

MODELOS DE SIMULAÇÃO DE CENÁRIOS DE PRODUÇÃO DE ENERGIA EÓLICA A PARTIR DO MÉTODO DE HOLT-WINTERS E SUAS VARIAÇÕES

Matheus Ferreira de Barros

Programa de Pós-Graduação em Metrologia para Qualidade e Inovação - PUC Rio
Rua Marquês de São Vicente, 225 – Gávea, Rio de Janeiro – RJ
matheusferreira.puc@gmail.com

Fernando Luiz Cyrino Oliveira

Departamento de Engenharia Industrial - PUC Rio
Rua Marquês de São Vicente, 225 – Gávea, Rio de Janeiro – RJ
cyrino@puc-rio.br

Reinaldo Castro Souza

Departamento de Engenharia Elétrica - PUC Rio
Rua Marquês de São Vicente, 225 – Gávea, Rio de Janeiro – RJ
reinaldo@ele.puc-rio.br

RESUMO

A energia eólica apresenta cada vez mais importância na matriz elétrica nacional, devido ao seu crescimento. Com isso, novos métodos de geração de cenários de produção de energia eólica adquirem importância, pois podem auxiliar no planejamento de operação do sistema elétrico nacional. Visando essa questão, o presente trabalho propõe uma nova metodologia e a aplica em dados de produção de energia eólica, utilizando o método de Holt-Winters e sua recente variação, que lida com múltiplos padrões de sazonalidade. Os resultados das métricas de avaliação mostram que os métodos desenvolvidos são promissores para lidar com o problema levantado.

PALAVRAS CHAVE. Energia Eólica, Simulação de Séries Temporais, Método de Holt-Winters.

Área principal (EN - Pesquisa Operacional na área de Energia)

ABSTRACT

The wind energy shows itself as times passes by more relevance in the electric national source. Because of that, new methods of generating wind power data grow in importance, because they can support the operation planning of the national electric system. Aiming this issue, the present article come up with a new methodology and applies it in wind energy production data a Holt-Winters' model and its recent variation, which deals with multiple patterns of seasonality. The result of the evaluation metrics shows that the developed methods are promising in handling the problem that was raised.

KEYWORDS. Wind Power, Time Series Simulation, Holt-Winters' Method.

Main area (EN - Operations Research in Energy)

1. Introdução

Uma das características do sistema elétrico brasileiro é a sua complexidade, no que tange ao seu planejamento de operação de curto, médio e longo prazo. Essa complexidade vem do fato de que sua maior fonte é a hidroeletricidade, levando assim a uma dependência da geração de variáveis climáticas, como o volume de precipitação na região dos reservatórios. Mas recentemente, como uma decorrência da diversificação da matriz elétrica nacional depois da última crise energética sofrida pelo Brasil em 2001, as fontes de energias renováveis, em especial a eólica, vem experimentando um crescimento vertiginoso na participação da capacidade de geração de energia no país.

