LI Simpósio Brasileiro de Pesquisa Operacional
Limeira–SP, 02 a 06 de setembro de 2019

Um modelo de séries temporais com regularização interquantis para previsão probabilística de geração de energia eólica

Marcelo Ruas
PUC-Rio
R. Marquês de São Vicente, 225 - Gávea, Rio de Janeiro
mcruas@gmail.com

Alexandre Street
PUC-Rio
R. Marquês de São Vicente, 225 - Gávea, Rio de Janeiro

Cristiano Fernandes
PUC-Rio
R. Marquês de São Vicente, 225 - Gávea, Rio de Janeiro

RESUMO

Produzir previsões probabilísticas de Recursos Renováveis é um tópico de interesse em aplicações de Sistemas de Energia. Neste trabalho, foca-se em gerar cenários futuros de geração de energia eólica, apesar de que os métodos propostos podem ser aplicados diretamente para outras fontes de recursos. A maior parte dos métodos de séries temporais utilizados para produzir tais previsões baseia-se na hipótese de erros gaussianos ou distribuição gaussiana; no entanto, em aplicações práticas, principalmente naquelas relacionadas à análise de risco, são requeridos modelos não-gaussianos com foco nas caudas. Assim, neste trabalho, desenvolve-se um modelo de séries temporais baseados numa função de distribuição condicional não-paramétrica. A distribuição condicional é formada por um modelo que considera quantis como uma função linear das suas variáveis exógenas com dupla regularização: uma para criar um conjunto de quantis com suavização e outro para seleção de variáveis. No modelo proposto, os quantis estimados estão conectados, criando a ideia de um modelo de distribuição condicional único. Estudos de casos com dados reais de produção de energia eólica do nordeste brasileiro ilustram as vantagens e propriedades dos modelos e discussões são conduzidas.

PALAVRAS CHAVE. Regressão Quantílica, Modelo Não Paramétrico, Previsão de Energia Eólica

https://proceedings.science/p/106671?lang=pt-br

1. Introdução

A previsão da produção de usinas renováveis é um tópico de interesse crescente dentro da comunidade de sistemas de energia por causa da quantidade de aplicações que se beneficiam da mesma. A natureza intermitente das fontes de energia renovável e a complexidade das aplicações em sistemas de energia requerem desenvolvimentos e desafios específicos, como por exemplo a substituição de métodos de previsão pontuais por métodos de previsão probabilísticos. Tais metodologias são, em geral, utilizadas para dar suporte a problemas cujo risco seja um fator importante, principalmente a partir da correta estimação dos quantis extremos [Pinson et al., 2009]. Veja, por exemplo, Bessa et al. [2012]; Hoeltgebaum et al. [2018]; Gallego-Castillo et al. [2016]; Møller et al. [2008]; Nielsen et al. [2006]; Bremnes [2004]; Wan et al. [2017]. O objetivo principal destes trabalhos é a proposição de modelos capazes de gerar cenários a partir da distribuição de probabilidade das séries temporais de geração renovável. Isto é particularmente importante em aplicações em sistemas de energia baseados em modelos de otimização estocástica [Birge e Louveaux, 2011], como em comercialização de energia [Fanzeres et al., 2015], problema de despacho [Papavasiliou e Oren, 2013; Papavasiliou et al., 2015] e planejamento da expansão e investimentos [Passos et al., 2017; Munoz e Watson, 2015; Saldarriaga-Cortés et al., 2019] são exemplos em que os cenários exercem um papel crucial.

Em Zhang et al. [2014], o autor revisa as metodologias mais usuais utilizadas para fazer previsão probabilística, classificando-as em modelos paramétricos e não paramétricos. As principais características dos **modelos paramétricos** são (i) assumir um formato de distribuição e (ii) baixos custos computacionais. O modelo ARIMA-GARCH, por exemplo, assume uma distribuição gaussiana *a priori*. No outro lado, **modelos não paramétricos** possuem as seguintes características: (i) não requerem que se assuma nenhuma distribuição, (ii) necessitam de mais dados para estimar um modelo e (iii) possuem altos custos computacionais. Exemplos de modelos populares são regressão quantílica, estimação de densidade com funções kernel, inteligência artificial, ou uma combinação deles. Apesar de muitos métodos usuais em séries temporais considerarem a distribuição como gaussiana, as séries temporais de geração com recursos renováveis como solar e eólica, são reconhecidamente não gaussianas, conforme apresentado em Bessa et al. [2012]; Jeon e Taylor [2012]; Taylor e Jeon [2015]; Wan et al. [2017]. Assim, a utilização de métodos não paramétricos aparece como uma alternativa interessante.

