEDRA(1);
ALEXANDRE STREET(1); CRISTIANO FERNANDES(1);
PUC-Rio(1);**

RESUMO

A previsão de demanda energética numa janela de anos à frente constitui uma informação valiosa para o planejamento adequado do setor elétrico, seja para a expansão do sistema, para a operação ou para a contratação de montantes de uso de transmissão e distribuição (MUST). A previsão probabilística, realizada através da geração de cenários futuros, apresenta vantagens significativas sobre a previsão pontual, uma vez que possibilita o levantamento da distribuição de probabilidade da variável de interesse e permite análises de risco. Neste trabalho, propomos uma metodologia para gerar cenários de carga de longo prazo em frequência horária. A metodologia se divide em duas partes: na primeira, um modelo de séries temporais não-Gaussiano é utilizado para a modelagem de sinais elétricos mensais; na segunda, um modelo auto-regressivo quantílico conecta os cenários gerados pelo modelo anterior à carga horária. Um estudo de caso utilizando dados reais do sistema elétrico brasileiro ilustra o uso e a eficácia da metodologia proposta.

PALAVRAS-CHAVE

Previsão probabilística, demanda energética, modelos de séries temporais, modelos de regressão, simulação

1.0 - INTRODUÇÃO

O planejamento adequado é um dos pilares fundamentais do setor elétrico no Brasil e no mundo. Nesse contexto, previsões sobre o estado futuro do sistema devem ser realizadas em diversas instâncias, como, por exemplo, na operação diária [1]–[3] e na expansão da geração e transmissão [4]. Uma tendência observada recentemente na literatura de previsão no setor elétrico diz respeito à obtenção de simulação de cenários futuros [5]–[7], possibilitando assim a obtenção da distribuição probabilística dos valores futuros da variável de interesse. A partir desses valores simulados, torna-se possível obter quantis e intervalos de confiança e, portanto, estimar os riscos inerentes ao problema em questão.

Dentre os problemas que comumente utilizam cenários de demanda, destaca-se o da contratação dos montantes de uso dos sistemas de transmissão e distribuição (MUST e MUSD) por parte das distribuidoras. O mesmo desempenha um papel importante no planejamento da expansão do sistema, na medida em que busca criar as condições para uma previsão de demanda máxima robusta e assertiva, a partir de um mecanismo descentralizado baseado em incentivos financeiros. A acurácia dessa previsão é crucial para que o planejador possa identificar as necessidades de investimentos e de melhorias para atender à demanda e garantir a confiabilidade do sistema. Neste contexto, as regras contratuais constituem o principal mecanismo de indução dos agentes a uma previsão mais pessimista ou otimista. Em outras palavras, elas atuam como parâmetros de controle que o planejador emprega para ajustar a confiabilidade implícita nas previsões realizadas para o MUST. Se a demanda observada exceder o montante contratado – isto é, se a distribuidora subcontratar o MUST –,

além de pagar pelo montante excedente, ela será penalizada por expor o sistema ao risco de fornecimento. Por outro lado, se a distribuidora superestimar a demanda máxima, ela pode sofrer penalidades a fim de estimular estimativas mais adequadas e evitar investimentos excessivos. Através desse mecanismo descentralizado, o planejador deixa nas mãos das distribuidoras, as entidades que mais conhecem e possuem acesso às informações de suas respectivas redes e consumidores, a previsão de máxima demanda futura para cada ponto de conexão com o sistema de transmissão.

Técnicas mais recentes que produzem estimativas dessas contratações [8] envolvem formulações de otimização estocástica que utilizam cenários relacionados às incertezas do problema como insumos. Embora existam na literatura metodologias para a previsão e simulação de séries temporais que podem ser utilizadas para gerar esses cenários, há um desafio inerente à escala do problema, devido à necessidade de obter dados em frequência horária para um horizonte de anos à frente. Soluções factíveis para esses tipos de problemas geralmente exigem um sacrifício em relação a: (i) a frequência das séries a serem modeladas, tornando a escolha mensal em vez de horária, ou (ii) a sua janela de previsão, modelando apenas dias à frente em vez de anos.