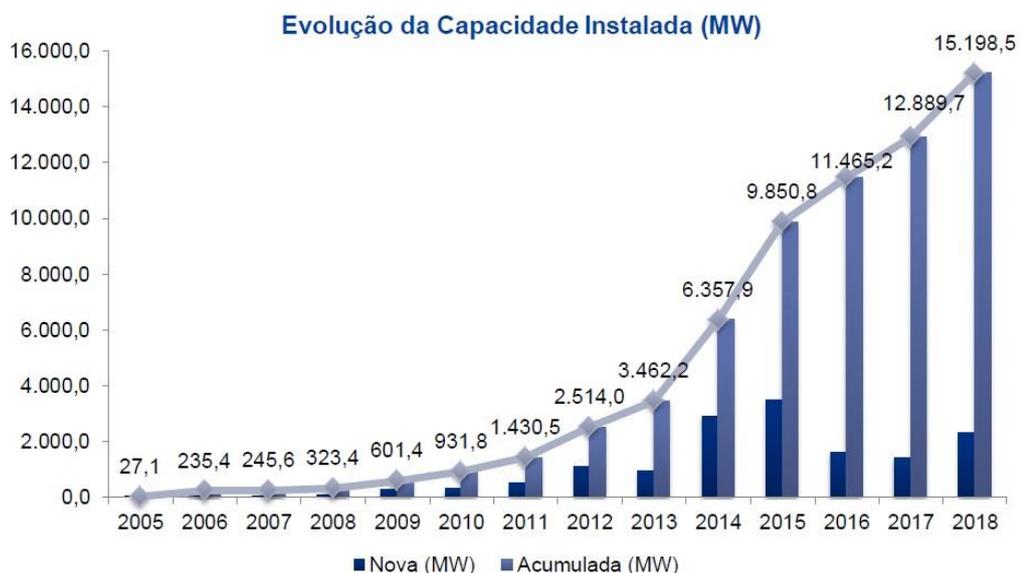


Figura 1 - Projeção da geração de energia eólica no Brasil

Fonte: Abeólica

Pode-se observar na figura acima a projeção da capacidade instalada de energia eólica na matriz elétrica nacional, que deve alcançar 9850,8 MW no final de 2015, chegando possivelmente a 7ª posição do ranking mundial de produção de energia eólica em índices absolutos.

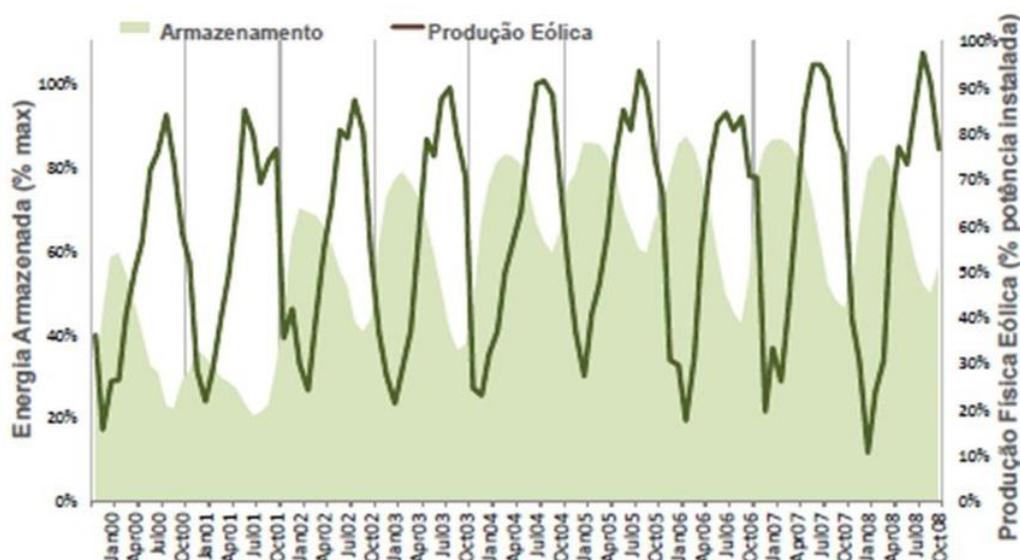


Figura 2 - Produção de energia eólica e energia hidroelétrica armazenada

Fonte: BNDES

O gráfico acima representa durante o período de janeiro de 2000 à outubro de 2008, o percentual da produção eólica quando comparada com a capacidade máxima de produção, e o percentual de energia armazenada nas hidroelétricas quando comparada com a capacidade máxima de armazenamento. Como a produção de energia eólica depende do regime de ventos, e o armazenamento de água para produção de hidroeletricidade depende do regime hidrológico, ambas as produções apresentam caráter sazonal dentro do ano.

Mas é interessante observar que as produções são complementares, pois quando temos o mínimo de chuva a velocidade de vento média é máxima (meses secos, de abril a setembro) e quando temos o máximo de chuvas temos o mínimo de velocidade de vento média (meses úmidos, de outubro a março). Por esse motivo, o aumento de produção de energia eólica se torna estratégico a médio e longo prazo para a diversificação da matriz elétrica nacional.

Portanto, torna-se cada vez mais necessário estudar as características da produção de energia eólica ao longo do tempo, para que essas informações sejam utilizadas no planejamento da operação do sistema elétrico nacional, que se apresenta como um problema muito complexo de otimização, como aborda Souza et al (2014). Tais trabalhos envolvem a previsão da velocidade do vento como os modelos Holt-Winters desenvolvidos por Monteiro (2013), e nos diversos modelos que foram estabelecidos na literatura e analisados por Chang (2014).

Com isso, o presente trabalho se propõe a mostrar a aplicação de metodologias alternativas para a geração de séries temporais de produção de energia eólica, utilizando uma adaptação do modelo Holt-Winters tradicional e o modelo Holt-Winters com múltiplos ciclos.