O trabalho seminal de Koenker e Bassett Jr [1978] define regressão quantílica (RQ) como a solução de um problema de otimização em que a soma de uma função "visto"ρ (definida formalmente na próxima seção), uma função linear por partes convexa, é minimizada. O resultado deste problema de otimização São quantis condicionais, e essa abordagem é empregada em diversos outros trabalhos, como Chao et al. [2012]; Li et al. [2007]; Bosch [1995]; Gallego-Castillo et al. [2016]; Møller et al. [2008]; Nielsen et al. [2006]; Bremnes [2004]; Wan et al. [2017]. Em Gallego-Castillo et al. [2016]; Møller et al. [2008]; Nielsen et al. [2006]; Bremnes [2004]; Wan et al. [2017], RQ são utilizados para modelar a distribuição condicional de séries temporais de geração de energia eólica. Um modelo de quantis que se atualizam no tempo é apresentado em Møller et al. [2008]. Os autores apresentam uma versão modificada do algoritmo simplex para incorporar novas observações sem que o procedimento de estimação seja reiniciado. Em Nielsen et al. [2006], os autores produzem um modelo quantílico a partir de previsões probabilísticas já existentes. A abordagem de Gallego-Castillo et al. [2016] é utilizar RQ com um modelo não paramétrico. Os autores adicionam um termo de penalização de uma função kernel no espaço de Hilbert. Em Wan et al. [2017], utiliza-se um tipo de redes neurais denominado *extreme learning machine*, em que cada quantil é a combinação linear de camadas intermediárias.

O objetivo deste trabalho é propor um modelo de séries temporais não paramétrico e adaptativo, a partir da estimação conjunta de quantis através de regressão quantílica. Num segundo passo, simulações de Monte Carlo são geradas. Para isso, as probabilidades no intervalo $[0, 1]$ são discretizados e estima-se com uma granularidade especificada pelo usuário. Ao invés de possuir modelos independentes, os quantis são estimados simultaneamente por um modelo único, garantindo assim que o modelo seja coerente na construção de uma função densidade condicional (FDC). Além disso, o modelo de otimização proposto assegura que os coeficientes fornecidos pela regressão são suavizados e garante-se que a FDC seja monotônica crescente.

As contribuições do trabalho são as seguintes:

- Um modelo adaptativo não paramétrico baseado em séries temporais para simular cenários de recursos renováveis através de um procedimento de Monte Carlo. O modelo proposto é concebido através da estimação conjunta de um vetor de quantis através de regressão quantílica. O modelo possui dois termos de regularização. Enquanto o primeiro deles considera o método adaLASSO para selecionar variáveis explicativas (valores defasados da série), o segundo impõe uma ligação coerente entre os vários quantis, formando assim a função distribuição condicional.

- Um modelo de otimização linear que estima conjuntamente o modelo de séries temporais não paramétrico proposto, assegurando as propriedades estruturais citadas anteriormente para a FDC. Isto é feito através de um filtro ℓ_1, proposto por Kim et al. [2009], onde o valor absoluto da segunda diferença dos coeficientes autoregressivos é penalizada.

O resto do trabalho está organizado da forma a seguir. Na seção II, é apresentado o framework de regressão quantílica e o modelo proposto: o *quantile regularized adaptive lasso* (QRAL). Nesta seção, discute-se a forma como a estimação liga os diferentes quantis para formar um modelo único e coerente para depois gerar a FDC. A seção III apresenta como estimar, avaliar e simular o modelo proposto. Na seção IV, apresenta-se um estudo de caso para avaliar o modelo proposto, considerando dados reais de uma usina eólica do nordeste brasileiro. A seção V conclui este trabalho.

