

MODELO ESTRUTURAL DINÂMICO COM COVARIÁVEIS PARA PREVISÃO DE CURTO-PRAZO DA PROCURA DE ENERGIA ELÉCTRICA NAS CIDADES ANGOLANAS

Dynamic Structural Model with Covariates for Short-term Forecast of Electricity Demand in Angolan Cities

PUINDI, António Casimiro¹, & SILVA, Maria Eduarda²

Resumo

A previsão de curto prazo da carga eléctrica é um importante instrumento para o planeamento dos sistemas de geração eléctrica, operações (programar a geração do fluxo da carga eléctrica necessária para o consumo) e controlo. Nesse estudo, o objectivo é o de mostrar como os efeitos das covariáveis podem ser incorporados em modelos de espaço de estados. Um modelo estrutural baseado em processos dinâmicos e um método para gerar as densidades preditivas e estimar o fluxo máximo da carga eléctrica consumida são examinados. O modelo e o método são empiricamente investigados, usando dados reais da procura diária de energia eléctrica na Cidade de Cabinda, para obter previsões de curto-prazo. A avaliação do desempenho da metodologia é feita comparando os valores previstos com os valores observados.

Abstract

Short-term electric load forecasting is an important tool for planning electrical generation systems, operations (scheduling the generation of electric load flow required for consumption) and control. In this study the aim is to show how the effects of covariates can be incorporated into state space models. A structural model based on dynamic processes and a method for generating predictive densities and estimating the maximum flow of the consumed electrical load are examined. The model and method are empirically investigated using actual data of daily electricity demand in Cabinda city to obtain short-term forecasts. The performance of the methodology is validated via comparisons using predicted values and observed values.

Palavras-chave: *Densidades preditivas; Energia eléctrica; Previsão da procura de electricidade; Sazonalidade.*

Key words: *Predictive densities; Electricity; Electricity demand forecast; Seasonality.*

Data de submissão: Dezembro de 2019 | **Data de publicação:** Março de 2020.

¹ ANTÓNIO CASIMIRO PUINDI – Instituto Superior de Ciências da Educação. Universidade 11 de Novembro, ANGOLA. Email: acpuindi@gmail.com.

² MARIA EDUARDA SILVA – Universidade do Porto. CIDMA & Faculdade de Economia. PORTUGAL.

INTRODUÇÃO

O estudo da procura de energia eléctrica é uma das preocupações mais importantes para os gestores de empresas de produção de electricidade, sobre tudo quando se pretende garantir a oferta suficiente de energia. Devido ao seu papel fundamental para o funcionamento eficaz e económico dos sistemas, é fundamental que os gestores primem por um planeamento baseado em previsões de curto-prazo para assegurar o equilíbrio entre a procura e a oferta. Muitas decisões operacionais são baseadas em previsões de curto prazo da carga eléctrica, tais como programar a geração do fluxo da carga eléctrica necessária para o consumo; a análise de fiabilidade e o plano de manutenção dos geradores (Shu & Hyndman, 2012). Quando se pretende estimar os fluxos de carga e controlar a geração e distribuição de energia eléctrica necessária, é fundamental conhecer a dinâmica da procura da carga eléctrica para garantir a oferta e assegurar o equilíbrio entre a procura e a oferta, bem como a qualidade do produto fornecido.

Os contínuos défices registados no fornecimento de energia eléctrica nas cidades angolanas, provocados pela falta de capacidade de resposta à crescente procura da carga eléctrica, impõem aos gestores da ENDE (Empresa Nacional de Distribuição de Electricidade de Angola) a compreensão da dinâmica dessa procura. Porém, a quantificação da previsão da dinâmica dessa procura é um processo matemático complexo, devido a vários factores que influenciam no comportamento do consumidor. Ademais, o confronto com a incerteza sobre o futuro é um facto irrefutável para qualquer gestor. Todavia, pode-se obter a medida de algumas incertezas em termos de probabilidades (Spiegelhalter, Pearson, & Short, 2011; Gneiting & Katzfuss, 2014; Taieb, Huser, & Genton, 2015).

As previsões probabilísticas servem para quantificar a incerteza, prevendo a distribuição de probabilidade ao longo de um intervalo temporal de valores, no intuito de maximizar a nitidez das distribuições preditivas com base no conjunto de informações disponíveis (Gneiting & Katzfuss, 2014; Taieb et al., 2015). A vantagem de se fazer previsões probabilísticas está no facto das empresas precisarem da previsão de energia probabilística presente em todo o planeamento e operações da cadeia de valores de energia eléctrica; e as previsões probabilísticas sob a forma de densidades preditivas são necessárias para resolver muitos dos desafios enfrentados pelos gestores. Por exemplo, a energia eléctrica não pode ser armazenada, a geração instantânea deve coincidir com a procura a partir do sistema. Para assegurar esse equilíbrio entre a procura e a oferta, bem

como a segurança e qualidade no fornecimento de energia eléctrica, a previsão do consumo eléctrico de curto prazo é necessária. Tais previsões fornecem a base para a geração e manutenção da programação, e podem ser utilizadas para estimar os fluxos de carga eléctrica de forma mais eficiente, impedindo que o sistema sofra perturbações graves (Rebennack, Pardalos, Pereira, & Iliadis 2010). Mas, a questão chave, do ponto de vista operacional, é de facto, saber se haverá problemas em atender a procura máxima; e a incapacidade de atendê-la, obviamente, pode resultar em apagões inesperados. Um cenário possível para esse problema é fazer previsão e estimar as regiões de maior densidade de consumo, o que permite expor as características mais marcantes da procura. Nesse contexto, três questões de natureza estatística precisam-se responder: 1. Como modelar e prever o comportamento da procura de energia eléctrica nas cidades angolanas?; 2. Em quais regiões do espaço amostral o consumo de energia eléctrica difere em densidade?; 3. Como estimar o fluxo máximo da carga eléctrica consumida num dado período?