2. Holt-Winters e Holt-Winters com Múltiplos Ciclos

O modelo Holt-Winters foi um dos maiores e mais importantes desenvolvimentos na área de análise de séries temporais, como aborda Gardner (2006), e se mostra adequado para previsões cujos dados, apresentam como componentes básicos, como nível acompanhado de uma tendência e mais um fator sazonal.

O modelo de Holt-Winters possui dois tipos de procedimentos, multiplicativo e aditivo, cuja utilização depende das características das séries consideradas. No caso no presente trabalho, devido a maior difusão na literatura e melhores resultados, (Morettin e Tolo, 2006) serão explorados os modelos multiplicativos. Tais procedimentos são baseados em três equações e constantes de alisamento que estão associadas a cada uma das componentes do padrão da série: nível (2), tendência (3) e sazonalidade (4), e uma equação de previsão (1), como mostrado abaixo.

$$Z_t = (a_1 + a_2 t)\rho_1 \quad (1)$$

$$\hat{a}_1(T) = \alpha[Z_t - \hat{\rho}_{m(T)+kS}(T-1)] + (1-\alpha)[\hat{a}_1(T-1) + \hat{a}_2(T-1)] \quad (2)$$

$$\hat{a}_2(T) = \beta[\hat{a}_1(T) - \hat{a}_1(T-1)] + (1-\beta)\hat{a}_2(T-1) \quad (3)$$

$$\hat{\rho}_{m(T)+kS}^*(T) = \gamma[Z_t - \hat{a}_1(T)] + (1-\gamma)\hat{\rho}_{m(T)+kS}(T-1) \quad (4)$$

Onde α, β e γ são hiperparâmetros de suavização do nível, da tendência e da sazonalidade.

O modelo Holt-Winters padrão é muito utilizado para a previsão de séries temporais que contém sazonalidade. No entanto, esta modelagem é capaz de comportar apenas um padrão sazonal como observa Hyndman et al (2008).

Posteriormente, Taylor (2003) desenvolveu um trabalho no qual previa dados de demanda elétrica no intervalo de trinta minutos na Inglaterra, que exibiam além de um ciclo diário, um ciclo semanal. Esse modelo se consolidou na literatura em casos com padrões sazonais complexos, sendo aplicado com sucesso por exemplo por Miranda (2007) na previsão de carga do sistema elétrico brasileiro. A equação de previsão (5) é explicitada a seguir, sendo que suas equações de atualização são análogas ao modelo Holt-Winters padrão, descrevendo o nível (6), tendência (7) e agora as duas componentes de sazonalidade, nas equações (8) e (9).

$$Z_t = (a_1 + a_2 t)\rho_1\rho_2 \quad (5)$$

$$\hat{a}_1(T) = \alpha \left[\frac{Z_t}{\hat{\rho}_{1,m(T)+kl_1}(T-1)\hat{\rho}_{2,m(T)+kl_2}(T-1)} \right] + (1 - \alpha)(\hat{a}_1(T-1) + \hat{a}_2(T-1)) \quad (6)$$

$$\hat{a}_2(T) = \beta(\hat{a}_1(T) - \hat{a}_1(T-1)) + (1 - \beta)\hat{a}_2(T-1) \quad (7)$$

$$\hat{\rho}_{1,m(T)+kl_1}^*(T) = \gamma_1 \left[\frac{Z_T}{\hat{a}_1(T)\hat{\rho}_{2,s(T)+kl_2}(T-1)} \right] + (1 - \gamma)\hat{\rho}_{1,m(T)+kl_1}(T-1) \quad (8)$$

$$\hat{\rho}_{2,s(T)+kl_2}^*(T) = \gamma_2 \left[\frac{Z_T}{\hat{a}_1(T)\hat{\rho}_{1,m(T)+kl_1}(T-1)} \right] + (1 - \gamma)\hat{\rho}_{2,s(T)+kl_2}(T-1) \quad (9)$$

Onde α, β, γ_1 e γ_2 são hiperparâmetros de suavização do nível, da tendência, do primeiro e do segundo padrão sazonal.

Uma vantagem dos modelos de Holt-Winters aqui abordados é a facilidade de serem implementados computacionalmente, pois já possuem uma formulação teórica consolidada na literatura, e podem ser adaptados para lidarem com uma ampla variedade de tipos de séries temporais.