2. Modelo de Séries Temporais baseado em Regressão Quantílica

Seja $Q_{Y|X} : [0, 1] \times \mathbb{R}^d \to \mathbb{R}$ a função de distribuição condicional da variável aleatória dependente Y para um dado valor x de uma variável aleatória d-dimensional X, composto por defasagens de Y. A função α–quantílica pode ser definida como:

$$Q_{Y|X}(\alpha, x) = F^{-1}_{Y|X=x}(\alpha) = \inf\{y : F_{Y|X=x}(y) \geq \alpha\}. \tag{1}$$

A função Q é o inverso da FDC F, e representa o menor valor y pelo qual a função de distribuição é maior que uma dada probabilidade α.

Seja ρ a função "visto":

$$\rho_\alpha(x) = \begin{cases} \alpha x & \text{se } x \geq 0 \\ (\alpha - 1)x & \text{se } x < 0 \end{cases}. \tag{2}$$

A função α–quantílica de uma dada amostra finita $\{y_t, x_t\}_{t \in T}$, em que T é um conjunto de índices de tempo, pode ser estimada através da solução do seguinte problema de otimização convexo:

$$\hat{Q}_{Y|X}(\alpha, \cdot) \ \in \ \arg\min_{q \in \mathbb{Q}} \sum_{t \in T} \rho_\alpha(y_t - q_\alpha(x_t)). \tag{3}$$

Para inferência em Regressão Quantílica e propriedades de amostras finitas, veja o capítulo 3 em Koenker [2005]. A função α-quantílica $q(\cdot)$ pertence ao espaço funcional $\mathbb{Q}$. Pode-se assumir diferentes configurações para $\mathbb{Q}$, dependendo do tipo de função que desejamos encontrar para q. Algumas propriedades, no entanto, devem fazer fazer parte da escolha do espaço, como sendo contínua e possuindo uma primeira diferença limitada. Neste trabalho, apenas o caso em que $\mathbb{Q}$ é uma função linear é considerado. Assim, q é da forma

$$q_\alpha(x_t) = \beta_0 + \beta^T x_t.$$

Este modelo possui dupla regularização: tanto na seleção de variáveis como na suavização dos coeficientes entre quantis.

O filtro de segunda diferença é dado por

$$D^2_{\alpha_j}\beta_{pj} := \frac{\left(\frac{\beta_{p,j+1}-\beta_{pj}}{\alpha_{j+1}-\alpha_j}\right) - \left(\frac{\beta_{p,j}-\beta_{p,j-1}}{\alpha_j-\alpha_{j-1}}\right)}{\alpha_{j+1}-\alpha_{j-1}}. \tag{4}$$

A penalização presente no termo final da equação (5) assegura transições suaves entre os coeficientes através dos quantis. Mais detalhes sobre o filtro ℓ_1 podem ser obtidos em Kim et al. [2009]. Esta transição suave ajuda a criar um modelo multiquantílico único.

Quando o modelo possui muitas variáveis explicativas, é necessário alguma metodologia para selecionar os mais relevantes. Na prática, significa que alguns coeficientes do vetor $\beta_j = [\beta_{1,j} \cdots \beta_{pj}]$ podem assumir valor zero, para cada quantil α. As técnicas de LASSO/adaLASSO são interessantes para esse contexto, pois se encaixam num problema de programação linear. Eles consistem em penalizar a norma ℓ_1 do tamanho dos coeficientes, calibrados pelo tamanho do parâmetro λ, que define a magnitude da penalização. Além de comprimir os coeficientes em direção a zero, eles possuem a capacidade de efetivamente zerar estes coeficientes, fazendo a seleção de variáveis simultaneamente à estimação [Tibshirani, 1996]. O uso destes métodos já foi empregado em RQ por Li e Zhu [2008]; Ciuperca [2016]; Belloni e Chernozhukov [2009]; Zou e Yuan [2008]; Jiang et al. [2014]. Para informações sobre propriedades específicas e taxas de convergência destes, ver Belloni e Chernozhukov [2009]. Conforme discutido em Ciuperca [2016], a principal vantagem do adaLASSO sobre o LASSO é a propriedade de oráculo para a seleção de variáveis.