Nesse artigo, propomos uma metodologia de simulação para obter cenários futuros de demanda horária em cada barra do sistema. O método conecta um modelo de simulação em frequência mensal de sinais energéticos, como energia requerida, a outro em frequência horária de carga nas barras. O objetivo é condicionar o modelo de carga horária a cenários de sinais energéticos que traduzam movimentos de aumento, diminuição ou estagnação. Este modelo permite que cada cenário de carga de cada barra do sistema esteja relacionado a um cenário de sinal energético, produzindo simulações coerentes com a evolução dos sinais energéticos observados.

A simulação mensal utiliza modelos de séries temporais com parâmetros variantes no tempo recentemente propostos na literatura, denominados modelos GAS (*generalized autoregressive score*) [9], enquanto a simulação horária, que tem como objetivo a caracterização da incerteza em alta frequência da demanda em cada barra, utiliza um modelo auto-regressivo quantílico [10]. Os modelos GAS oferecem vantagens significativas em relação aos modelos mais clássicos de séries temporais (da classe ARIMA), cabendo destacar a possibilidade do usuário escolher distribuições não-Gaussianas para as séries energéticas, o que elimina a possibilidade de simular cenários incoerentes (por exemplo, geração negativa), um risco presente no uso de modelos Gaussianos.

O restante deste artigo é organizado da seguinte forma: na Seção 2, a metodologia de simulação de cenários, compreendendo os modelos mensal e horário, é apresentada. Na Seção 3, um estudo de caso com dados reais do sistema elétrico brasileiro é realizado para ilustrar o uso da metodologia proposta. Finalmente, conclusões são levantadas na Seção 4.

2.0 - METODOLOGIA

O arcabouço desenvolvido possui duas etapas principais. A primeira é responsável pela caracterização das séries mensais de sinais energéticos (por exemplo, demanda ou consumo de energia). Nessa etapa, a modelagem é realizada através de um modelo GAS não-Gaussiano, onde o valor esperado condicional da série é decomposto em componentes estocásticas de tendência linear e sazonalidade. O resultado dessa etapa é a geração de diversos cenários futuros em frequência mensal para os sinais utilizados. O objetivo principal do modelo mensal é a obtenção de cenários que caracterizem o comportamento de mensal da série e que tenham o potencial de transferir essa informação para o modelo horário.

Na próxima etapa, os resultados da modelagem mensal são conectados à modelagem na frequência horária, que utiliza um modelo auto-regressivo quantílico. Esse modelo recebe o histórico de carga das barras do sistema em frequência horária e os sinais energéticos em frequência mensal. O objetivo deste modelo é caracterizar os movimentos em frequência horária através dos termos autoregressivos e os em frequência mensal através dos sinais energéticos. Uma vez estimados os parâmetros, os cenários em frequência mensal gerados na primeira etapa são utilizados para a geração de cenários de carga em frequência horária nas barras do sistema.

2.1 Modelo GAS para simulação de cenários mensais

Seja E_m uma série de sinal energético, como consumo de energia, por exemplo, no mês m . Considere um parâmetro variante no tempo f_m , um vetor de variáveis explicativas x_m e um vetor de parâmetros fixos ψ . Definindo $E^m = \{E_1, \dots, E_m\}$, $F^m = \{f_0, \dots, f_m\}$, $X^m = \{x_1, \dots, x_m\}$, então o conjunto de informação disponível no mês m é $\{f_m, F_m\}$, onde $F_m = \{E^{m-1}, F^{m-1}, X^m\}$, $\forall m \in M$.