3. Metodologia e Aplicação

1. Descrição dos dados

Os dados inicialmente obtidos são os de velocidade do vento em metros por segundo, medidos na estação anemométrica de São João do Cariri – Rio Grande do Norte, a 50 metros de altura, com frequência de 10 minutos, de janeiro de 2006 a dezembro de 2009. Os dados estão disponíveis no site do Projeto SONDA (Sistema de Observação Nacional de Dados Anemométricos).

Para realizar a conversão dos dados de velocidade do vento para potência gerada, foi utilizada a curva de potência de um aerogerador comercial, de capacidade nominal de 2300 kW. Para isso, com a tabela abaixo obtida na especificação técnica do equipamento, foi realizada uma interpolação linear entre cada ponto, de modo que para todos os valores reais de velocidade do vento na base dados, pode se obter valores de potência equivalentes se submetidos a esse aerogerador.

Tabela 1 - Velocidade do vento e potência gerada

velocidade (m/s)	potência (kW)
0 - 1	0
2	3
3	25
4	82
5	174
6	321
7	532
8	815
9	1180
10	1580
11	1890
12	2100
13	2250
14	2350
15 - 25	2350

Abaixo é apresentado o gráfico resultante da interpolação dos valores da tabela 1 em 15 polinômios de primeiro grau.

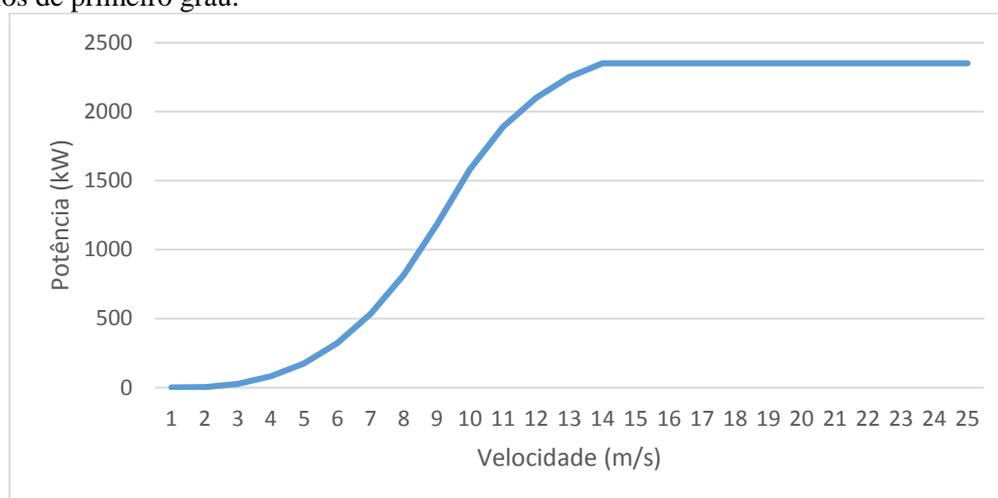


Figura 3 - Curva de potência gerada pela interpolação

Para construir os modelos de simulação, uma das mais importantes características de se observar são os padrões de sazonalidade encontrados nos dados. No caso dos dados de produção de energia eólica são tipicamente dois padrões: um referente ao ciclo diário, pois existem horários específicos dentro do dia em que devido a maior velocidade do vento, a produção de energia é maior, e o outro padrão é devido ao ciclo anual, pois em determinados meses devido a maior velocidade de vento, a produção também é maior. A existência dos padrões sazonais ficam claros quando apresentados os gráficos abaixo, que mostram os dados de potência observados em relação as horas do dia e em relação aos meses do ano.