Seja a discretização finita do intervalo $[0, 1]$ dado pela sequência de probabilidades $0 < \alpha_1 < \alpha_2 < \cdots < \alpha_{|J|} < 1$ e seja A o conjunto tal que $A = \{\alpha_j \mid j \in J\}$, onde J designa conjunto de índices para as probabilidades α. Os α-quantis são, deste ponto em diante, indexados por j, identificando os diferentes modelos que são estimados simultaneamente. Uma propriedade que deve ser respeitada é a monotonicidade da função quantílica Q, tal que $q_{\alpha_1} \leq q_{\alpha_2} \cdots \leq q_{\alpha_{|J|}}$. A sequência de quantis define uma função quantílica contínua após interpolação.

O modelo proposto, denominado **quantile regularized adaptive LASSO (QRAL)**, é definido por um vetor de coeficientes β_{0j} e pela matriz de tamanho $|P| \times |J|$ dos coeficientes dos regressores β_{pj}, que são a solução do seguinte problema de minimização:

$$\min_{\beta_{0j},\beta_j} \sum_{j\in J}\left(\sum_{t\in T}\rho_{\alpha_j}(y_t - (\beta_{0j} + \beta_j^T x_t)) + \lambda \sum_{p\in P} w^\delta_{pj} \mid \beta_{pj} \mid\right) + \gamma \sum_{p\in P}\sum_{j\in J'} |D^2_{\alpha_j}\beta_{pj}|, \tag{5}$$

subject to

$$\beta_{0j} + \beta_j^T x_t \leq \beta_{0,j+1} + \beta_{j+1}^T x_t, \qquad \forall t \in T, \forall j \in J_{(-1)}, \tag{6}$$

https://proceedings.science/p/106671?lang=pt-br

em que $\tilde{\beta}_{pj}$ são os coeficientes do LASSO - feito no primeiro estágio da estimação do AdaLASSO - e $w_{pj} = 1/\tilde{\beta}_{pj}$. O parâmetro δ é um parâmetro exponencial e normalmente possui valor 1. A soma dos valores absolutos compõe o filtro da segunda diferença $\sum_{j\in J'}\sum_{p\in P}|D^2_{\alpha_j}\beta_{pj}|$, e é adicionado na função objetivo multiplicado pelo parâmetro γ. Finalmente, $J_{(-1)} = \{2,\ldots,|J|\}$ é um conjunto contendo todos os índices com exceção do primeiro elemento e em $J' = \{2,\ldots,|J|-1\}$ excluem-se o primeiro e o último elemento. Estes dois conjuntos auxiliares são necessários para incorporar a restrição (6), que assegura que a função quantílica seja monotônica, forçando que, para cada x_t e α_j–quantil, $q_{\alpha_j}(x_t) \leq q_{\alpha_{j+1}}(x_t)$.

Com essa abordagem, é possível tomar conta do problema do cruzamento de quantis, assim como manter uma estrutura coerente entre quantis com a estratégia de produzir um modelo único, já que a estimação de cada quantil está relacionada com os outros. A conexão entre eles se dá com o último termo de penalização na expressão (5), o que assegura também uma solução linear por partes e contínua Kim et al. [2009], interessante para o tratamento em futuras aplicações de otimização com programação linear.

3. Procedimentos de Estimação e Simulação

Esta seção apresenta os aspectos computacionais para a estimação do modelo proposto, assim como a formulação em programação matemática que o implementa. Também é apresentado o algoritmo de Monte Carlo para simulação de cenários e o procedimento para determinar os parâmetros de regularização. A metodologia é implementada nas linguagens R [R Development Core Team, 2008] e Julia [Bezanson et al., 2012], utilizando os pacotes JuMP [Dunning et al., 2017], Gurobi, RCall e Interpolations.

