Incluindo a Geração de Energia Eólica no Planejamento Energético Brasileiro de Longo Prazo

Paula Medina Maçaira
Pontifícia Universidade Católica do Rio de Janeiro (PUC-Rio)
R. Marquês de São Vicente, 225 – Gávea, Rio de Janeiro – RJ, 22430-060
paulamacaira@aluno.puc-rio.br

Yasmin Monteiro Cyrillo
Pontifícia Universidade Católica do Rio de Janeiro (PUC – Rio)
R. Marquês de São Vicente, 225 - Gávea, Rio de Janeiro - RJ, 22430-060
yasmin@ele.puc-rio.br

Reinaldo Castro Souza
Pontifícia Universidade Católica do Rio de Janeiro (PUC – Rio)
R. Marquês de São Vicente, 225 - Gávea, Rio de Janeiro - RJ, 22430-060
reinaldo@puc-rio.br

Fernando Luiz Cyrino Oliveira
Pontifícia Universidade Católica do Rio de Janeiro (PUC – Rio)
R. Marquês de São Vicente, 225 - Gávea, Rio de Janeiro - RJ, 22430-060
cyrino@puc-rio.br

Resumo

Atualmente, planejar a operação energética do Sistema Elétrico Brasileiro significa, basicamente, avaliar as condições futuras de suprimento de energia no horizonte de planejamento, minimizando o valor esperado do custo da operação durante o período de planejamento, sob restrições operacionais e de segurança. Este trabalho apresenta uma nova metodologia, intitulada "Demanda Líquida", que incorpora a geração de energia eólica no despacho hidrotérmico brasileiro utilizando o método analítico de Frequência e Duração. A metodologia é aplicada na região Nordeste do Brasil, abrangendo o período de planejamento de janeiro de 2017 a dezembro de 2021, utilizando a técnica de Markov Chain Monte Carlo para simular a série de energia eólica. Os resultados desta aplicação mostram que o método proposto é capaz de incluir os cenários de energia eólica no planejamento de longo prazo da operação de eletricidade considerando a estocasticidade dessa variável.

1. Introdução

A energia eólica apresentou significativo crescimento no Sistema Elétrico Brasileiro (SEB), respondendo por aproximadamente 8% da capacidade instalada em março de 2018, com 12.5GW de potência instalada (ANEEL, 2018). Em setembro de 2017 foram gerados, aproximadamente, 46.7TWh de energia no Brasil, sendo que 11% (5TWh) por usinas eólicas e desses 11%, 86% (4.4TWh) foi gerado na região Nordeste (Operador Nacional do Sistema Elétrico, 2018). A expectativa oficial para 2026 indica que a capacidade instalada referente a usinas eólicas no Brasil será de 25,8GW e a região Nordeste será responsável por 90% desse total (Ministério de Minas e Energia, 2016).

Apesar do aumento da geração de energia eólica, o sistema elétrico brasileiro é formado basicamente por usinas hidrelétricas e termelétricas, que representam juntas, aproximadamente 86% da geração total do país em 2016 (ONS, 2017). Atualmente, planejar a operação energética do SIN significa, basicamente, avaliar as condições futuras de suprimento de energia no horizonte de planejamento, minimizando o valor esperado do custo da operação durante o período de planejamento (Oliveira, Souza e Marcato, 2015). Este custo é formado pelos custos de

https://proceedings.science/p/85336?lang=pt-br

combustível mais as penalidades por falha no fornecimento de carga sob restrições operacionais e de segurança. As outras fontes de geração, incluindo a energia eólica, são descontadas da demanda de energia de forma determinística. Ou seja, o atual modelo de despacho não considera a variabilidade da série temporal da geração eólica. (Suomalainen *et al.*, 2015) mostra que em um sistema altamente influenciado pela geração hidráulica sazonal, a alta penetração de fontes eólicas causa grandes impactos nos modelos de despacho.

Do ponto de vista operacional, a geração eólica apresenta a desvantagem de sua volatilidade, enquanto é possível minimizar a variação da geração hidroelétrica através de reservatórios. Para capturar com precisão a natureza estocástica e o comportamento aleatório das séries de vento em um determinado local, são necessárias extensas medições históricas de velocidade/potência do vento. No entanto, em face da indisponibilidade de dados suficientes, são necessárias técnicas confiáveis de simulação estocástica para gerar esses dados. Nos últimos anos, devido à necessidade de representar a variabilidade cronológica e a natureza estocástica do vento, pesquisas importantes têm sido dedicadas a modelos de simulação e previsão de velocidade de vento, ver na seção Revisão de Literatura os trabalhos com maior importância segundo o número de citações.

Além da modelagem e previsão da geração eólica, o principal objetivo deste trabalho é a integração dos resultados no atual modelo de despacho hidrotérmico, sem a necessidade de qualquer alteração estrutural, ou seja, atualizando o cálculo das fontes não despachadas. Para alcançar o objetivo proposto e considerar o comportamento estocástico das séries de ventos, utiliza-se a metodologia de Frequência & Duração (F&D), combinando, via técnica de Cadeias de Markov, os estados de geração e carga para determinar os estados de demanda líquida e suas probabilidades de ocorrência.

O restante deste artigo está organizado da seguinte forma: a Seção 2 apresenta uma breve revisão da literatura de trabalhos que tratam da simulação de velocidade do vento, enquanto a Seção 3 apresenta uma estrutura para alcançar os objetivos descritos anteriormente, passo a passo. A Seção 4 descreve os resultados obtidos a partir do modelo proposto e a Seção 5 fornece algumas conclusões.