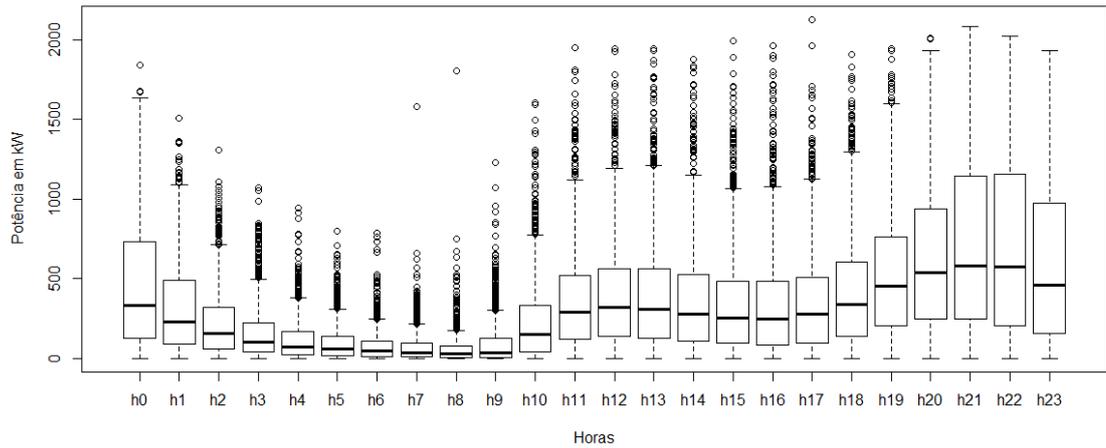


Figura 4 - Boxplot da potência gerada em relação as horas do dia

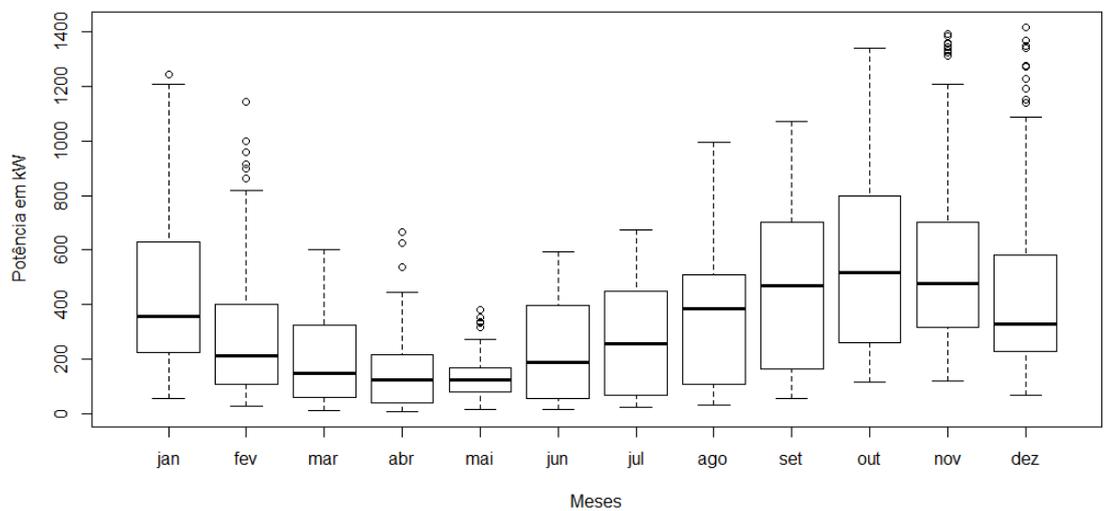


Figura 5 - Boxplot da potência gerada em relação aos meses do ano

Observando essas características, foi adotada uma estratégia de agrupamento dos dados para facilitar a construção dos modelos. A primeira foi a de transformar a frequência de 10 minutos para 1 hora, realizando o cálculo da média das 6 observações relativas a cada hora. A segunda, que é mais complexa, foi a de retirar a média das observações horárias nos dias do mesmo mês. Por exemplo, no mês de outubro de 2007, são encontrados 31 dias, cada um com 24 observações, mas realizando essa transformação, foi obtido um dia “médio” representativo do mês de outubro de 2007, que contém 24 observações. Essa estratégia foi adotada ao se observar que os padrões diários são bem similares dentro do mesmo mês. Dessa forma, o banco de dados agora conta com 24x12x4 (1152) observações, que podem ser observadas no gráfico abaixo, que torna bem claro a ilustração dos dois ciclos sazonais (diário e anual)