Assumimos que E_m seja gerado por uma função de densidade de probabilidade condicional arbitrária $p(E_m \mid f_m, F_m; \psi)$, possivelmente não-Gaussiana. A evolução do modelo é definida pelo mecanismo de atualização do

parâmetro variante no tempo f_m . Modelos GAS podem ter esse mecanismo modelado em um arcabouço SARIMA ou via componentes não-observáveis. No primeiro caso, o parâmetro variante no tempo é atualizado através de uma equação auto-regressiva com choques dados pelo vetor *score*, apresentando semelhança aos modelos SARIMA; mais detalhes sobre essa formulação podem ser encontrados em [7] e [9]. No presente artigo, utilizamos o arcabouço de componentes não-observáveis, que pode ser considerado mais flexível e adequado para séries de sinais energéticos em geral. Essa vantagem está ligada à possibilidade de descrever as séries a partir de fatos estilizados observados, como tendência, inclinação e sazonalidade, sendo assim independente da definição de um conjunto de *lags* arbitrários. No arcabouço de componentes não-observáveis, definimos que o parâmetro variante no tempo f_m – geralmente modelado como o valor esperado condicional da variável de interesse – segue um modelo estrutural básico [11]:

$$\begin{aligned} f_m &= \mu_m + \gamma_m + \theta^\top X_m, \\ \mu_{m+1} &= \mu_m + v_m + \kappa_1 s_m, \\ v_{m+1} &= v_m + \kappa_2 s_m, \\ \gamma_{m+1} &= - \sum_{j=1}^{11} \gamma_{m+1-j} + \eta_m s_m, \end{aligned}$$

onde μ_m representa a tendência, v_m a inclinação e γ_m a sazonalidade da série observada no mês m . Essas componentes não-observáveis ditam o comportamento da série e são estimadas através do modelo GAS.

Para completar a descrição do mecanismo de atualização GAS, é necessário definir o *score* ponderado s_m , que possui o papel de choque aleatório no modelo anterior. Os autores em [9] propõem a seguinte definição:

$$\begin{aligned} s_m &= I^{-d} \cdot \nabla_m, \\ I &= E[\nabla_m^\top \nabla_m], \\ \nabla_m &= \partial \ln p(E_m | f_m, F_m; \theta) / \partial f_m, \end{aligned}$$

onde m é a função *score* e I^{-d} é uma matriz de ponderação. O valor de d pode ser empiricamente selecionado baseado em diagnósticos e aderência. Valores comumente empregados para d são: $d = 0, \frac{1}{2}, 1$.

A estimação dos parâmetros constantes do modelo – nesse caso, $\psi = [\kappa_1, \kappa_2, \eta_m, \theta]$ – é realizada através da maximização da verossimilhança. Métodos de otimização não-linear como BFGS [12] e Nelder-Mead [13] podem ser empregados para resolver esse problema. A função de log-verossimilhança a ser maximizada é dada por:

$$l(\psi) = \sum_m \ln p(E_m | f_m, F_m; \theta)$$

Uma vez estimado o modelo, a geração de cenários é realizada via simulação Monte Carlo. Dessa forma, para cada cenário desejado, deve-se aplicar a recursão do modelo utilizando os parâmetros estimados e amostrar um valor a partir da distribuição obtida. O algoritmo é o seguinte:

Passo 1. Dado o vetor de parâmetros fixos obtido por máxima verossimilhança e a estimativa do parâmetro variante no tempo, f_{M+1} , amostrar cenários $\{E_{M+1}(\omega)\}$ para cada cenário ω desejado.

Passo 2. Utilizar os cenários simulados e a equação de recorrência do GAS para obter $\{f_{M+2}(\omega)\}$.

Passo 3. Repetir passos 1 e 2 para cada mês contemplado no período de simulação.