2. Revisão da Literatura

O primeiro trabalho importante que trata da simulação de dados de velocidade de vento é datado de 1996 e usa testes estatísticos para verificar a adequação de um modelo ARMA para fornecer essa simulação (Billinton, Chen e Ghajar, 1996). (Castino, Festa e Ratto, 1998) aplica Cadeias de Markov e modelo Autorregressivo Discreto para prever as séries de vento usando informações sobre a velocidade e direção do vento. (Alexiadis *et al.*, 1998) prevê velocidade e potência de vento por meio de Redes Neurais Artificiais (RNA) e modelos Autorregressivos, concluindo que nesse caso RNA apresenta melhor precisão. (Pinson, 2013) enfatiza a importância de considerar a geração de energia eólica como um processo estocástico e (Zhang, Wang e Wang, 2014) prova que a geração de energia eólica pode ser modelada como um processo estocástico, já que é não linear e não estável. (Jung e Broadwater, 2014) apresentam uma revisão bibliográfica sobre previsão de velocidade e potência de vento, correlação espacial, probabilística e off-shore, mostrando que as formulações não podem ser comparadas já que cada modelo depende da localização (correlação espacial). (Iversen *et al.*, 2016) propõe uma estrutura de modelagem para a velocidade do vento que é baseada em equações diferenciais estocásticas; (Landry *et al.*, 2016) descreve o método probabilístico de previsão de energia eólica que foi usado para ganhar a competição intitulada Global Energy Forecasting Competition 2014 (GEFCom2014).

3. Metodologia

https://proceedings.science/p/85336?lang=pt-br

A seção de Introdução enfatiza a tendência crescente de geração de energia eólica dentro da matriz elétrica brasileira e a necessidade de considerar o comportamento estocástico da fonte no modelo de planejamento da operação elétrica. Para superar essa necessidade, o presente estudo propõe uma metodologia que pode ser dividida em três procedimentos independentes: dados históricos, modelo Markov Chain Monte Carlo e modelo de Demanda Líquida, conforme ilustrado na Figura 1.

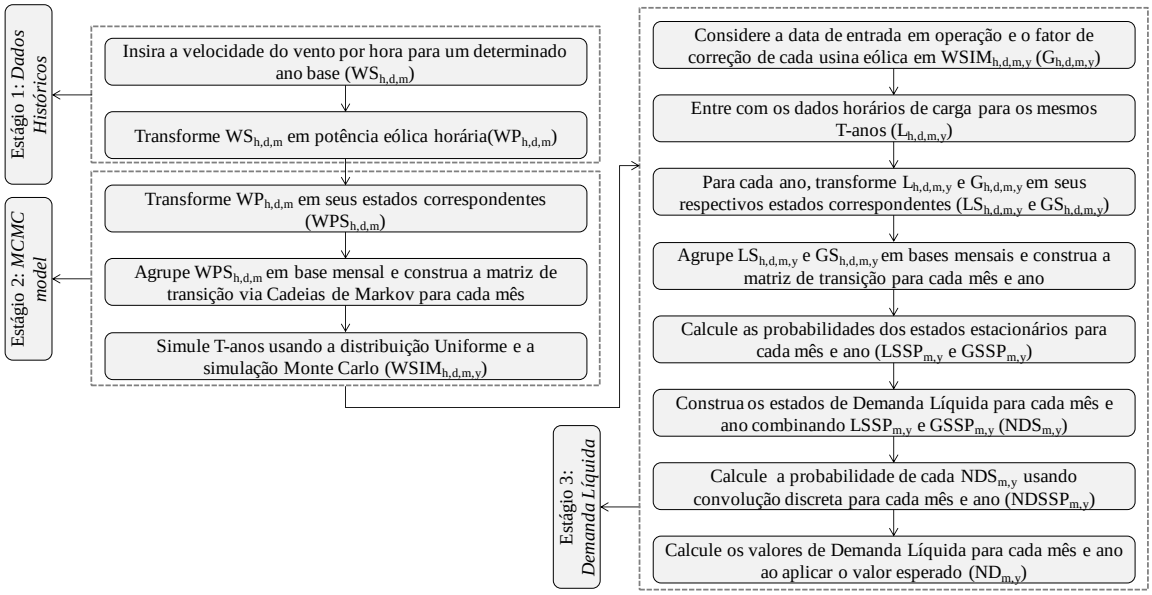

Figura 1 – Principais procedimentos da metodologia

a. Dados históricos

De acordo com (Papaefthymiou e Klöckl, 2008) um modelo estocástico baseado na geração eólica é mais apropriado e oferece vantagens básicas em comparação com o uso de um modelo baseado em dados de velocidade do vento. Há duas razões para sustentar: a primeira é a eliminação de qualquer erro na modelagem da velocidade do vento que aumenta por um fator cúbico a geração eólica correspondente quando a velocidade do vento estiver entre os valores de entrada e nominal; e o segundo é o número reduzido de estados, uma vez que a energia eólica é observada apenas para um determinado intervalo de valores de velocidade do vento.

O primeiro passo consiste em obter um histórico anual da série de velocidade do vento horária no local selecionado. Esta informação pode ser acessada através do Climate Forecast System Reanalysis (CFSR) (Saha *et al.*, 2011) mantida pelo The National Centers for Environmental Prediction (NCEP). Através do CFSR é possível obter a informação desejada por coordenadas geográficas com uma resolução espacial de 0.25º por 0.25º. Assim, a associação de uma série de velocidade do vento a um parque eólico foi realizada, pesquisando o ponto de medição que minimiza a distância entre eles.