A dinâmica da procura de energia eléctrica pode estar influenciada a uma série de factores dependentes do comportamento humano, para além das condições climáticas. Esses factores são, normalmente, utilizados como variáveis regressoras para gerar modelos de previsão da procura eléctrica. Entretanto, o desafio metodológico essencial tem a ver com a capacidade de relacionar a carga eléctrica a factores exógenos ou covariáveis, como efeitos de calendário, actividades económicas, o crescimento da população e o preço da electricidade, para além das condições climáticas como a temperatura, umidade, velocidade do vento e precipitação (Gob, Lurz, & Pievatolo, 2013). Várias metodologias, adotando modelos estatísticos, têm sido desenvolvidas para calcular previsões de curto-prazo da procura de electricidade. Dentre esses modelos, estão aqueles que permitem gerar previsões pontuais e outros que permitem gerar as previsões probabilísticas sob a forma de densidades preditivas (Harvey, 1989; Harvey & Koopman, 1993; Hyndman, 1996; Ord, Koehler, & Snyder, 1997; Hyndman, Koehler, Snyder, & Grose, 2002; Ord, Snyder, Koehler, Hyndman, & Leeds, 2005; Hyndman, Koehler, Ord, & Snyder, 2008; Durbin & Koopman, 2011; Koehler, Snyder, Ord, & Beaumont, 2012; Gneiting & Katzfuss, 2014; Ahmad & Maxwell, 2015; Shumway & Stoffer, 2017).

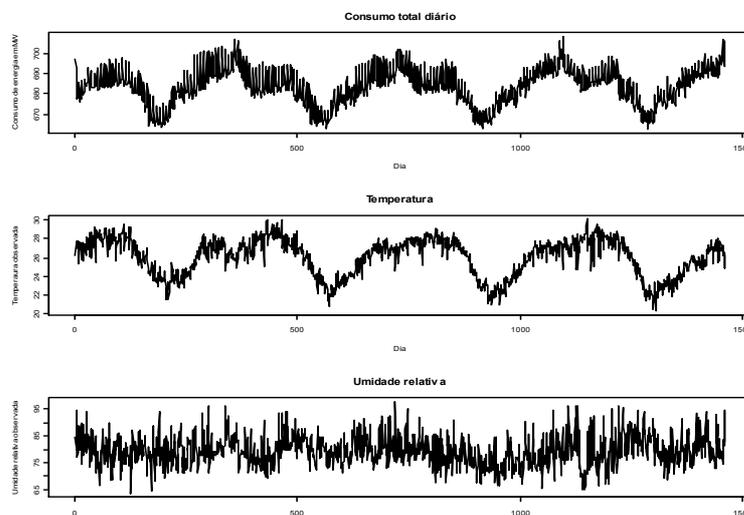
A projecção de modelos de espaço de estados, particularmente, para problemas de previsão de séries temporais tem merecido muita atenção da parte dos pesquisadores. Essa atenção está justificada pelo facto desses modelos serem flexíveis para a classe de modelos de suavização exponencial, Hyndman et al. (2008), e para incorporar os efeitos

das covariáveis, (Wang, 2006; Dordonnat, Koopman, Ooms, Dessertaine, & Collet, 2008; Gob et al., 2013; Shumway & Stoffer, 2017). Neste trabalho, um modelo estrutural, com covariáveis, baseado em processos dinâmicos (Puindi, 2018) é examinado para gerar previsões pontuais de curto-prazo, usadas para estimar, através do método *HDR (Highest Density Regions)*, o fluxo máximo da carga eléctrica consumida num dado período. O resto do trabalho está organizado como se segue. Na Secção II faz-se a descrição dos dados e sua análise para a percepção da dinâmica da procura de energia eléctrica na Cidade de Cabinda. A Secção III descreve o modelo estrutural com covariáveis e apresenta a análise empírica dos resultados. As conclusões estão apresentadas na Secção IV.

1. DESCRIÇÃO DOS DADOS E ANÁLISE

Para esse estudo, foram utilizadas, para além da informação referente à procura de energia eléctrica (em megawatt/horas (*MWh*), mais três variáveis regressoras: Temperatura (T_t), Umidade relativa (U_t) e uma variável de intervenção descrita mais adiante. Os dados referentes à procura de energia eléctrica na Cidade de Cabinda, observados entre 00:00 do dia 01 de Janeiro de 2011 e 23:00 do dia 31 de Dezembro de 2014, foram fornecidos pela ENDE, a partir da Estação da Central Térmica de Malembo, cuja distribuição é feita por duas linhas de transporte (Linha Fútila N.º 1 e Linha Fútila N.º 2). O INAMET (Instituto Nacional de Meteorologia) em Cabinda forneceu o conjunto de dados de variação diária da temperatura e umidade relativa, igualmente observados no período entre 1 de Janeiro de 2011 e 31 de Dezembro de 2014, Figura 1.