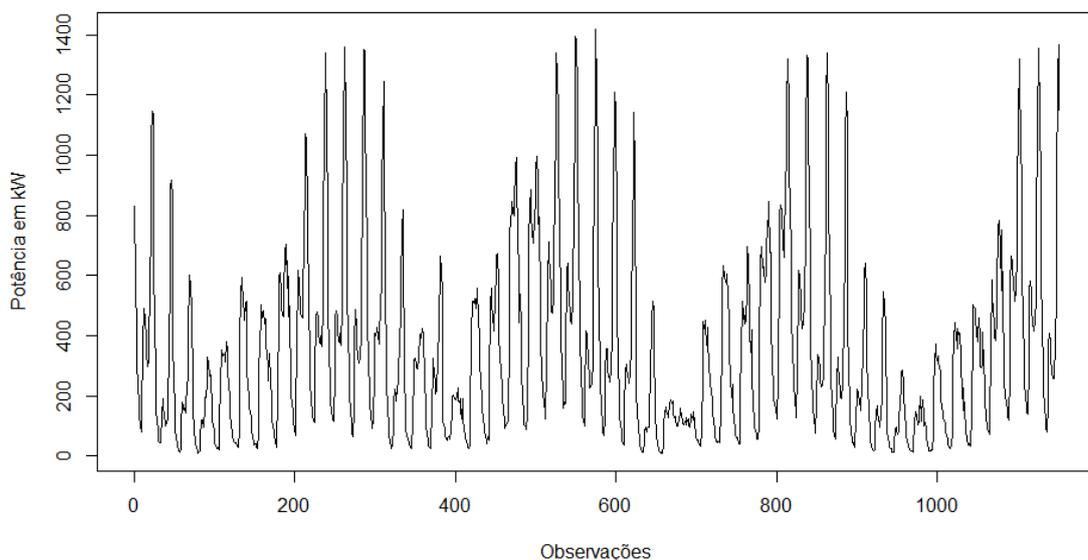


Figura 6 - Série temporal dos dados após os agrupamentos

2. Construção dos modelos de simulação

Para realizar a construção do modelo de simulação para a geração de séries temporais relativas ao ano seguinte, a primeira etapa foi a de construção do modelo de previsão. A partir daqui adotou-se duas estratégias diferentes para lidar com a questão dos dois ciclos sazonais. A primeira (denominada de Holt-Winters estratificado), foi a de construir um modelo Holt-Winters para cada mês, resultando assim em 12 modelos distintos, cada um realizando assim, a previsão 24 passos a frente, para assim, todos serem capazes de gerarem previsões para um ano a frente (288 observações). A segunda foi a de construir um modelo Holt-Winters com múltiplos ciclos, capaz de lidar com os dois padrões sazonais simultaneamente, gerando previsões para um ano a frente.

Com as previsões feitas, foram adotadas duas abordagens para a geração dos cenários. A primeira é a de a partir dos resíduos da construção do modelo de previsão, realizar um teste de aderência de probabilidade nos resíduos, e então usar uma simulação de Monte Carlo para construir os cenários futuros. A segunda consiste em a partir dos resíduos da construção do modelo de previsão, realizar *bootstrap* nos resíduos e gerar uma quantidade de novas amostras que somadas a cada uma das previsões dos modelos gere a quantidade de cenários desejados.

Desta forma, é possível a construção de 4 modelos de simulação distintos, a partir da combinação de todas as abordagens explicitadas anteriormente. A seguir são apresentadas duas figuras com os resultados das simulações quando comparadas a média histórica dos períodos anteriores. Na primeira é ilustrado o modelo de Holt-Winters estratificado com Monte Carlo aplicado ao mês de outubro, com 50 séries geradas.