Para transformar a série de velocidade de vento em dados de energia eólica, é necessário conhecer os seguintes parâmetros de turbina de cada um dos parques eólicos considerados: modelo, quantidade, altura média e curva de potência das turbinas. Para obter tais informações, os dados fornecidos pela Agência Nacional de Energia Elétrica (ANEEL) através do Banco de Informações de Geração (BIG) e pelo Operador Nacional do Sistema (ONS), bem como a página dos fabricantes das turbinas foram utilizados. Para associar a velocidade de vento medida aos parques eólicos, devem-se considerar os fatores de correção da altura (Manwell, McGowan e Rogers, 2010). O fator é calculado pela razão logarítmica das alturas das turbinas e o ponto no qual a medição do vento é realizada, como na Equação (1).

https://proceedings.science/p/85336?lang=pt-br

$$HF_i = \frac{\log(HT_i)}{\log(HM_i)} \quad (1)$$

Onde HF_i é o fator de correção da altura, HT_i é a altura da turbina e HM_i é a altura da medição associada ao parque i. A curva de potência eólica é dada em um formato de tabela onde, para cada velocidade do vento, há uma potência eólica correspondente, portanto, a transformação de uma dada velocidade de vento ($WS_{h,d,m}$) após a aplicação dos fatores de correção da altura, na potência eólica ($WP_{h,d,m}$) é facilmente obtida através da curva de potência.

b. Modelo Markov Chain Monte Carlo

O procedimento desenvolvido neste estudo para simular a energia eólica de maneira estocástica foi baseado no trabalho de (Almutairi, Hassan Ahmed e Salama, 2016) que usa a técnica Markov Chain Monte Carlo (MCMC).

O primeiro passo neste procedimento envolve o uso da técnica de agrupamento K-means (MacQueen, 1967) para transformar os dados de energia eólica ($WP_{h,d,m}$) em um número finito de estados ($WPS_{h,d,m}$). Para a técnica K-means, dado um número k de clusters e centróides iniciais M_k, a distância $D_{(k,i)}$ de cada valor de potência eólica WP_i para cada M_k é calculada e todos os valores de energia eólica são atribuídos ao centróide mais próximo. Os novos centróides dos clusters são calculados usando a média dos dados de energia eólica no cluster k e as distâncias são recalculadas. Esse processo é repetido até que os centróides se estabilizem após várias iterações. No final, os valores calculados de energia eólica são substituídos pelos centróides do cluster ao qual pertencem.

O segundo passo corresponde à criação das matrizes de transição da cadeia de Markov (P_{ind}), para cada mês, com as dimensões ($k \times k$), onde k é o número de estados calculados no passo anterior. A probabilidade de transição ($p_{(i,j)}$) do estado i para o estado j, para todos os índices $1 \leq (i,j) \leq k$, pode ser calculada como descrito na Equação (2).

$$p_{i,j} = \frac{n_{i,j}}{\sum_k n_{i,k}} \quad (2)$$

Onde $n_{i,j}$ é o número de transições do estado i para o estado j. Uma vez que a matriz de transição individual P_{ind} baseada nas probabilidades dos estados individuais é obtida, a matriz cumulativa de transição de probabilidade P_{cum} pode ser criada para que a última coluna de P_{cum} seja igual a 1 para cada linha e mês.

A terceira e última etapa usa as matrizes cumulativas de transição da cadeia de Markov e uma variável aleatória de distribuição uniforme para simular os valores horários da energia eólica para o horizonte de T-anos ($WSIM_{h,d,m,y}$). Este procedimento é detalhado descrito em (Almutairi, Hassan Ahmed e Salama, 2016) e é resumido a seguir: o estado inicial i é selecionado aleatoriamente, e um valor aleatório entre 0 e 1 é gerado a partir de uma variável aleatória de distribuição uniforme; o próximo estado de energia eólica é determinado pela comparação do valor do número aleatório com os elementos da i-ésima linha da transição de probabilidade cumulativa. Se o número gerado aleatoriamente for maior que a probabilidade cumulativa do estado anterior, mas menor ou igual à probabilidade cumulativa do estado seguinte, o estado seguinte será escolhido para representar o próximo estado. Este procedimento é repetido sequencialmente para simular todos os dados de energia eólica horária.

https://proceedings.science/p/85336?lang=pt-br

c. Demanda Líquida

A principal tarefa deste estudo é a inclusão da geração de energia eólica no despacho hidrotérmico brasileiro, considerando sua natureza estocástica. Para fazer isso, é crucial que todas as informações necessárias para cada parque eólico estejam disponíveis. Para considerar a data de início da operação na energia eólica simulada na etapa anterior, a parcela individual de cada parque eólico que ainda não começou a operar na data simulada é descontada do total. Ou seja, considere que existem n parques eólicos no banco de dados cada um com IC_i, de capacidade instalada, onde $i = 1, \dots, n$. A participação do parque eólico i é calculada como a divisão entre a capacidade instalada do parque eólico e a soma da capacidade instalada de todos os geradores, conforme descrito na Equação (3).

$$Share_i = \frac{IC_i}{\sum_i IC_i} \tag{3}$$

Se a data de entrada de tal gerador for dada pelo dia d, mês m e ano y, toda simulação de energia eólica antes dessa data deve ser descontada por $Share_i$. Como não é possível obter informações sobre o fator capacidade e disponibilidade para cada parque eólico, sugere-se o uso de um ano com geração mensal conhecida para calibrar os valores previstos, ou seja, para um mês m, o fator de correção CF_m será a energia eólica verificada sobre a simulada. O resultado desta etapa é a série de geração de energia eólica calibrada, calculada como mostrado na Equação 4.

$$G_{h,d,m,y} = WSIM_{h,d,m,y} \times \left(1 - \sum_i Share_{i,h,d,m,y}\right) \times CF_m \tag{4}$$