3.1. Estimação do modelo QRAL

O modelo QRAL, conforme descrito no problema (5)-(6), pode ser implementado conforme o problema de programação linear mostrado a seguir:

$$\min_{\beta_0,\beta,\varepsilon^+_{tj},\varepsilon^-_{tj}} \sum_{j\in J}\sum_{t\in T}(\alpha_j\varepsilon^+_{tj} + (1-\alpha_j)\varepsilon^-_{tj}) + \lambda\sum_{p\in P}\sum_{j\in J} w_{pj}(\xi^+_{pj}+\xi^-_{pj}) + \gamma\sum_{p\in P}\sum_{j\in J'}(D2^+_{pj}+D2^-_{pj}), \tag{7}$$

subject to:

$$\varepsilon^+_{tj} - \varepsilon^-_{tj} = y_t - \beta_{0j} - \beta_j^T x_t, \qquad \forall t\in T, \forall j\in J, \tag{8}$$

$$\xi^+_{pj} - \xi^-_{pj} = \beta_{pj}, \qquad \forall p\in P, \forall j\in J \tag{9}$$

$$D2^+_{pj} - D2^-_{pj} = \frac{\left(\frac{\beta_{p,j+1}-\beta_{pj}}{\alpha_{j+1}-\alpha_j}\right) - \left(\frac{\beta_{p,j}-\beta_{p,j-1}}{\alpha_j-\alpha_{j-1}}\right)}{\alpha_{j+1}-\alpha_{j-1}}, \qquad \forall p\in P, \forall j\in J', \tag{10}$$

$$\beta_{0j} + \beta_j^T x_t \leq \beta_{0,j+1} + \beta_{j+1}^T x_t, \qquad \forall t\in T, \forall j\in J_{(-1)}, \tag{11}$$

$$\varepsilon^+_{tj}, \varepsilon^-_{tj} \geq 0, \qquad \forall t\in T, \forall j\in J, \tag{12}$$

$$\xi^+_{pj}, \xi^-_{pj} \geq 0, \qquad \forall p\in P, \forall j\in J, \tag{13}$$

$$D2^+_{pj}, D2^-_{pj} \geq 0, \qquad \forall p\in P, \forall j\in J'. \tag{14}$$

As variáveis ε^+_t e ε^-_t representam as quantidades $|y-q(\cdot)|^+$ e $|y-q(\cdot)|^-$, respectivamente. A primeira linha da função objetivo em (7) representa a soma da função ρ para todo j, i.e., $\rho_{\alpha_j}(y - q(\cdot)) = \alpha_j\varepsilon^+_{tj} + (1-\alpha_j)\varepsilon^-_{tj}$. O valor absoluto da segunda diferença $D^2_{\alpha_j}\beta_{pj}$ é implementado no problema de otimização pela adição das variáveis auxiliares $D2^+_{pj} + D2^-_{pj}$. O parâmetro γ controla

https://proceedings.science/p/106671?lang=pt-br

o grau de suavidade que a sequência $\{\beta_{pj}\}_{j\in J}$ pode assumir, para um dado p. A soma $\xi^+_{pj} + \xi^-_{pj}$ representa o valor absoluto do coeficientes β_{pj}. O parâmetro λ controla a regularização destes coeficientes.

3.2. Geração de cenários através do método de Monte Carlo

Utiliza-se o método de Monte Carlo (MC) para produzir S cenários futuros $\{\hat{y}_{\tau,s}\}_{\tau=|T|+1}^{|T|+K}$ de tamanho K. O método consiste em primeiro estimar o modelo para um dado período τ e cenário s. Depois, para cada um dos vetores de input $x_{\tau,s}$, calcula-se a função discreta $\tilde{Q}_{y_\tau|X}$, que é um passo intermediário para a estimação da função quantílica contínua $\hat{Q}_{y_\tau|X}$. Este mesmo procedimento MC é empregado para simular cenários para todos os modelos baseados em RQ, incluindo o QRAL. Este procedimento é detalhado no Algoritmo 1.