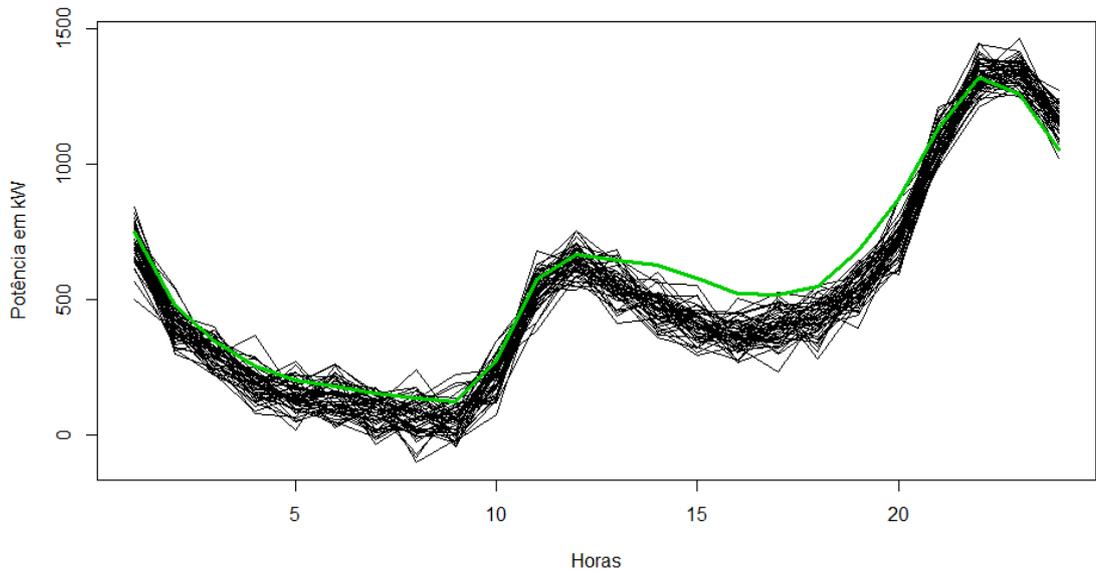


Figura 7 - Cenários gerados (preto) e média histórica (verde) para outubro

Na segunda, logo abaixo, é apresentado o resultado do modelo Holt-Winters com múltiplos ciclos e *bootstrap*.

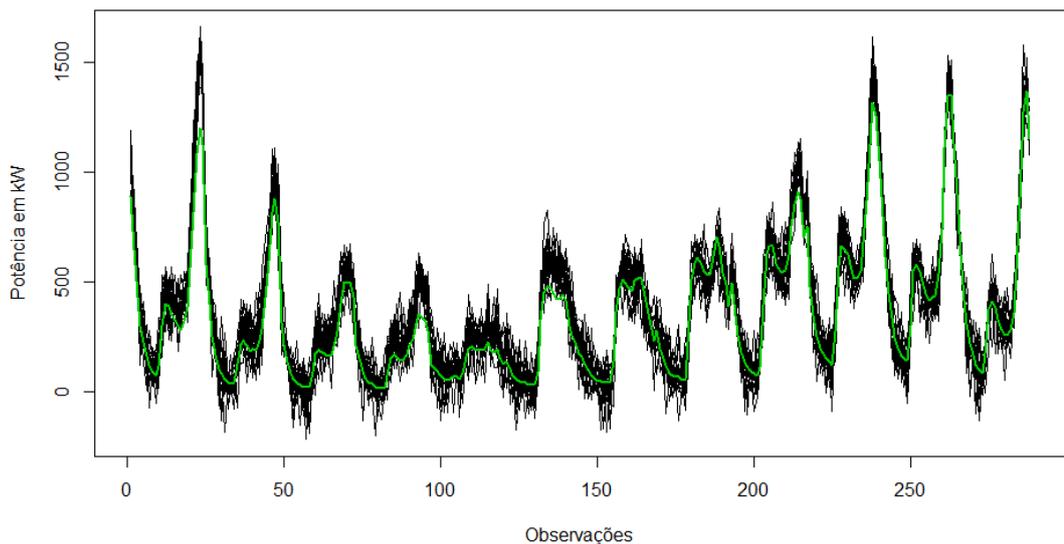


Figura 8 - Cenários gerados (preto) e média histórica (verde)

3. Análise dos Resultados

Com as 50 séries geradas para cada modelo proposto, resta agora analisar o quanto as simulações foram capazes de se adequar as características estatísticas das séries originais. As comparações foram feitas através das seguintes métricas:

- a) Comparar o desvio médio absoluto percentual (MAPE) dos cenários gerados contra a série original. Desta forma, teremos um MAPE para cada modelo construído.
- b) Comparar a média de cada série original com a média do cenário médio respectivo através do teste de Kruskal-Wallis (KRUSKAL & WALLIS, 1952), onde a hipótese nula

é a de que o cenário médio gerado por cada método tem média igual a série original dentro do período de comparação. A segunda coluna da tabela 2 apresenta os p-valores dos testes de hipóteses para cada modelo, logo, um resultado adequado será então quando o p-valor for maior que o nível de significância adotado.

- c) De forma análoga ao item anterior, cabe verificar a homogeneidade entre a variância de cada série original com o seu cenário médio através do teste de Fligner-Killeen (PAN, 1999). Logo, a quarta coluna da tabela 2 apresenta os p-valores dos testes de hipóteses para cada modelo.
- d) Analisar através de um teste de aderência de distribuição se cada cenário médio se adequa à sua respectiva série original através do teste de Kolmogorov-Smirnov. Logo, a quinta coluna da tabela 2 apresenta os p-valores dos testes de hipóteses para cada modelo.