Para iniciar o cálculo da demanda líquida, os dados de carga horária são necessários para o mesmo horizonte da geração de energia eólica. Devido à dificuldade em encontrar dados oficiais de carga horária no Brasil, um perfil de carga padrão ($LP_{m,h}$) foi criado ao longo dos meses e horas, sendo aplicado à carga mensal $ML_{m,y}$ esperada pelo governo para cada ano no horizonte e resultando nos dados de carga horária $L_{h,d,m,y} = LP_{m,h} \times ML_{m,y}$. Depois disso, o algoritmo K-means foi usado para discretizar a geração de energia eólica e transformar a série em estados ($LS_{h,d,m,y}$ e $GS_{h,d,m,y}$). Além disso, em uma etapa subsequente, as matrizes de transição da cadeia de Markov para cada mês foram criadas, seguindo as mesmas etapas descritas acima. A necessidade de recalcular os estados e as matrizes de transição para a série de geração eólica vem do fato de que a série originada na etapa anterior foi alterada com a entrada das datas de entrada em operação e o fator de correção.

Para ser capaz de combinar estados de geração e carga em estados de demanda líquida é necessário associar uma única probabilidade a cada estado. Visto que na teoria das Cadeias de Markov as probabilidades dos estados estacionários podem ser consideradas o comportamento de longo prazo do sistema após o efeito das condições iniciais diminuírem, isto é, em uma situação de equilíbrio, essa é a probabilidade que representará a ocorrência de cada estado. Então, a quarta etapa neste estágio calcula as probabilidades dos estados estacionários de cada série de carga e geração para cada mês e ano ($LSSP_{m,y}$ e $GSSP_{m,y}$).

De acordo com (Leite da Silva, Melo e Cunha, 1991) para encontrar os parâmetros do modelo de uma combinação $S = S(1) - S(2)$, deixe c_i e p_i denotar os parâmetros associados ao estado i do componente $S(1)$ e c_j e p_j os parâmetros para o estado j do componente $S(2)$. Suponha que a combinação dos estados i e j forneça o estado k do sistema S. Assumindo que os estados i e j são estatisticamente independentes, então os parâmetros de S associados ao estado k são $c_k = c_i - c_j$ e $p_k = p_i \times p_j$. Como a demanda líquida pode ser caracterizada como a diferença entre a carga e a geração, ou seja, $ND = L - G$, a penúltima etapa desse procedimento combina os parâmetros

https://proceedings.science/p/85336?lang=pt-br

do modelo de carga e geração para derivar os estados e probabilidades da demanda líquida ($NDS_{m,y}$ e $NDSSP_{m,y}$).

O resultado final deste sistema é um valor para cada mês e ano no período previsto, e para isso a última etapa do processo compreende no cálculo dos valores esperados entre os estados e a probabilidade associada à demanda líquida, resultando em um valor da demanda líquida para cada mês e ano ($ND_{m,y} = \sum_w NDS_{m,y} \times NDSSP_{m,y}$, onde w é o número de estados de $NDS_{m,y}$).

4. Resultados e análises

Nesta seção, a metodologia proposta é aplicada ao Nordeste brasileiro para prever a geração de energia eólica de janeiro de 2017 até dezembro de 2021. O ano de 2016 é utilizado como ano base, portanto as séries de velocidade do vento extraídas da CFSR são de 01 de janeiro a 31 de dezembro de 2016 e o perfil de carga padrão é construído com base na carga horária para 2016, obtida do Operador Nacional do Sistema.

A região Nordeste é composta pelos estados de Alagoas, Bahia, Ceará, Maranhão, Paraíba, Piauí, Pernambuco, Rio Grande Norte e Sergipe, compreendendo a maior extensão costeira do país (3000 km). De acordo com a ANEEL, em julho de 2017, existiam 362 usinas eólicas em operação no Nordeste, 144 unidades em construção e 127 a construir. Sendo assim, a base de dados considerada contem 597 usinas, considerando usinas em operação, em construção e a construir, pois somente as que possuem data de entrada são inseridas no cálculo.

A carga mensal prevista no Nordeste para o horizonte de previsão (janeiro 2017 a dezembro de 2021) está na Figura 2. Para transformar esta carga mensal em carga horária foi utilizado o perfil exposto na Tabela 1. Assim, a maior carga a ser atendida encontra-se no mês de Julho às 20 horas e a menor em Novembro às 8 horas.