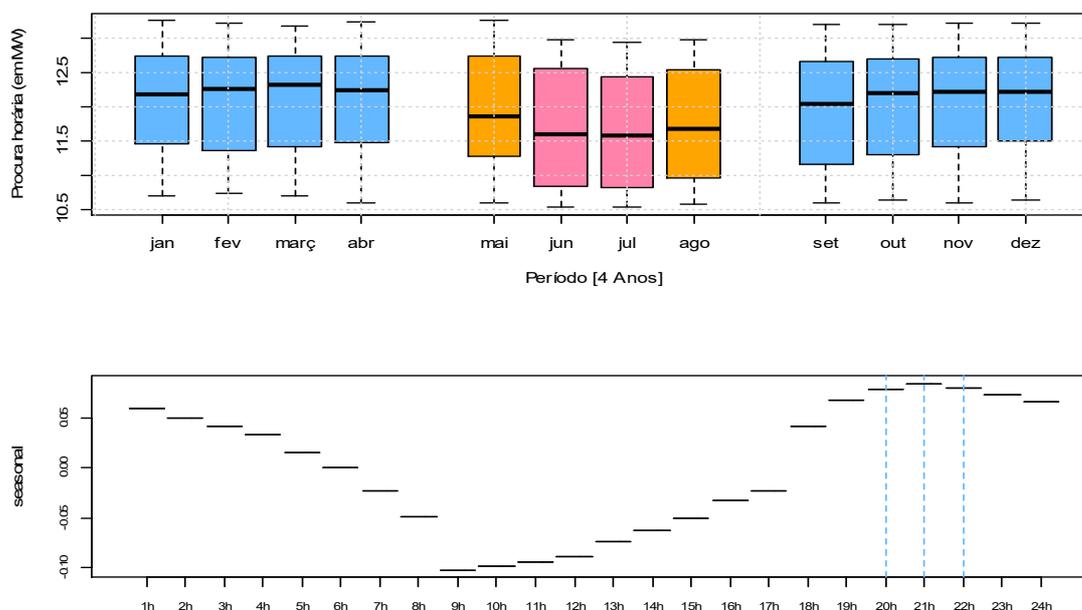
Figura 1: Painel I: Consumo total diário de energia eléctrica; Painel II: Variação da temperatura; Painel III: Variação da umidade relativa.



Fonte: Figura gerada com o ambiente de *software R*.

Para melhor compreensão sobre a dinâmica da procura de energia eléctrica na Cidade de Cabinda, uma análise prévia foi feita, especificamente, para a série da procura horária de energia eléctrica.

Figura 2: Painel I: Variação mensal do consumo horário para os 4 anos observados. Painel II: sazonalidade do consumo horário num período de 4 anos.



Fonte: Figura gerada com o ambiente de *software R*.

A Figura 2 mostra a variação mensal (dos 4 anos) dessa procura como consequência do efeito de calendário entre o verão e o inverno. É possível observar que o padrão de consumo noturno é mais elevado que o diurno e tem o pico a variar entre 20h e 22h, justificado fundamentalmente pelo uso da iluminação pública e aos diferentes níveis no comportamento das famílias no que tange ao uso de eletro-domésticos como aparelhos de ar condicionado, lâmpadas residenciais, arcas, geleiras, etc. Entre as 23h e às 09h o consumo é decrescente, e o pico de mínimo decorre às 9h matinal e vai crescendo lentamente até às 17h, quando volta a aumentar até atingir o pico.

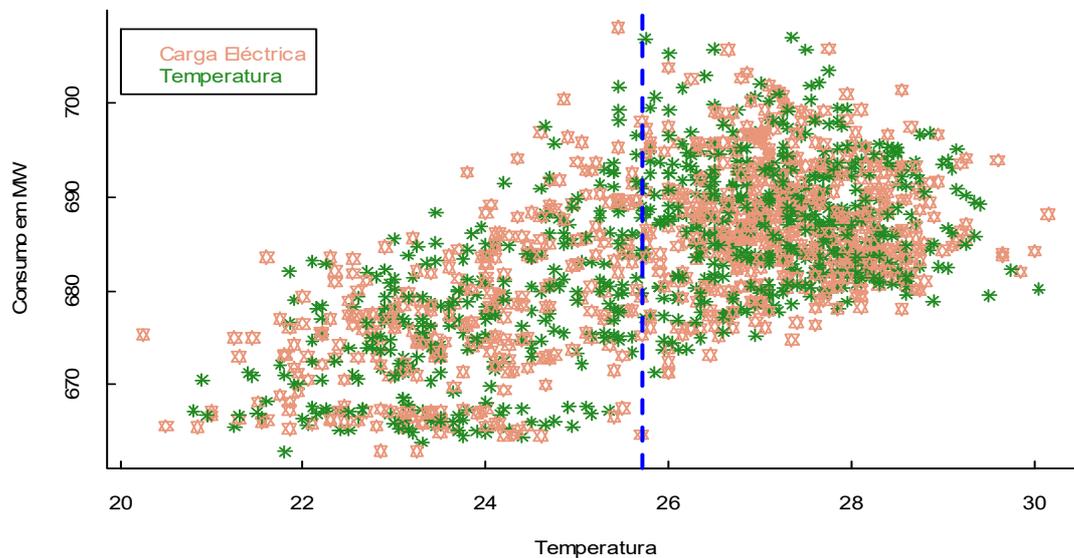
Como a leitura do consumo de energia eléctrica em Cabinda é feita em intervalos de uma hora, quando a temperatura e a umidade relativa às leituras são feitas em intervalos de um dia, a estratégia utilizada para compatibilizar os dados, foi transformar os dados horários (de energia eléctrica) em total diário, conforme se mostra na Figura 1 (painel I).