Suponha agora que queremos estimar um modelo GAS gama. A distribuição gama é interessante para modelar séries energéticas por sua flexibilidade de formato e seu suporte positivo. Definindo a seguinte parametrização:

$$p(E_m | f_m, F_m; \theta) \sim \text{Gama}(\alpha, \lambda_m / \alpha),$$

onde α e λ_m são parâmetros da distribuição necessariamente positivos. Segue que a média e variância condicionais da variável de interesse são, respectivamente:

$$E[E_m | \alpha, \lambda_m] = \lambda_m, V[E_m | \alpha, \lambda_m] = \lambda_m^2 / \alpha.$$

Por sua vez, a função de log-verossimilhança é dada por

$$l(\psi) = \sum_m \left[\ln \Gamma(\alpha) + \alpha \ln \alpha - \alpha \ln \lambda_m + (\alpha - 1) \ln E_m - \frac{\alpha}{\lambda_m} E_m \right].$$

O parâmetro variante no tempo pode ser definido como $f_m = \ln \lambda_m$, de forma que a média condicional da variável de interesse é dada diretamente pela exponencial de f_m . Finalmente, utilizando a definição previamente apresentada, a expressão do *score* ponderado fica da seguinte forma:

$$s_m = \alpha^{d+1} \left(\frac{E_m}{\lambda_m} - 1 \right).$$

Com isso, basta realizar a estimação por máxima verossimilhança seguida da simulação Monte Carlo, conforme os algoritmos apresentados. Um estudo de caso utilizando o modelo GAS gama e dados reais do sistema elétrico brasileiro está disponível na Seção 3.

2.2 Modelo auto-regressivo quantílico para simulação horária de carga nas barras do sistema

Para simplificar a notação utilizada na descrição deste modelo vamos considerar que os subscritos d , h e m são funções de um dado instante de tempo t , definido por uma data. Se temos uma variável com $a_{d,h,m}$ deve-se entender que os índices d , h e m na realidade são funções de um instante t . Escrevendo de forma rigorosa, teríamos uma variável $a_{d(t),h(t),m(t)}$ significando que essa variável está associada ao dia $d(t) \in \text{Dias}$, $h(t) \in \text{Horas}$ e $m(t) \in \text{Meses}$.

Sejam os conjuntos $\text{Dias} = \{1, \dots, 7\}$, $\text{Horas} = \{1, \dots, 24\}$, $\text{Meses} = \{1, \dots, 12\}$, o número de sinais energéticos distintos J e $p_{d,h,b}$ a carga da barra b na hora h e no dia da semana d . Utilizaremos um modelo auto-regressivo quantílico com regularização l_1 [14] para cada barra, cada dia da semana e cada hora do dia. A motivação por trás de um modelo quantílico está relacionada ao fato de as séries horárias de carga costumarem ser bastante mal comportadas. Desta forma, utilizar um modelo robusto a *outliers* é adequado.

Em um modelo auto-regressivo quantílico, o quantil condicional é estimado calculando valores de parâmetros W associados a termos auto-regressivos e variáveis explicativas. Em [15], é mostrado que o processo de estimação de parâmetros é dado pela resolução de um problema de otimização onde deve-se minimizar uma função dos erros ε . Tal função é definida pela equação abaixo onde o termo τ é o quantil a ser encontrado.

$$\rho_\tau(\varepsilon) = \begin{cases} \tau \varepsilon, & \varepsilon \geq 0 \\ (1 - \tau) \varepsilon, & \varepsilon < 0 \end{cases}$$

Para adicionar regularização l_1 ao modelo, devemos adicionar um novo termo na função objetivo que minimiza a soma dos valores absolutos dos parâmetros. Desta forma, o problema de otimização conta com dois termos na função objetivo. Para obter a melhor regularização possível, podemos adicionar outro parâmetro $\lambda_{d,h,b}$, definindo uma combinação convexa entre o mínimo erro dado pela função ρ_τ e o valor absoluto dos parâmetros, de forma a criar uma ponderação entre os mesmos.