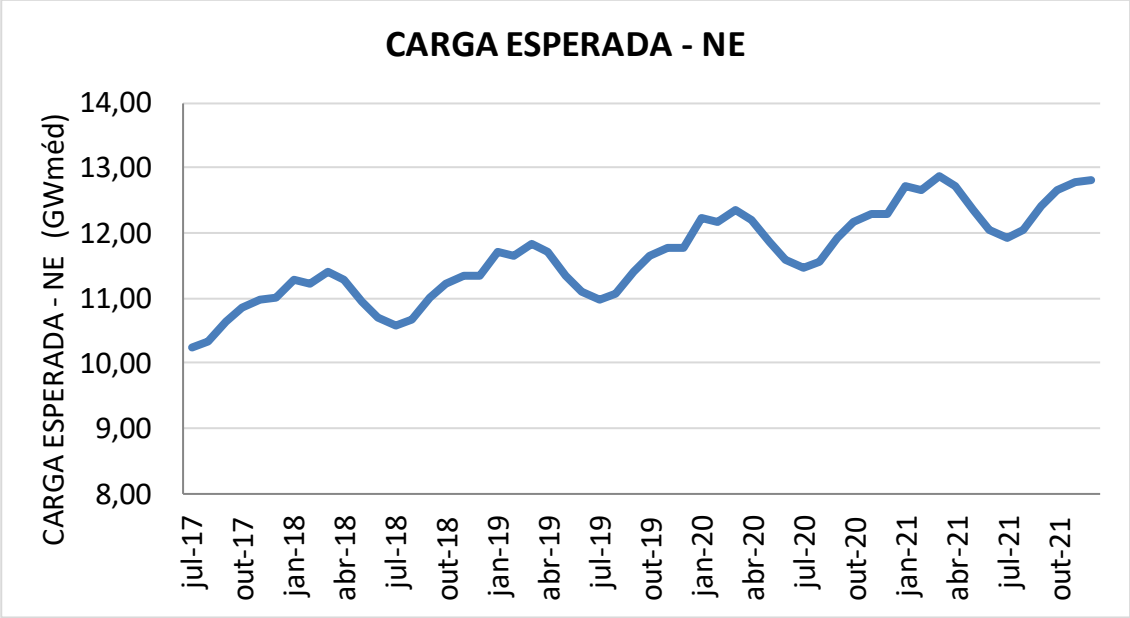

Figura 2 – Carga esperada para o subsistema Nordeste (CCEE, 2017)

https://proceedings.science/p/85336?lang=pt-br

Tabela 1 – Perfis de carga horária do subsistema Nordeste baseado no consumo horário de 2013

	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
Hora 1	1.06	1.05	1.03	1.02	1.01	1.00	1.00	1.00	1.01	1.03	1.05	1.07
Hora 2	1.02	1.01	0.99	0.98	0.97	0.96	0.96	0.96	0.96	0.99	1.01	1.03
Hora 3	0.98	0.97	0.95	0.95	0.94	0.93	0.93	0.92	0.93	0.96	0.98	0.99
Hora 4	0.96	0.94	0.93	0.92	0.92	0.91	0.91	0.90	0.91	0.93	0.94	0.96
Hora 5	0.94	0.92	0.91	0.91	0.91	0.90	0.90	0.89	0.90	0.92	0.92	0.94
Hora 6	0.92	0.91	0.90	0.90	0.90	0.89	0.89	0.89	0.89	0.91	0.91	0.93
Hora 7	0.92	0.89	0.85	0.85	0.85	0.85	0.86	0.85	0.83	0.86	0.89	0.91
Hora 8	0.85	0.85	0.84	0.85	0.85	0.85	0.86	0.86	0.85	0.84	0.83	0.84
Hora 9	0.86	0.87	0.92	0.93	0.93	0.93	0.93	0.93	0.94	0.89	0.85	0.86
Hora 10	0.93	0.95	1.00	1.00	1.00	1.01	1.00	1.01	1.01	0.97	0.93	0.93
Hora 11	1.00	1.01	1.03	1.03	1.03	1.04	1.03	1.04	1.04	1.02	1.01	1.00
Hora 12	1.03	1.03	1.05	1.05	1.05	1.06	1.05	1.06	1.06	1.05	1.04	1.03
Hora 13	1.05	1.05	1.05	1.04	1.05	1.05	1.05	1.05	1.05	1.05	1.06	1.05
Hora 14	1.04	1.04	1.03	1.03	1.03	1.03	1.03	1.03	1.04	1.04	1.05	1.04
Hora 15	1.02	1.04	1.07	1.06	1.06	1.06	1.05	1.07	1.07	1.05	1.03	1.03
Hora 16	1.05	1.07	1.08	1.07	1.07	1.07	1.06	1.08	1.08	1.07	1.07	1.06
Hora 17	1.06	1.07	1.06	1.05	1.05	1.06	1.05	1.06	1.06	1.06	1.08	1.07
Hora 18	1.04	1.04	1.01	1.01	1.02	1.02	1.02	1.03	1.02	1.04	1.06	1.04
Hora 19	1.00	0.99	0.97	1.04	1.07	1.07	1.06	1.04	1.05	1.04	1.02	1.00
Hora 20	0.96	0.98	1.06	1.07	1.08	1.08	1.10	1.09	1.08	1.06	1.02	0.97
Hora 21	1.08	1.06	1.04	1.05	1.05	1.05	1.06	1.06	1.05	1.06	1.07	1.06
Hora 22	1.07	1.06	1.05	1.05	1.05	1.04	1.05	1.05	1.04	1.05	1.05	1.05
Hora 23	1.06	1.07	1.09	1.09	1.08	1.08	1.08	1.08	1.08	1.06	1.05	1.04
Hora 24	1.09	1.09	1.07	1.06	1.05	1.05	1.05	1.05	1.05	1.06	1.08	1.08

Após todas as etapas calculadas, a geração eólica espera pelo modelo de Demanda Líquida (DL) e pelo órgão oficial (NW) é apresentada na Figura 3. Note que o modelo aqui utilizado espera uma geração eólica maior do que o oficial, porém nos períodos de menor presença de vento o modelo de DL é mais pessimista do que o oficial. Como consequência desse resultado de geração eólica, a carga a atender com geração eólica no modelo oficial é maior do que o modelo de Demanda Líquida, como poder ser visto na Figura 4.