A circunstância pela qual o consumo aumenta com o aumento da temperatura é descrita através de uma variável de intervenção I_t , representada por indicadores que usam valores de 0 e 1. Essa variável é definida a partir da análise de correlação entre o consumo de electricidade e a temperatura. Conforme a Figura 3, uma relação linear entre as duas variáveis é bastante visível. No entanto, definiu-se um corte na linha de regressão em torno de 25°C, para indicar o efeito da temperatura nos níveis da procura total diária de energia eléctrica.

$$I_t = \begin{cases} 1 & \text{se } T_t > 25^\circ\text{C} \\ 0 & \text{se } T_t \leq 25^\circ\text{C} \end{cases}$$

onde, 25°C é o limiar abaixo do qual o consumo de energia eléctrica é considerado não afectado pela temperatura.

Figura 3: Consumo total diário (em MW) em função da temperatura (em °C).



Fonte: Figura gerada com o ambiente de *software R*.

2. DESCRIÇÃO DO MODELO

Adota-se \mathbf{z}_t para representar o vector que contém todas as entradas de controlo (variáveis meteorológicas, por exemplo, temperatura do ar, umidade relativa, variáveis pré-determinadas, também pode conter as variáveis indicadoras) e $\mathbf{\Gamma}$ para representar a matriz de entrada de controlo (matriz formado pelos coeficientes de regressão β_k^* , que aplica o efeito de cada parâmetro de entrada de controlo em \mathbf{z}_t no vector de observação \mathbf{y}_t , por exemplo, aplica o efeito da temperatura no consumo de electricidade).

O vector Γ contém parâmetros desconhecidos, mas eles não afectam as propriedades estocásticas do modelo, apenas entram de forma determinística, ou seja, os parâmetros que aparecem em Γ afectam apenas o valor esperado das observações de uma maneira determinística. Essa distinção pode ficar embaçada, por exemplo, se Γ é uma função de um valor defasado de \mathbf{y}_t . Se Γ é uma função linear de parâmetros desconhecidos, esses parâmetros podem ser tratados como variáveis de estado (Harvey, 1989). Então, descrevemos a possível forma de explicar a dinâmica da procura de electricidade nas cidades angolanas através de um modelo linear Gaussiano em espaço de estados, que incorpora a regressão de efeitos fixos na equação do sinal:

$$\mathbf{y}_t = \mathbf{A}_t \mathbf{x}_t + \Gamma \mathbf{z}_t + \mathbf{v}_t \quad t = 1, 2, \dots, n \quad (1a)$$

$$\mathbf{x}_t = \Phi \mathbf{x}_{t-1} + \boldsymbol{\eta}_t \quad t = 1, 2, \dots, n \quad (1b)$$

onde \mathbf{A}_t é uma matriz $q \times p$ de medição ou observação; (1a) é chamada de equação de observação. O vector de dados observados \mathbf{y}_t , é q -dimensional, que pode ser maior ou menor que p , a dimensão do estado. (1b) é chamada de equação de estado, é uma matriz de transição $p \times p$. Supomos que temos um vector de entradas $r \times 1$, \mathbf{z}_t , e Γ uma matriz $q \times r$ e \mathbf{v}_t e $\boldsymbol{\eta}_t$ são ruído branco. Neste trabalho, consideramos o seguinte modelo estrutural trigonométrico que se denomina por **TSCov** – iniciais de *Trigonometric Structural model with Covariates*, proposto por Puindi (2018) para calcular as previsões pontuais. Trata-se de um modelo de espaço de estados com múltiplas fontes de aleatoriedade. (i) A estrutura do modelo não integra os parâmetros de suavização; (ii) o modelo lida com covariáveis, mas pode funcionar sem a integração das covariáveis; (iii) o procedimento de estimação dos parâmetros é baseado no filtro de Kalman com as matrizes de covariância do sistema calculadas recursivamente – um processo automático que agrega o filtro de Kalman e o método de selecção dos harmônicos necessários para os termos trigonométricos é construído para a otimização das estimativas dos parâmetros através do método de Newton-Rapson.

$$y_t = l_{t-1} + \phi b_{t-1} + \sum_{i=1}^T s_{t-1}^{(i)} + T_t + \sum_{\kappa=1}^r \beta_{\kappa}^* z_{\kappa,t} + \varepsilon_t \quad \varepsilon_t \sim \mathcal{N}(0, \sigma_{\varepsilon}^2) \quad (2a)$$

$$l_t = l_{t-1} + \phi b_{t-1} + \xi_t \quad \xi_t \sim \mathcal{N}(0, \sigma_{\xi}^2) \quad (2b)$$

$$b_t = (1 - \phi) + \phi b_{t-1} + \zeta_t \quad \zeta_t \sim \mathcal{N}(0, \sigma_{\zeta}^2) \quad (2c)$$

$$S_t = \sum_{j=1}^{k_i} s_{j,t}^{(i)} \quad (2d)$$

$$s_{j,t} = s_{j,t-1} \cos\left(\frac{2\pi j}{m_i}\right) + s_{j,t-1}^* \sin\left(\frac{2\pi j}{m_i}\right) + e_{j,t}^{(i)} \quad (2e)$$

$$s_{j,t}^* = -s_{j,t-1} \sin\left(\frac{2\pi j}{m_i}\right) + s_{j,t-1}^* \cos\left(\frac{2\pi j}{m_i}\right) + e_{j,t}^{*(i)} \quad (2f)$$

Assumimos que $e_{j,t}^{(i)} = e_{j,t}^{*(i)} \sim \mathcal{N}(0, \sigma_e^2)$ e $\varepsilon_t, \xi_t, \zeta_t, e_{j,t}^{(i)}$ são processos independentes. m_1, \dots, m_T representam os períodos sazonais e T padrões sazonais, respetivamente, com $i = 1, \dots, T; j = 1, \dots, k_i$. k_i é o número de harmônicas necessário para os termos trigonométricos na i -ésima componente sazonal, cuja abordagem é equivalente as abordagens de índices sazonais, quando $k_i = m_i/2$ para valores pares de m_i e, quando $k_i = (m_i - 1)/2$ para valores ímpares de m_i . Os componentes l_t e b_t são o nível local e a tendência de curto prazo no instante t , respetivamente; b é a tendência de longo prazo. $s_{j,t}^{(i)}$ representa o nível estocástico da componente sazonal; o crescimento estocástico no nível da i -ésima componente sazonal que é necessário para descrever a mudança na componente sazonal ao longo do tempo t é definido por $s_{j,t}^{*(i)}$. Para mais detalhes sobre o modelo, a sua especificação na forma matricial, ver Puindi (2018), disponível em: <https://repositorio-aberto.up.pt/handle/10216/117682>.