Para este modelo definimos o vetor de parâmetros como $W = \{w_{d,h,b,0}, \dots, w_{d,h,b,J+11}\}$. O modelo conta com *lags* no dia da semana $p_{d-1,h,b}$ e *lags* para a hora do dia $p_{d,h-1,b}$. Em condições de contorno como a primeira hora do dia, o termo de *lag* no dia da semana se torna a última hora do dia anterior. Além dos termos auto-regressivos, o modelo explora os cenários de sinais energéticos mensais $E_m(\omega)$ obtidos conforme descrito na Seção 2.1 para guiar os movimentos em frequência mensal da carga. Para capturar os movimentos sazonais, o modelo também conta com variáveis *dummies* D_m que ditam o nível de carga em cada mês do ano. A expressão geral para um modelo dados uma barra, um dia da semana e uma hora do dia fica:

$$\hat{p}_{d,h,b} = w_{d,h,b,0} + w_{d,h,b,1} p_{d,h-1,b} + w_{d,h,b,2} p_{d-1,h,b} + \sum_{j=3}^J w_{d,h,b,j} E_m + \sum_{k=J+1}^{J+11} w_{d,h,b,k} D_m.$$

Dessa forma temos um modelo auto-regressivo quantílico para cada dia da semana e para cada hora do dia, totalizando 168 modelos auto-regressivos por barra do sistema. Os parâmetros $W = \{w_{d,h,b,0}, \dots, w_{d,h,b,J+11}\}$ são estimados usando uma formulação de programação linear para cada barra do sistema. O modelo é flexível para todos os quantis τ .

$$\min(1 - \lambda_{d,h,b}) \sum \rho_{\tau}(\varepsilon_{d,h,b}) + (\lambda_{d,h,b}) \sum_{j=1}^{J+11} w_{d,h,b,j} v$$

$$\varepsilon_{d,h,b} = p_{d,h,b} - \hat{p}_{d,h,b}$$

Observe que o modelo é separável, podemos fazer um modelo para cada dia da semana, hora do dia e barra separadamente, isso permite que as estimações sejam feitas de maneira independente tornando o modelo escalável. Como cada uma das estimações independentes não é computacionalmente exaustiva é viável paralelizar a estimação. Para transformar este modelo em um problema de programação linear é necessário fazer uma transformação nas variáveis onde usamos o valor absoluto. As variáveis com um sobrescrito “+” representam a parte positiva da variável original e as variáveis com um sobrescrito “-” representam a parte negativa da variável original.

$$|w_{d,h,b,j}| = w_{d,h,b,j}^{++w_{d,h,b,j}^-}$$

$$w_{d,h,b,j} = w_{d,h,b,j}^{+-w_{d,h,b,j}^-}$$

$$\rho_{\tau}(\varepsilon_{d,h,b}) = \tau \varepsilon_{d,h,b}^{++(1-\tau)\varepsilon_{d,h,b}^-}$$

$$\varepsilon_{d,h,b} = \varepsilon_{d,h,b}^{+-\varepsilon_{d,h,b}^-}$$

Para encontrar o parâmetro de regularização $\lambda_{d,h,b}$ que melhor se adequa a cada modelo, realizamos a estimação para vários valores de $\lambda_{d,h,b}$ e aplicamos o critério BIC [16] para definir o valor ótimo. Uma vez que os parâmetros foram estimados, é possível estabelecer uma equação para a simulação de cenários de carga baseada não somente nos cenários gerados na Seção 2.1 mas também nos erros de estimação $\varepsilon_{d,h,b}^{+-\varepsilon_{d,h,b}^-}$. Para cada barra do sistema temos um conjunto de erros por hora do dia e por dia da semana. Podemos incorporar esses erros na equação de simulação a fim de capturar a variabilidade de cada série na frequência horária. Este processo é também conhecido como *bootstrap* [17]. Após a estimação, temos um vetor de parâmetros estimados e podemos escrever uma função de simulação $\hat{p}_{d,h,b}(W, \omega)$. Para realizar a simulação completa, devemos avaliar a função para todos os cenários $\omega \in \Omega$ e todos os instantes de tempo do período de simulação desejado $t \in T$:

$$\hat{p}_{d,h,b}(W, \omega) = w_{d,h,b,0} + w_{d,h,b,1} \hat{p}_{d,h-1,b} + w_{d,h,b,2} \hat{p}_{d-1,h,b} + \sum_{j=3}^J w_{d,h,b,j} Y_m(\omega) + \sum_{k=j+1}^{J+11} w_{d,h,b,k} D_m + \varepsilon_{d,h,b}(\omega) \forall \omega \in \Omega, t \in T .$$