https://proceedings.science/p/85336?lang=pt-br

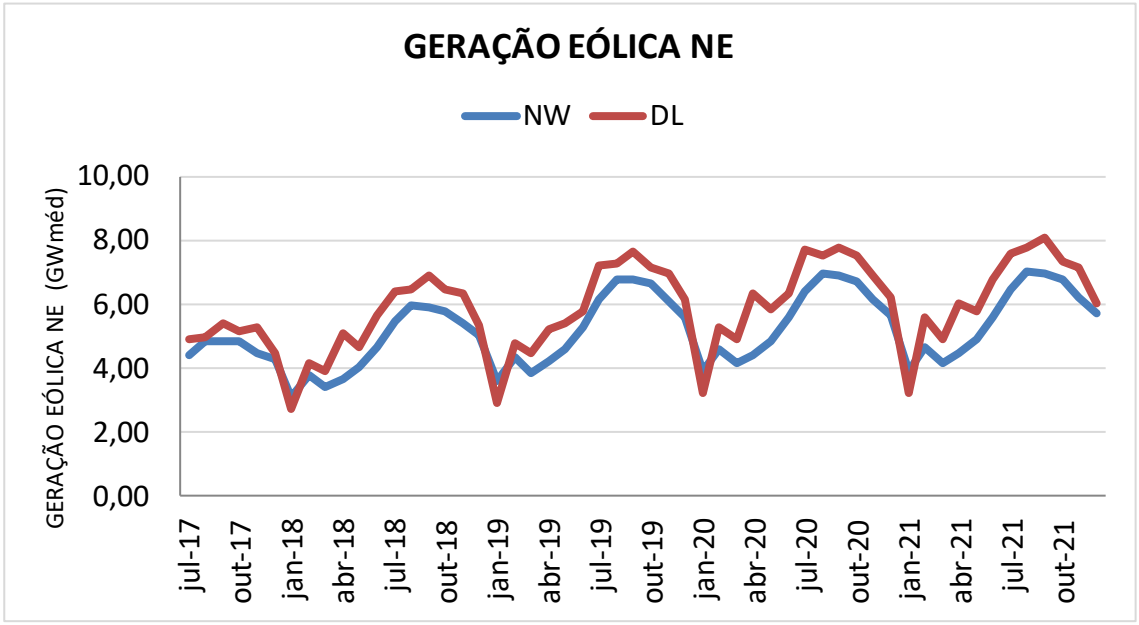

Figura 3 – Geração eólica esperada para o horizonte de previsão de acordo com o Newave e a Demanda Líquida

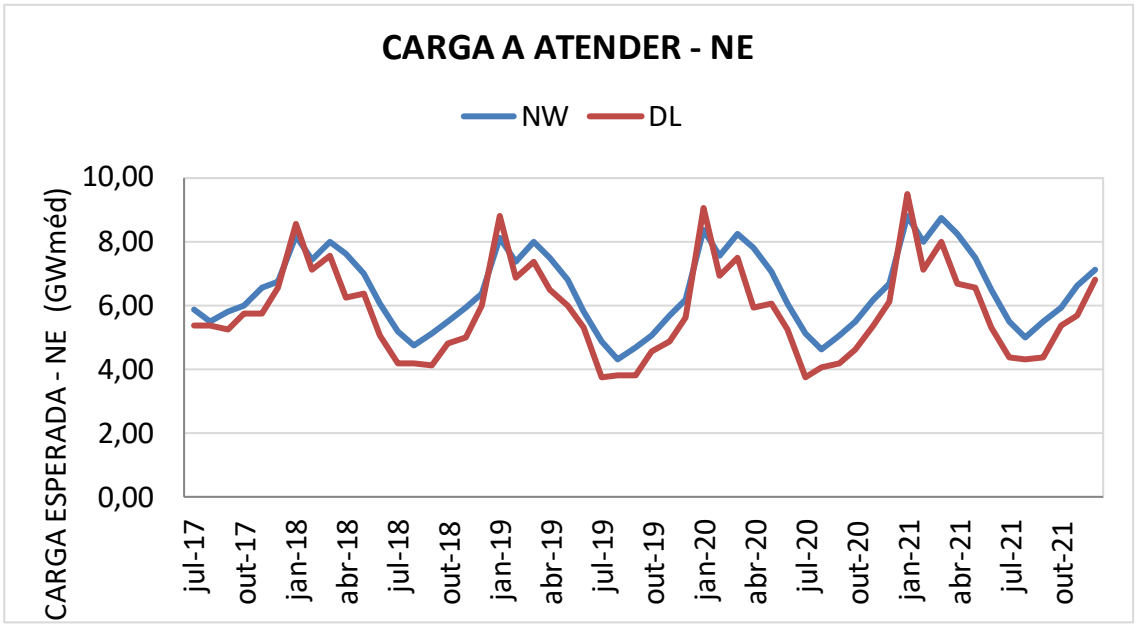

Figura 4 – Carga a atender para o horizonte de previsão de acordo com o Newave e a Demanda Líquida

Com esses dois resultados (NW e DL) é possível avaliar através do Modelo de Despacho Hidrotérmico qual o comportamento esperado do sistema, como por exemplo, a Energia Armazenada Média (Figura 5) e a Geração Térmica Média (Figura 6). Note que como o modelo aqui empregado espera uma geração eólica em média maior do que o modelo oficial é consequência um uso menor das hidráulicas e assim uma maior economia da água nos reservatórios, traduzidas como Energia armazenada. O mesmo pensamento é aplicado para a Geração Térmica, pois com menor geração eólica usam-se mais térmicas e assim a geração térmica esperada pelo NW é maior do que a estimado pelo DL.