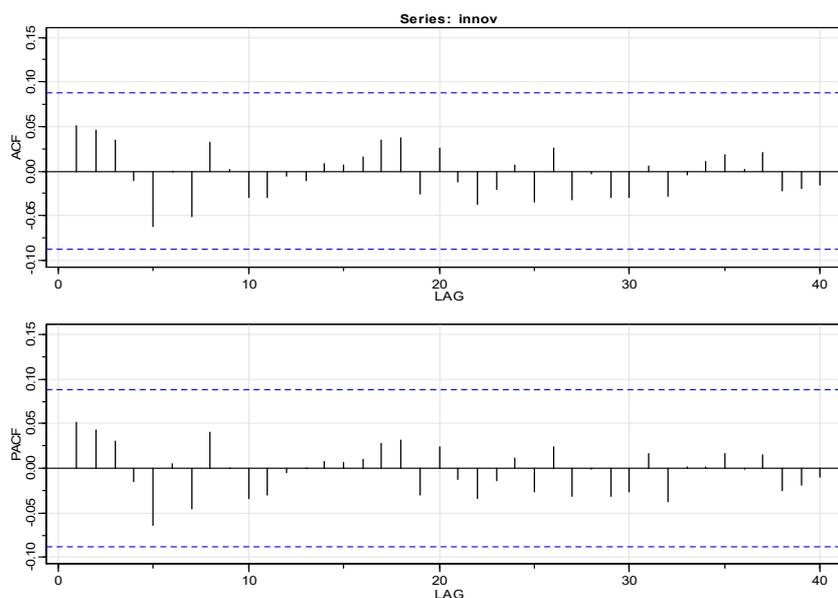
Para o cálculo das previsões probabilísticas, este trabalho usa o método HDR (*Highest Density Regions*) proposto por Hyndman (1996) para gerar as regiões de densidade relativamente alta da procura de energia eléctrica e estimar o fluxo máximo da carga eléctrica consumida.

2.1. Estimação do modelo e previsão pontual

A série de teste é composta por 1166 observações que corresponde o período entre 01 de Janeiro de 2011 até 11 de Março de 2014. A série de validação tem 295 observações. A média e a covariância do estado do sistema são inicializadas em $x_0 = 0$ e $P_{0i} = 30$, com $i = 14$, respetivamente. A covariância da observação é inicializada em $R_0 = \sigma_\varepsilon^2 = 10^{-8}$ e as variâncias do vector de estados são inicializadas por $Q_0 = \text{diag}\{\sigma_\xi^2, \sigma_\zeta^2, \sigma_\omega^{2(i)}\} = \{4, 0.9, 0, 0\}$, com $i = 4$. Os componentes da matriz coeficiente de regressão são inicializados por $\{\beta_1, \beta_2, \beta_3\} = 0.01$ e o factor de esquecimento é fixado em $\delta = 0,6$.

As estimativas dos parâmetros e os respetivos erros-padrão estão apresentados na Tabela 1. A avaliação da adequação do modelo ajustado aos dados é verificada pela análise do correlograma dos resíduos, Figura 4, que não apresenta picos significativos em todos os *lags*. Ademais, o teste de Box-Ljung sobre a independência dos resíduos fornece um valor de Qui-quadrado igual a 22.436, com 29 graus de liberdade e p-valor = 0.586; o que permite não rejeitar a hipótese nula de que os resíduos são independentes.

Figura 4: Correlograma dos resíduos da previsão um passo à frente da procura total diária de energia eléctrica na Cidade de Cabinda.



Fonte: Figura gerada com o ambiente de *software R*.