Algorithm 1 Procedimento MC para simular S cenários K passos a frente

1. Estimar o modelo de RQ (para o QRAL, resolver o problema de otimização definido em (7)-(14)). A saída deste problema de otimização é um conjunto de coeficientes $\{\hat{\beta}_{0j}\}_{j\in J}$ e $\{\hat{\beta}_j\}_{j\in J}$, utilizando y_t e x_{pt} para $t = 1, \ldots, |T|$.
2. Inicializar o índice de tempo $\tau = |T| + 1$.
3. Para cada cenário $s \in S$, fazer:
   (a) Seja $x_{\tau,s} = [y_{\tau-1,s}, \ldots, y_{\tau-24,s}]$ o vetor de variáveis defasadas utilizados como entrada para prever prever a FDC no tempo τ e cenário s.
   (b) Seja $\tilde{Q}_{y_\tau|X} : A \times \mathbb{R}^d \to \mathbb{R}$ a função quantílica discreta. Seus valores são mapeados conforme os valores de quantis estimados $\tilde{Q}_{y_\tau|X}(\alpha_j, x_{\tau,s}) \leftarrow \hat{\beta}_{0j} + \hat{\beta}_j^T x_{\tau,s}$, para todo $j \in J$.
   (c) Para definir a função contínua $\hat{Q}_{y_\tau|X} : [0,1] \times \mathbb{R}^d \to \mathbb{R}$ de $\tilde{Q}_{y_\tau|X}$, utilizar interpolação linear para conectar os pontos. Como $0 < \alpha_1 < \cdots < \alpha_{|J|} < 1$, não há estimação para os quantis nos intervalos $[0, \alpha_1]$ e $[\alpha_{|J|}, 1]$. Esses vazios são preenchidos extrapolando linearmente as retas que conectam α_1 e α_2 no lado esquerdo e extendendo a reta que conecta $\alpha_{|J|-1}$ a $\alpha_{|J|}$ do lado direito, garantindo assim que todo a função esteja definida em todo o domínio $[0, 1]$.
   (d) Seja U a variável aleatória com distribuição uniforme no intervalo $[0, 1]$. Como $Q_{y_\tau}(U)$ possui a mesma distribuição que y_τ, tomando
   $$y_{\tau,s} \leftarrow \hat{Q}_{y_\tau|X}(u), \quad u \sim U[0,1],$$
   pode-se simular os próximos valores dos cenários.
4. Fazer $\tau = \tau + 1$. Se $\tau > K$, então parar. Caso contrário, volte para o passo 3).

3.3. Seleção de Modelos Baseada em Critério de Informação

Critérios de informação (IC) são o estado da arte em seleção de modelos para séries temporais. Eles também são empregados em outros trabalhos em que são estimados múltiplos quantis,

como Zou e Yuan [2008]; Jiang et al. [2014]. Um critério de informação sumariza duas características importantes para seleção de modelos: ajuste dentro da amostra e penalização da complexidade dada pelo tamanho do modelo. A expressão para o SIC é dada pela equação a seguir:

$$SIC_\theta = \sum_{j\in J}\left(\log\left(\sum_{t\in T}\rho_{\alpha_j}(y_t - \beta_{0j}^{\theta} - \beta_j^{T\theta}x_t)\right) + \frac{\log(|T|)|\epsilon_\theta|}{2|T|}\right), \tag{15}$$

onde $\theta = [\gamma \quad \lambda]^T$ e ϵ_θ é o "conjunto cotovelo", definido como $\epsilon_\theta = \{(t,j) : y_t - q_{\alpha_j}(x_t) = 0\}$. Os autores em Li e Zhu [2008] mostram que a quantidade $|\epsilon_\theta|$ representa os graus de liberdade efetivos na RQ.

3.4. Seleção de modelo baseado em qualidade do ajuste para cenários (QAC)

A maioria dos modelos estatísticos são desenvolvidos para possuir um bom desempenho em previsões pontuais, mas assumir estacionariedade faz com que rapidamente os cenários convirjam pra a média incondicional. As aplicações que utilizam cenários para a tomada de decisão exigem que eles reproduzam o comportamento já observado para a série. Para produzir cenários que vão ao encontro deste objetivo, é precise realizar a seleção de modelos levando em conta essa necessidade.

Uma nova métrica é proposta, em que cenários simulados são comparados com a média incondicional dos dados observados, produzindo assim cenários correlatados com a realidade. A versão apropriada do Erro Absoluto Médio (EAM) para regressão quantílica é definida por

$$EAM_\theta = \frac{1}{|J|}\frac{1}{12}\sum_{j\in J}\sum_{i=1}^{12}\left|q_i^{\alpha_j} - \hat{q}_i^{\alpha_j}\right|, \tag{16}$$

em que $q_t^{\alpha_j}$ é o α_j-quantil incondicional e $\hat{q}_t^{\alpha_j}$ o α_j-quantil previsto. Obtém-se $q_t^{\alpha_j}$ tomando o α_j-quantil dos valores históricos de um dado mês. O $\hat{q}_t^{\alpha_j}$ previsto é obtido tomando o α_j-quantil. A função EAM enfatiza a acurácia através dos quantis.