https://proceedings.science/p/85336?lang=pt-br

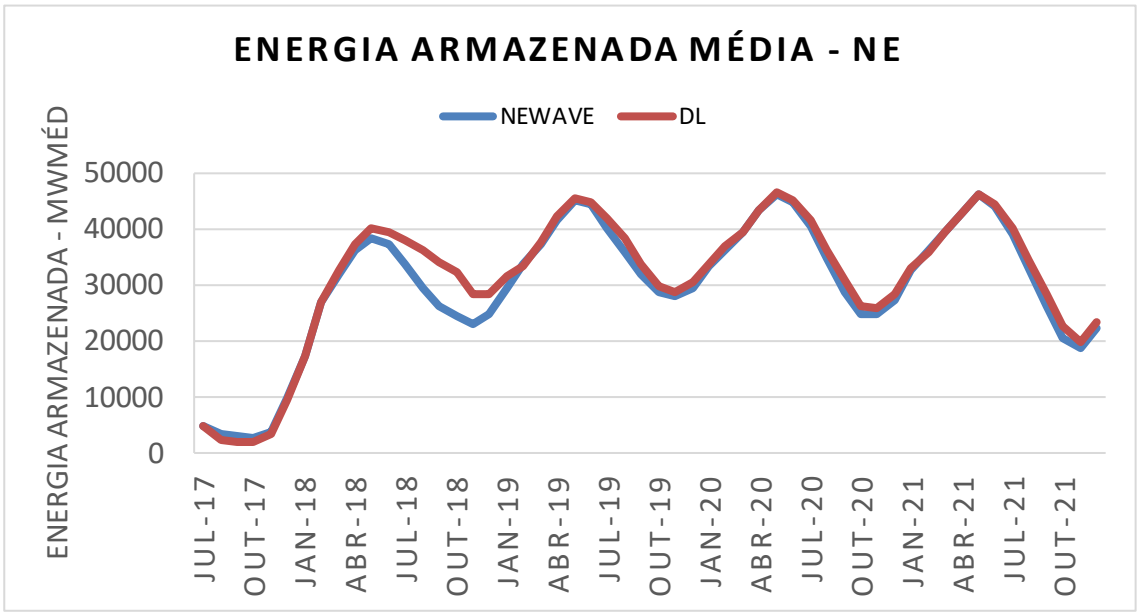

Figura 5 – Energia armazenada média para o horizonte de previsão de acordo com o Newave e a Demanda Líquida

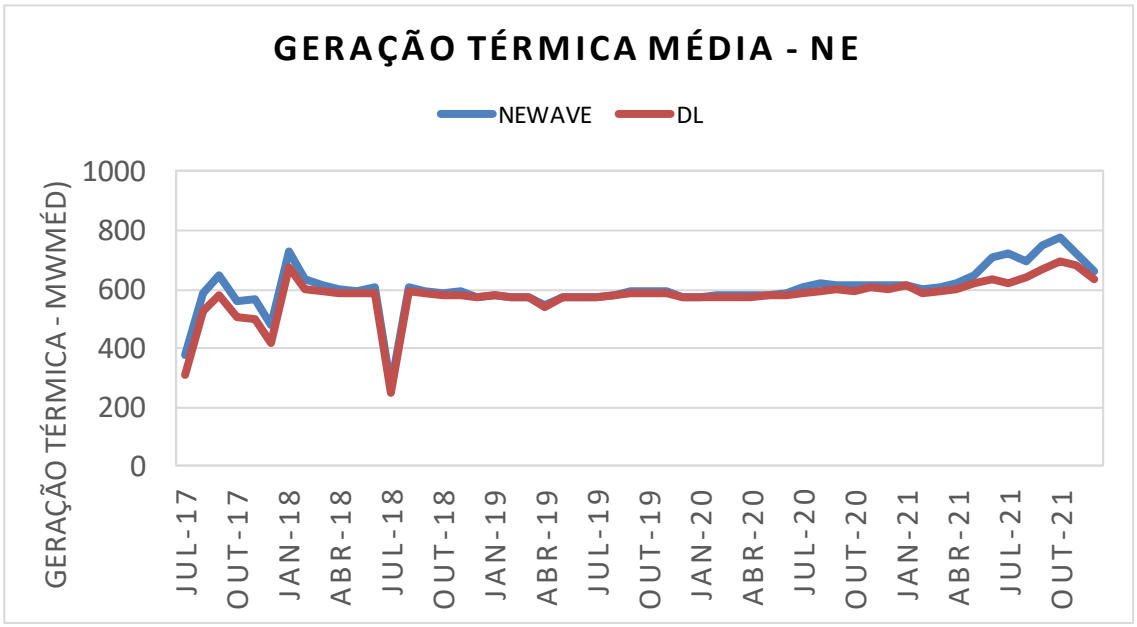

Figura 6 – Geração térmica média para o horizonte de previsão de acordo com o Newave e a Demanda Líquida

5. Conclusões

Este artigo propõe uma estrutura para a incorporação da geração de energia eólica no atual despacho hidrotérmico brasileiro. A metodologia é resumida em três estágios, compreendendo treze etapas, onde o primeiro estágio lida com os dados históricos, o segundo estágio com a simulação da energia eólica via MCMC e o estágio final com o cálculo da demanda líquida. O estágio de dados históricos envolve a obtenção de dados de velocidade de vento a partir de um banco de dados de reanálise e transformação em energia eólica pelas curvas de potência eólica. Uma série temporal de energia eólica sintética baseada no modelo MCMC é criada para todo o horizonte de previsão, considerando também a data de entrada em operação de cada parque eólico e seu fator de capacidade e disponibilidade. No estágio de demanda líquida, um perfil de carga padrão é calculado e aplicado à previsão de carga mensal, seguido pela discretização de

https://proceedings.science/p/85336?lang=pt-br

ambas as séries de geração e carga em estados finitos. Nesse estágio, as matrizes de transição das Cadeias de Markov e as probabilidades dos estados estacionários também são estimadas. A combinação dos estados de geração e carga em um único valor de demanda líquida para cada mês do período de planejamento é executada através do cálculo da convolução discreta e do valor esperado.