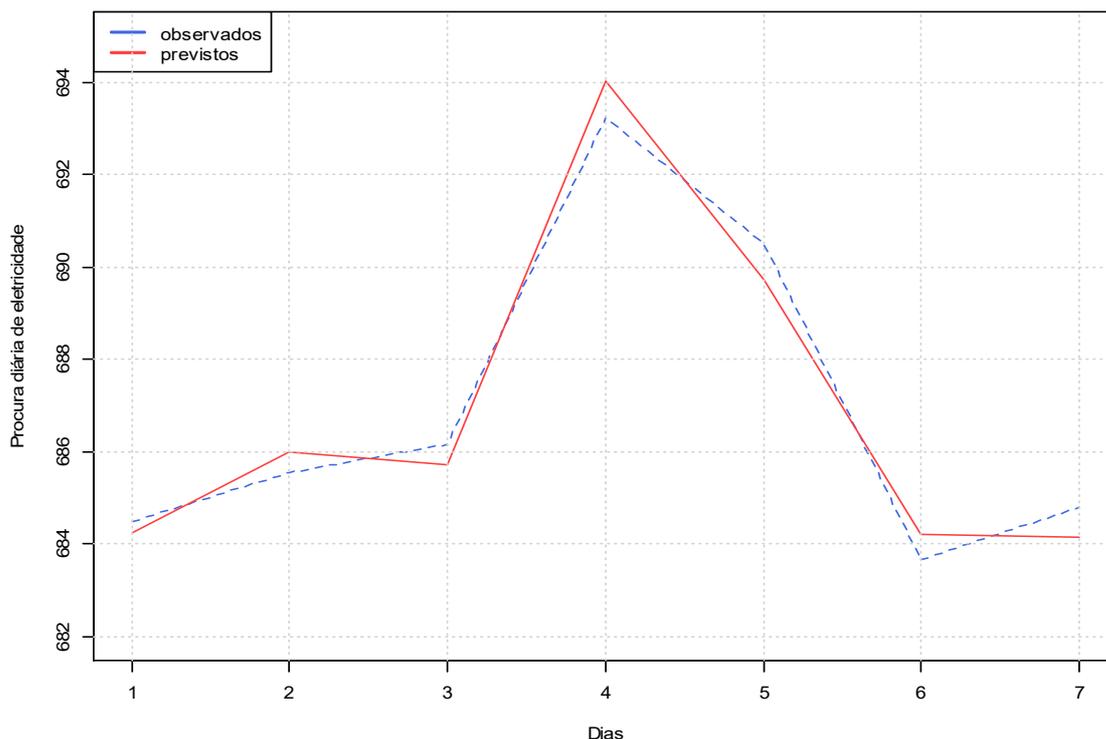
Tabela 1: Estimativas dos parâmetros e os respetivos erros-padrão do modelo de previsão da procura total diária de energia eléctrica na Cidade de Cabinda.

Parâmetro	MLE(TSCov)	E.Padrão
σ_{ε}^2	2.179	0.623
β_1^*	0.909	0.113
β_2^*	0.088	0.025
β_3^*	3.299	0.402
σ_{ξ}^2	3.460	0.313
σ_{ζ}^2	0.026	0.116
ϕ	0.800	0.071
σ_{ω}^2	{0.336; 0.258}	{0.322; 0.213}
$\sigma_{\omega^*}^2$	{0.062; 0.226}	{0.222; 0.012}

Fonte: Criação do autor, conforme as estimativas dos parâmetros do modelo.

As previsões calculadas resultam do uso de covariáveis reais, a temperatura (T_t) e a umidade relativa (U_t), incluindo a variável de intervenção (I_t). A Figura 5 mostra as previsões até 7 passos à frente.

Figura 5: Valores observados e a previsão até 7 passos à frente que corresponde ao período entre 12 e 18 de Março de 2014.

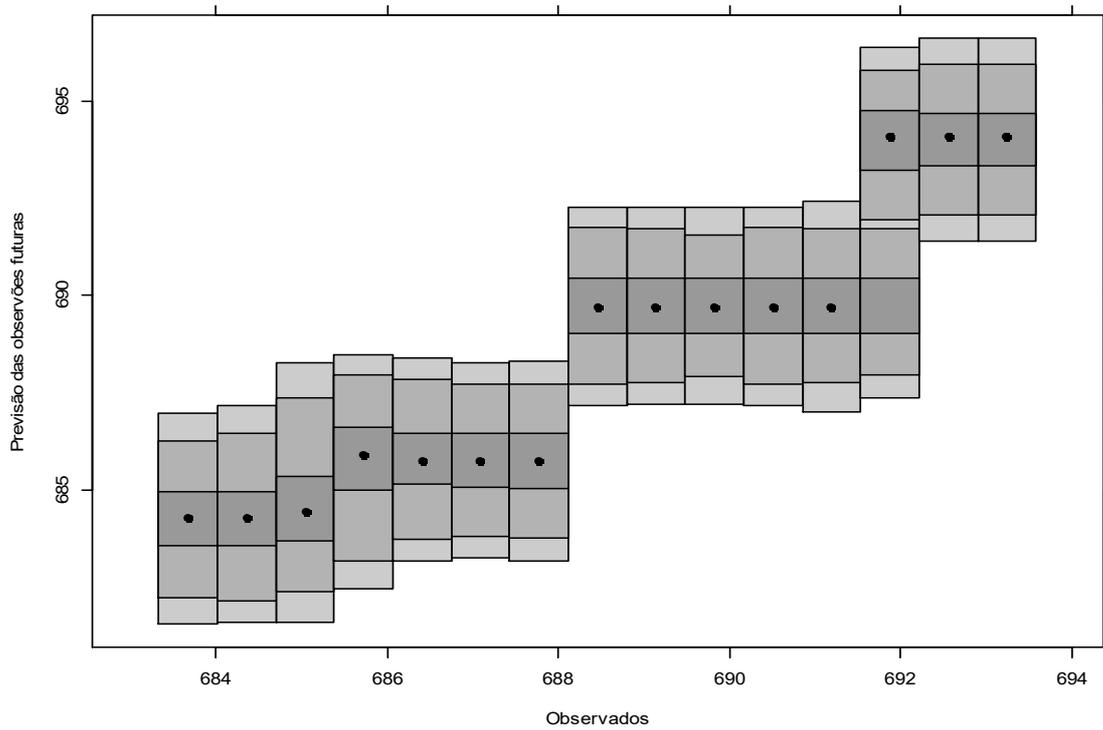


Fonte: Figura gerada com o ambiente de *software R*.