3.0 - ESTUDO DE CASO

Para demonstrar o uso da metodologia proposta, realizamos um estudo de caso com dados reais do sistema elétrico brasileiro. Para o modelo mensal, utilizamos um modelo GAS com distribuição gama devido ao seu suporte positivo e à sua flexibilidade de formato. Aplicamos esse modelo a uma série de energia requerida de uma distribuidora do Grupo Energisa. Como variáveis explicativas, utilizamos a temperatura máxima da região e um índice econômico de emprego. O resultado está apresentado na Figura 1.

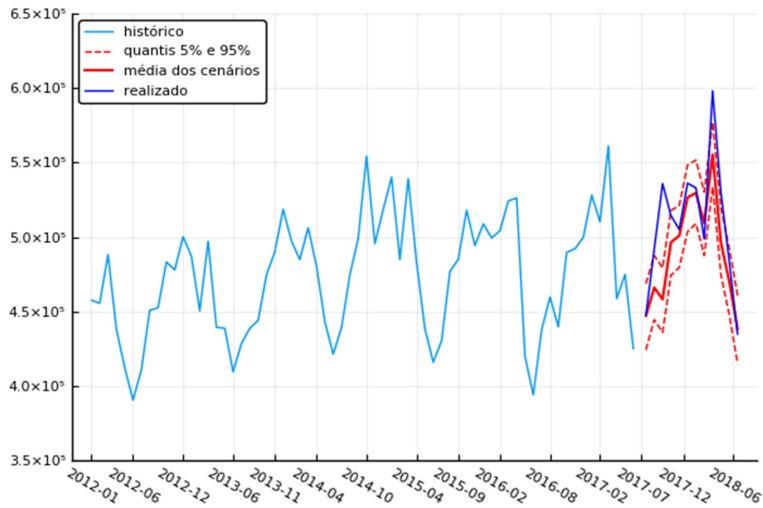


FIGURA 1 – Simulação de uma série de energia requerida.

Para avaliar o resultado obtido, utilizamos diagnósticos e estatísticas de aderência *out-of-sample*. No caso, o erro absoluto médio percentual *out-of-sample* foi de 3.81%, um valor bastante satisfatório. Como testes diagnósticos, utilizamos o teste Jarque-Bera de normalidade dos resíduos, o teste Ljung-Box de independência dos resíduos e o teste H de homoscedasticidade dos resíduos. Esses testes verificam, respectivamente, se os resíduos obtidos a partir do modelo estimado são normais, independentes entre si e possuem variância constante. Os p-valores resultantes dos testes estão na Tabela 1.

Tabela 1 – P-valores resultantes dos testes diagnósticos

Teste	P-valor
Jarque-Bera	0.17
Ljung-Box	0.73
Teste H	0.91

Portanto, em nenhum dos três testes a hipótese nula foi rejeitada no nível de significância de 95%, o que indica que o modelo foi estimado de forma satisfatória. Além disso, foi realizado um teste Z sobre os parâmetros associados às variáveis explicativas utilizadas e concluiu-se que ambas foram estatisticamente significantes.

Utilizando os históricos horários de carga nas barras, bem como a série de energia requerida e sua simulação, temos todos os dados necessários para prosseguir para o modelo horário. Seguindo os passos de estimação e simulação descritos na Seção 2.2 e utilizando $\tau = 0.5$, isto é, visando estimar a mediana da carga, geramos cenários futuros para 30 barras do sistema. Utilizamos o ano de 2016 para estimar o modelo e realizamos uma simulação para 4 anos a frente, ou seja, de janeiro de 2017 até dezembro de 2020. A Figura 2 ilustra o resultado.




FIGURA 2 – Simulação da demanda de uma barra em frequência horária

Para avaliar o resultado, comparamos com os dados realizados de janeiro de 2017 até agosto de 2018, A Tabela 2 mostra o resultado do erro médio absoluto simétrico percentual (SMAPE) e erro médio absoluto (MAE) comparando a média dos cenários gerados e os dados *out-of-sample*. Para este estudo o SMAPE é mais adequado que o erro médio absoluto percentual (MAPE) devido à presença de observações reais com valor zero.