A partir da utilização do deck de preços do Newave de julho de 2017 foram comparados os resultados do modelo oficial (NW) e do modelo proposto (ND). O modelo proposto prevê uma maior geração de energia eólica quando comparado com o oficial, ocorrendo em uma maior reserva de Energia Armazenada e uma menor Geração Térmica quando analisado pelo Modelo de Despacho Hidrotérmico.

Por fim, conclui-se que o objetivo deste estudo foi satisfatoriamente alcançado, uma vez que a metodologia sugerida demonstra, através dos resultados, que foi capaz de: (i) reproduzir a variável comportamento da série temporal do vento; e (ii) inserir a geração eólica no despacho atual considerando sua estocasticidade. Como trabalhos futuros sugere-se a utilização de diferentes métodos de simulação de séries de vento e/ou potência eólica e também a inserção da geração eólica diretamente nas equações do despacho hidrotérmico.

Referências Bibliográficas

ALEXIADIS, M. C. *et al.* Short-term forecasting os Wind speed and related electrical power. **Solar Energy**, v. 83, p. 61–68, 1998.

ALMUTAIRI, A.; HASSAN AHMED, M.; SALAMA, M. M. A. Use of MCMC to incorporate a wind power model for the evaluation of generating capacity adequacy. **Electric Power Systems Research**, v. 133, p. 63–70, 2016.

ANEEL. **BIG - Banco de Informações de Geração [Generation Information Bank]**. Disponível em: <http://www2.aneel.gov.br/aplicacoes/capacidadebrasil/capacidadebrasil.cfm>. Acesso em: 5 nov. 2017.

BILLINTON, R.; CHEN, H.; GHAJAR, R. Time-series models for reliability evaluation of power systems including wind energy. **Microeletronic Reliability**, v. 36, n. 9, p. 1253–1261, 1996.

CASTINO, F.; FESTA, R.; RATTO, C. F. Stochastic modelling of Wind velocities time series. **Journal of Wind Engineering and Indutrial Aerodynamics**, v. 74–76, p. 141–151, 1998.

CCEE. **Biblioteca Virtual**. Disponível em: <https://www.ccee.org.br/portal/faces/acesso_rapido_header_publico_nao_logado/biblioteca_virtual?palavrachave=Conjunto de arquivos para cálculo&_afrLoop=870851647413887&_adf.ctrl-state=9ll9uhpyu_27#!%40%40%3F_afrLoop%3D870851647413887%26palavrachave%3DConjunto%2Bde%2Barquivos%2Bpara%2Bc%25C3%25A1lculo%26_adf.ctrl-state%3D9ll9uhpyu_31>. Acesso em: 8 dez. 2017.

IVERSEN, E. *et al.* Short-term probabilistic forecasting of wind speed using stochastic differential equations. **International Journal of Forecasting**, v. 32, n. 3, p. 981–990, 2016.

JUNG, J.; BROADWATER, R. Current status and future advances for Wind speed and power forecasting. **Renewable and Sustainable Energy Reviews**, v. 31, p. 762–777, 2014.

LANDRY, M. *et al.* Probabilistic gradient boosting machines for GEFCom2014 wind forecasting. **International Journal of Forecasting**, v. 32, n. 3, p. 1061–1066, 2016.

LEITE DA SILVA, A. M.; MELO, A. C. G.; CUNHA, S. H. F. Frequency and duration method for reliability evaluation of large-scale hydrothermal generating systems. **Generation Transmission and Distribution, IEE Proceedings C**, v. 138, n. 1, p. 94–102, 1991.

MACQUEEN, J. **Some methods for classification and analysis of multivariateobservations**Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability. **Anais**...1967

MANWELL, J. F.; MCGOWAN, J. G.; ROGERS, A. L. **Wind Energy Explained: Theory, Design and Application**. [s.l: s.n.].

https://proceedings.science/p/85336?lang=pt-br

MINISTÉRIO DE MINAS E ENERGIA. **Energia Eólica no Brasil e no Mundo**. [s.l: s.n.].

OLIVEIRA, F. L. C.; SOUZA, R. C.; MARCATO, A. L. M. A time series model for building scenarios trees applied to stochastic optimisation. **International Journal of Electrical Power and Energy Systems**, v. 67, p. 315–323, 2015.

ONS. **Histórico da Operação 2016 [Operation History 2016]**.

OPERADOR NACIONAL DO SISTEMA ELÉTRICO. **Histórico da Operação - Geração de Energia**http://www.ons.org.br/Paginas/resultados-da-operacao/historico-da-operacao/geracao_energia.aspx, 2018. Disponível em: <http://www.ons.org.br/Paginas/resultados-da-operacao/historico-da-operacao/geracao_energia.aspxx>

PAPAEFTHYMIOU, G.; KLÖCKL, B. MCMC for wind power simulation. **IEEE Transactions on Energy Conversion**, v. 23, n. 1, p. 234–240, 2008.

PINSON, P. Wind energy: forecasting challenges for its operational management. **Statistical Science**, v. 28, n. 4, p. 564–585, 2013.

SAHA, S. *et al.* **NCEP Climate Forecast System Version 2 (CFSv2) Selected Hourly Time-Series Products**. Disponível em: <https://doi.org/10.5065/D6N877VB>. Acesso em: 3 mar. 2017.

SUOMALAINEN, K. *et al.* Correlation analysis on wind and hydro resources with electricity demand and prices in New Zealand. **Applied Energy**, v. 137, p. 445–462, 2015.

ZHANG, Y.; WANG, J.; WANG, X. Review on probabilistic forecasting of wind power generation. **Renewable and Sustainable Energy Reviews2**, v. 32, p. 255–270, 2014.

https://proceedings.science/p/85336?lang=pt-br