2.2. Previsão probabilística sob a forma de densidades preditivas

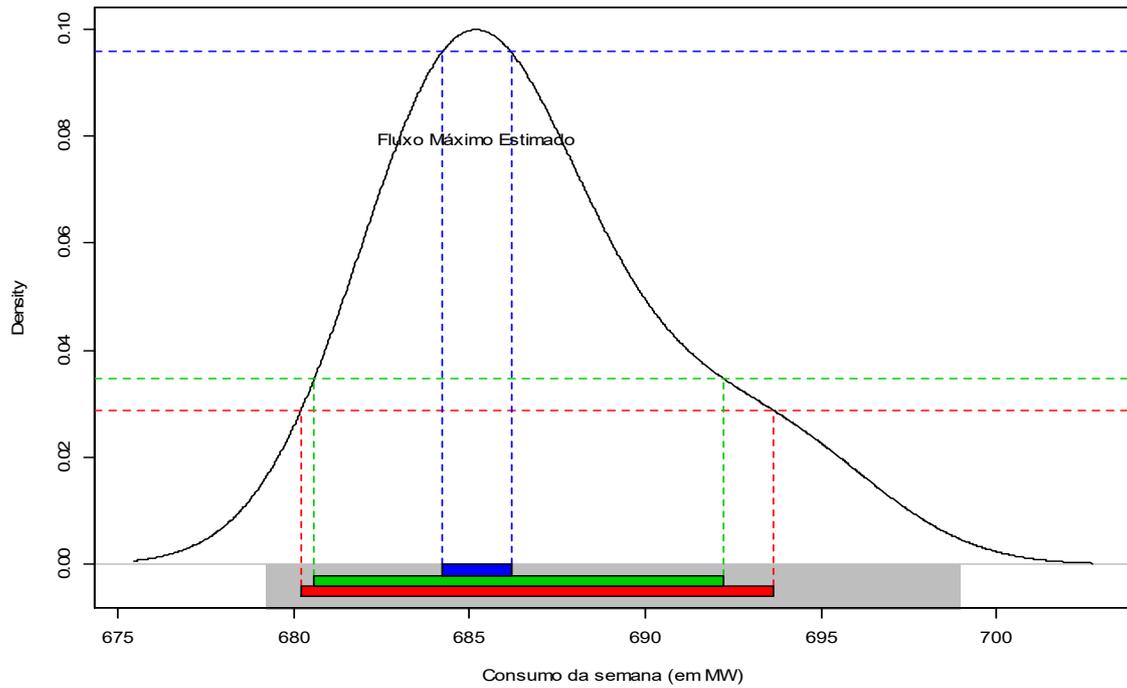
Dadas as previsões pontuais obtidas pelo modelo **TSCov** estimado, Figura 5, a aplicação do método **HDR** permitiu estimar as regiões de maior densidade exibida – as regiões onde o consumo de energia eléctrica difere em densidade condicional, que chamamos de “regiões de excesso no consumo de electricidade” apresentadas na Figura 6.

Figura 6: Estimativa das regiões de maior densidade para o período entre 12 e 18 de Março de 2014.



Fonte: Figura gerada com o ambiente de *software R*.

Figura 7: Estimativa do fluxo máximo da carga eléctrica consumida no período entre 12 e 18 de Março de 2014.



Fonte: Figura gerada com o ambiente de *software R*.

Sabe-se que a moda populacional de uma distribuição de probabilidade contínua é o valor em que a função densidade de probabilidade atinge o valor máximo, ou seja, o valor que está no pico. Assim, os máximos globais são modas. Outrossim, quando uma função densidade de probabilidade tem vários máximos locais, é comum referir-se a todos os máximos locais como modas da distribuição. Dentro de cada região estimada, conforme na Figura 6, observam-se pontos – são os pontos com densidade de probabilidade relativamente alta em relação a todos os pontos fora das regiões. Como se pode notar, a primeira região contém a maior quantidade de pontos. Do ponto de vista prático, isso significa que na semana de 12 a 18 de Março de 2014, o fluxo de carga eléctrica consumida com maior frequência fixou-se entre 684 e 688MW, com um máximo local em torno de 685MW. Este valor coincide com a moda estimada, apresentada na Figura 7. Assim, pode-se razoavelmente concluir que o *fluxo máximo da carga eléctrica* consumida durante a semana de 12 a 18 de Março de 2014 é aproximada a 685.2MW. Na Figura 7 essa estimativa está ilustrada pelo rectângulo limitado com linhas descontínuas azuis.

3. CONCLUSÃO

Esse estudo procurou responder as três perguntas formuladas na introdução, que constituem a motivação da pesquisa. Através da análise descritiva preliminar, foi constatado que o efeito de calendário na procura de energia eléctrica na cidade de Cabinda, em particular, é bastante visível nas duas principais estações do ano, verão e inverno, e é de fácil caracterizar. Ou seja, a procura de electricidade é maior no verão do que no inverno. O pico do consumo diário é registado no período entre 20h e 22h e o mínimo decorre às 9h matinal.

Um modelo de previsão da procura diária de energia eléctrica na Cidade de Cabinda foi estimado. As previsões pontuais geradas e usadas para estimar as regiões onde o consumo de electricidade difere em densidade, permitiram estimar o fluxo máximo da carga eléctrica consumida durante o período previsto. Tais resultados permitem assegurar que:

1. O modelo estimado é adequado para descrever a dinâmica da procura diária de energia eléctrica na Cidade de Cabinda e calcular previsões, e é aplicável para previsão da procura de electricidade nas demais cidades angolanas. Pois, à

semelhança de Cabinda, as demais cidades angolanas também são marcadas por apenas duas estações distintas: o verão e o inverno, e o clima é, igualmente, tropical húmido. A dinâmica da procura de energia eléctrica, nessas cidades, também é influenciada pelos mesmos factores enumerados acima.