Tabela 2 – Resultados

Barra	SMAPE (%)	MAE (MW)
1	3.29	0.781
2	5.12	0.571
3	7.47	2.182
4	3.13	4.424
5	2.60	1.507
6	2.52	3.003
7	4.94	2.038
8	3.34	1.011
9	3.42	1.078
10	8.41	8.875
11	4.12	6.24
12	3.02	3.669
13	3.93	3.917
14	3.85	0.075
15	3.79	3.793
16	3.01	0.910
17	4.58	0.363
18	4.28	2.676
19	3.16	1.554
20	3.54	1.852
21	3.63	1.204
22	2.95	0.580
23	2.77	0.657
24	3.63	0.769
25	4.41	0.352
26	3.15	1.997
27	5.82	1.233
28	3.51	1.660
29	3.45	0.821
30	5.18	0.705

Os indicadores dos resultados foram calculados usando as fórmulas abaixo, onde y_t representa o valor real e \hat{y}_t o valor previsto no instante t .

$$MAE = \sum y_t - \hat{y}_t \vee \frac{-}{n}$$

$$SMAPE = \frac{100\%}{n} \sum y_t - \hat{y}_t \vee \frac{(|y_t| + |\hat{y}_t|)/2}{-}$$

4.0 - CONCLUSÕES

A previsão probabilística de dados de carga em frequência horária em uma janela de anos à frente representa um desafio em aberto na literatura e um problema de interesse por parte de diversos agentes do setor elétrico. Neste artigo, propomos uma metodologia para simular cenários horários de carga que sejam coerentes com o comportamento de longo prazo do sistema. O arcabouço proposto consiste em um modelo de séries temporais não-Gaussiano em frequência mensal que se conecta a um modelo auto-regressivo quantílico em frequência horária.

A aplicação da metodologia em dados do Grupo Energisa resultou em cenários coerentes com os dados observados nas barras em geral, conforme indicado pelas estatísticas de aderência *out-of-sample*. A metodologia permite que aplicações relacionadas ao planejamento da operação e expansão sejam analisadas do ponto de vista probabilístico, o que permite estudos de análise de riscos e decisão sob incerteza, áreas de conhecimento que cada vez mais são usadas no setor elétrico brasileiro.