Tabela 2 - Comparação dos modelos de simulação

Modelo	MAPE médio	Kruskal-Wallis	Fligner-Killeen	K-S
Holt-Winters Estratificado + <i>bootstrap</i>	10,34%	0.787	0.777	0.714
Holt-Winters Estratificado + Monte Carlo	12,57%	0.752	0.839	0.964
Holt-Winters com Múltiplos Ciclos + <i>bootstrap</i>	11,91%	0.840	0.648	0.686
Holt-Winters com Múltiplos Ciclos + Monte Carlo	14,80%	0.951	0.661	0.941

Analisando a tabela que resume as métricas de avaliação dos modelos de simulação, nota-se que todos os modelos tiveram características satisfatórias no que é relativo a média, a variância e a distribuição, quando comparadas com os dados originais, pois todos os p-valores estão acima do nível de significância adotado (5%). Isso permite concluir que a média do cenário médio gerado é estatisticamente igual a média dos dados originais, que a variância do cenário médio gerado é estatisticamente igual a variância dos dados originais, e que o cenário médio gerado e os dados originais tem a mesma distribuição de probabilidade.

Observando o comportamento dos modelos em relação ao desvio percentual dos dados originais (MAPE), há uma pequena vantagem do *bootstrap* sobre o método de Monte Carlo, e do Holt-Winters estratificado sobre o Holt-Winters com múltiplos ciclos, tendo o melhor resultado o Holt-Winters estratificado com *bootstrap*.

4. Conclusões

No trabalho desenvolvido, foram aplicados quatro modelos distintos para a geração de cenários de produção de energia eólica com dados reais, sendo possível testar a adequabilidade das simulações quando comparadas com as médias históricas dos dados e comparar os modelos entre si quanto a sua precisão.

Para trabalhos futuros, existe a possibilidade se utilizar outros modelos de séries temporais, como os modelo Box & Jenkins para séries sazonais abordados em Souza e Camargo (2004), além de outras técnicas para simulação dos resíduos, como o *moving blocks bootstrap*. Além da utilização de outras bases de dados anemométricas, afim de obter uma validação mais robusta dos modelos aqui desenvolvidos

A maior contribuição do trabalho aqui desenvolvido é a adaptação de modelos de previsão de séries temporais amplamente difundidos na literatura para o contexto de geração de cenários, abordando um problema que tende a se tornar cada vez mais importante, que é a inserção da produção de energia eólica no planejamento da operação do sistema elétrico nacional.

Referências

- Chang, W. Y.** (2014), A Literature Review of Wind Forecasting Methods. *Journal of Power and Energy Engineering*, 2014, 2, 161-168
- Gardner, E. S.** (2006), Exponential smoothing: The state of the art – Part II. *International Journal of Forecasting*, 22, 637 – 666.
- Hyndman, R. J., Koehler, A. B., Ord, J. K., Snyder, R. D.** *Forecasting with Exponential Smoothing: The State Space Approach*, Springer, New York, 2008
- Kruskal W. H., Wallis W. A.** (1952) Use of Ranks in One-Criterion Variance Analysis, *Journal of the American Statistical Association*, Vol. 47, No. 260, pp. 583-621
- Miranda, C. V. C.** Previsão de Dados de Alta Freqüência para Carga Elétrica Usando Holt-Winters com Dois Ciclos, Dissertação de Mestrado, PUC-Rio, DEE, 2007
- Monteiro, C. M. N.** Modelo para previsão de curto prazo de velocidade de vento usando Holt-Winters, PUC-Rio, DEE, Dissertação de Mestrado, 2013
- Morettin, P. A., Toloi, M. C.** *Análise de Séries Temporais*, Egard Blucher, 2. Ed. São Paulo, 2006.
- Pan, G.** (1999), On a Levene Type Test for Equality of Two Variances. *Journal of Statistical Computation and Simulation*, v. 63, n. 1, p. 59-71.
- Souza, R. C., Oliveira, F. L. O., Ferreira, P. G. C., Marcato, A. L. M., Dias, B. H., Brandi, R. B. S., Ramos, T. P.** *Planejamento da operação de sistemas hidrotérmicos no Brasil - Geração de cenários e otimização*. PUC-Rio, 1. ed. Rio de Janeiro, 2014.
- Souza, R. C., Camargo, M. E.** *Análise e Previsão de Séries Temporais: Os Modelos Arima*, 2a. Edição, Gráfica e Editora Reginal, Rio de Janeiro, 2004.
- Taylor, J. W.** (2003), Short-term electricity demand forecasting using double seasonal exponential smoothing. *Journal of Operational Research Society*, 54, 799-805.