2. Do ponto de vista do planeamento e operação dos sistemas de geração de energia eléctrica, os gestores da ENDE e da PRODEL (Empresa de Produção de electricidade) teriam possibilidades de tomar decisões seguras sobre:
 - 1.1. A produção de energia eléctrica que deve coincidir com a procura para assegurar o equilíbrio entre a procura e a oferta;
 - 1.2. O fluxo de carga eléctrica a estimar de forma a impedir que os sistemas sofram perturbações graves e evitar desperdícios.

Finalmente, os resultados desse trabalho também permitem observar que, a rede que alimenta a Cidade de Cabinda exige-se num equilíbrio entre a electricidade produzida e a consumida ao longo do dia. Para isso, aconselha-se:

1. Os Governos das províncias a apostarem em projectos de urbanização dos bairros, pois, só assim e em colaboração com a ENDE/PRODEL ter-se-á o controlo efectivo do real fluxo de carga eléctrica consumida ao longo do dia (ou semana) e estimar o fluxo máximo futuro da carga eléctrica.
2. A ENDE/PRODEL a apostar na modernização do sector de controlo de consumo de energia eléctrica. Trata-se de uma área fundamental e com grande influência nas decisões tomadas no âmbito da programação e geração do fluxo de carga eléctrica necessária para o consumo, assim como o plano de manutenção dos geradores.

Todos os resultados computacionais deste trabalho foram obtidos com o ambiente de *software R*.

AGRADECIMENTOS

Os autores agradecem à Empresa Nacional de Distribuição de Energia Eléctrica (ENDE) em Cabinda e ao Instituto Nacional de Meteorologia em Cabinda, pela disponibilidade dos conjuntos de dados usados nesse trabalho.

REFERÊNCIAS BIBLIOGRÁFICAS

Ahmad, F., & Maxwell, L. (2015). Exponential smoothing with regressors: Estimation and initialization. *Model Assisted Statistics and Applications*, 10, 253 – 263. doi: 10.3233/MAS-150329

Dordonnat, V., Koopman, S. J., Ooms, M., Dessertaine, A., & Collet, J. (2008). An hourly periodic state space model for modelling french national electricity load. *International Journal of Forecasting*, 24, 566 – 587. doi:10.1016/j.ijforecast.2008.08.010

Durbin, J., & Koopman, S.J. (2011). *Time series analysis by state space methods*. Oxford: University Press, United Kingdom.

Gneiting, T., & Katzfuss, M. (2014). Probabilistic forecasting. *The Annual Review of Statistics and Its Application*, 1, 125–151. doi:10.1146/annurev-statistics-062713-085831

Gob, R., Lurz, K., & Pievatolo, A. (2013). Electrical load forecasting by exponential smoothing with covariates. *Applied models business and industry*, 29, 629 – 645. doi:10.1002/asmb.2008

Harvey, A., & Koopman, S.J. (1993). Forecasting hourly electricity demand using timevarying splines. *Journal of the American Statistical Association*, 88(424), 1228 – 1236.

Harvey, A. C. (1989). *Forecasting structural time series models and the Kalman filter*. Cambridge: University Press, United Kingdom.

Hyndman, R. J. (1996). Computing and graphing highest density regions. *American Statistical Association*, 50 (2), 120 – 126.

Hyndman, R.J., Koehler, A.B., Snyder, R.D., & Grose, S. (2002). A state space framework for automatic forecasting using exponential smoothing methods. *International Journal of Forecasting*, 18, 439 – 454.

Hyndman, R.J., Koehler, A. B., Ord, J. K., & Snyder, R. D. (2008). Forecasting with exponential smoothing: the state space approach. *Springer-Verlang*, 137 – 143.

Koehler, A. B., R. D. Snyder, R. D., Ord, J. K., & Beaumont, A. (2012). A study of outliers in the exponential smoothing approach to forecasting. *International Journal of Forecasting*, 28(2), 477 – 484. doi:10.1016/j.ijforecast.2011.05.001

Ord, J. K., Koehler, A.B., & Snyder, R.D. (1997). Estimation and prediction for a class of dynamic nonlinear statistical models. *Journal of the American Statistical Association*, 92(440), 1621 – 1629. doi:10.1080/01621459.1997.10473684

Ord, J. K., Snyder, R.D., Koehler, A.B., Hyndman, R.J., & Leeds, M. (2005). Time series forecasting: the case for the single source of error state space approach. *Working paper*, 2 – 33.

Puindi, A.C. (2018). *Contribuições para o Desenho de Modelos de Previsão da Procura: Aplicação no Planeamento Energético para a Cidade de Cabinda*. (Tese de Doutoramento). Universidade do Porto, Porto, Portugal. Disponível em: <https://repositorio-aberto.up.pt/handle/10216/117682>

Rebennack, S., Pardalos, P.M., Pereira, V. F., & Iliadis, N. A. (2010). *Handbook of power systems II*. Berlin: Springer-Verlag Berlin Heidelberg.

Shu, F., & Hyndman, R.J. (2012). Short-Term Load Forecasting Based on a Semi-Parametric Additive Model. *IEEE Transactions on Power Systems*, 27(1), 134 – 140.

Shumway, R. H., & Stoffer, D.S. (2017). *Time series analysis and its applications: With r examples*. New York: Springer, Four Edition.

Spiegelhalter, D., Pearson, M., & Short, I. (2011). Visualizing uncertainty about the future. *American Association for the Advancement of Science*, Washington, DC 20005.

Taieb, S. B., Huser, R., Hyndman, R.J., & Genton, M. G. (2015). Probabilistic time series forecasting with boosted additive models: an application to smart meter data. *Working Paper*, 2–30.

Wang, S. (2006). *Exponential smoothing for forecasting and bayesian validation of computer models* (Ph.D.'s Thesis). Georgia Institute of Technology, Georgia, USA.