5.0 - AGRADECIMENTOS

Este trabalho foi parcialmente desenvolvido com o apoio do Grupo Energisa através do projeto de P&D ANEEL PD-00405-1701/2017. Os autores também reconhecem o apoio da CAPES e do CNPq.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] WOOD, A. J., WOLLENBERG, B. F., SHEBLÉ, G. B. Power Generation, Operation, and Control; 3ª edição, 2014.
- [2] ZHENG, Q. P., WANG, J., LIU, A. L. Stochastic optimization for unit commitment—A review; IEEE Transactions on Power Systems, vol. 30, no. 4, pp. 1913–1915, 2015.
- [3] HUANG, Y., PARDALOS, P. M., ZHENG, Q. P. Electrical Power Unit Commitment: Deterministic and Two-Stage Stochastic Programming Models and Algorithms; Springer, 2017.
- [4] HEMMATI, R., HOOSMAND, R. A., KHODABAKHSHIAN, A. Comprehensive review of generation and transmission expansion planning; IET Generation, Transmission & Distribution, vol. 7, no. 9, pp. 955–964, 2013.
- [5] STREET, A., VEIGA, A., LIMA, D., MOREIRA, A., FANZERES, B., GARCIA, J., FREIRE, L. Simulação da Geração de Usinas Renováveis Coerentes com os Cenários de Operação do Sistema Elétrico Brasileiro; In: XXII Seminário Nacional de Produção e Transmissão de Energia Elétrica, Brasília, Brasil, 2013.
- [6] SOUTO, M., MOREIRA, A., VEIGA, A., STREET, A., GARCIA, J., EPPRECHT, C. A high-dimensional VARX model to simulate monthly renewable energy supply; In: 2014 Power Systems Computation Conference, Wroclaw, Poland, 2014.
- [7] HOELTGEBAUM, H., FERNANDES, C., STREET, A. Generating Joint Scenarios for Renewable Generation: The Case for Non-Gaussian Models with Time-Varying Parameters; IEEE Transactions on Power Systems, vol. 33, no. 6, pp. 7011–7019, 2018.
- [8] TELLES, E., SAAVEDRA, R., BODIN, G., SILVA, T., MILHORANCE, A., FERNANDES, C., STREET, A., LEITE, A. Risk-Averse Contracting Strategy for the Transmission System Usage; In: L Simpósio Brasileiro de Pesquisa Operacional, Rio de Janeiro, Brasil, 2018.
- [9] CREAL, D., KOOPMAN, S. J., LUCAS, A. Generalized autoregressive score models with applications; Journal of Applied Econometrics, vol. 28, no. 5, pp. 777–795, 2013.
- [10] KOENKER, R., XIAO, Z. Quantile autoregression; Journal of the American Statistical Association, vol. 101, no. 475, pp. 980–990, 2006.
- [11] DURBIN, J., KOOPMAN, S. J. Time Series Analysis by State Space Methods; 2ª edição, 2012.
- [12] LIU, D. C., NOCEDAL, J. On the limited memory BFGS method for large scale optimization; Mathematical Programming, vol. 45, no. 1–3, pp. 503–528, 1989.
- [13] SINGER, S., NELDER, J. Nelder-Mead algorithm; Scholarpedia, vol. 4, no. 7, 2009.

[14] TIBSHIRANI R., Regression shrinkage and selection via the lasso; *Journal of The Royal Statistical Society, Series B*, vol. 58, pp. 267–288, 1994.

[15] KOENKER R., HALLOCK K. F. Quantile regression; *Journal of Economic Perspectives*, vol. 15, pp. 143–156, 2001

[16] WANG H., LI R., TSAI C.-L. Tuning parameter selectors for the smoothly clipped absolute deviation method; *Biometrika*, vol. 94, pp. 553–568, 2007

[17] EFRON B., TIBSHIRANI R. *An Introduction to the Bootstrap*; No. 57 in *Monographs on Statistics and Applied Probability*, Boca Raton, Florida, USA: Chapman & Hall/CRC, 1993

6.0 - DADOS BIOGRÁFICOS

Guilherme Bodin graduou-se em engenharia elétrica na PUC-Rio em 2018. Atualmente, é aluno de mestrado do Departamento de Engenharia Elétrica da PUC-Rio e pesquisador no *Laboratory of Applied Mathematical Programming and Statistics (LAMPS)* na PUC-Rio. Seus principais interesses são otimização, *data science* e desenvolvimento de software.



Raphael Saavedra graduou-se em engenharia elétrica na PUC-Rio em 2017. Atualmente, é aluno de mestrado do Departamento de Engenharia Elétrica da PUC-Rio e pesquisador no LAMPS. Seus principais interesses são otimização e suas aplicações em sistemas de potência, *machine learning* e *data science*, além de modelos de séries temporais com parâmetros variantes no tempo.

Alexandre Street possui mestrado e doutorado em engenharia elétrica pela PUC-Rio. Em 2008, ele se juntou ao Departamento de Engenharia Elétrica da PUC-Rio, onde é atualmente professor associado e leciona economia da energia, otimização e estatística. Ele é um dos fundadores do LAMPS, no qual é atualmente o diretor de pesquisa.

Cristiano Fernandes é Ph.D. em Estatística pela *London School of Economics* e Professor do Departamento de Engenharia Elétrica da PUC-Rio. Sua área de interesse é modelos não-Gaussianos com coeficientes variantes no tempo (espaço de estado e *score-driven models*) com aplicações em energia, seguros, atuária e varejo.