Considera-se o terceiro ano dos cenários como representante da série temporal incondicional, já que é um período longo o suficiente para não ter mais resquícios do curto prazo, mas não longo o suficiente para que os cenários percam as características de sazonalidade. Dado que os valores observados estão em $t \in \{1,\ldots,|T|\}$, o subconjunto dos cenários futuros será o intervalo $\{y_{|T|+25,s}, y_{|T|+26,s}, \ldots, y_{|T|+36,s}\}$. Os quantis estimados são comparados com os quantis históricos de cada mês. Por exemplo, avalia-se quão próximo está o quantil de 25% para todos os cenários simulados no mês de março (do terceiro ano) contra o quantil de 25% de todos os meses de março observados. Toma-se o EAM da diferença $\left|q_i^{\alpha_j} - \hat{q}_i^{\alpha_j}\right|$ para cada mês i e quantil j como medida de erro, conforme mostrado na equação (16).

A saída do problema (7)-(14) é o melhor modelo 1 passo à frente dados os parâmetros λ e γ. Assim, selecionando os parâmetros de acordo com cenários realistas, a qualidade do ajuste k passos à frente é feita levando em consideração cenários confiáveis tanto no curto quanto no longo prazo.

4. Estudo de Caso

O estudo de caso utiliza dados reais de geração da usina de Icaraizinho, no nordeste brasileiro. A série temporal é composta por 31 anos (1981 a 2011) de observações mensais de produção de energia eólica, em fator de capacidade, que varia de 0 a 100. A sazonalidade anual pode ser vista na Figura 1, onde os anos são exibidos como linhas empilhadas.

https://proceedings.science/p/106671?lang=pt-br

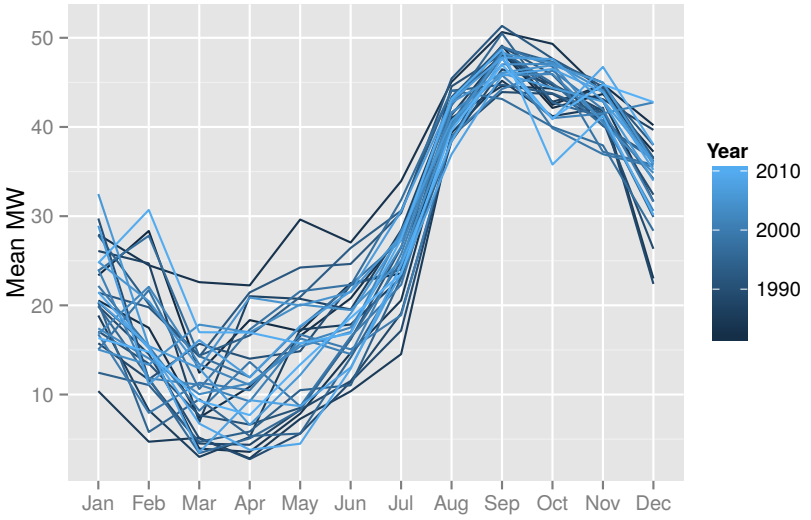


Figura 1: Dados anuais de Icaraizinho. Cada série consiste de observações mensais em um dado ano.

Utiliza-se quatro diferentes modelos para geração de cenários: QRAL, QRK (Regressão Quantílica conforme definido por Koenker), QRL (Quantile Regression LASSO, similar ao QRAL mas tendo $w_{ij} = 1$, para todo i e j) e SARIMA.

Para todos esses modelos, nenhuma variável exógena é utilizada como entrada. Portanto, apenas valores defasados são utilizados. Neste experimento, os parâmetros λ e γ do QRL e QRAL são selecionados de acordo com as duas métricas apresentadas na seção anterior: SIC e QAC.

Os coeficientes estimados para o QRAL e QRK são apresentados nas Figuras 2-3. Para

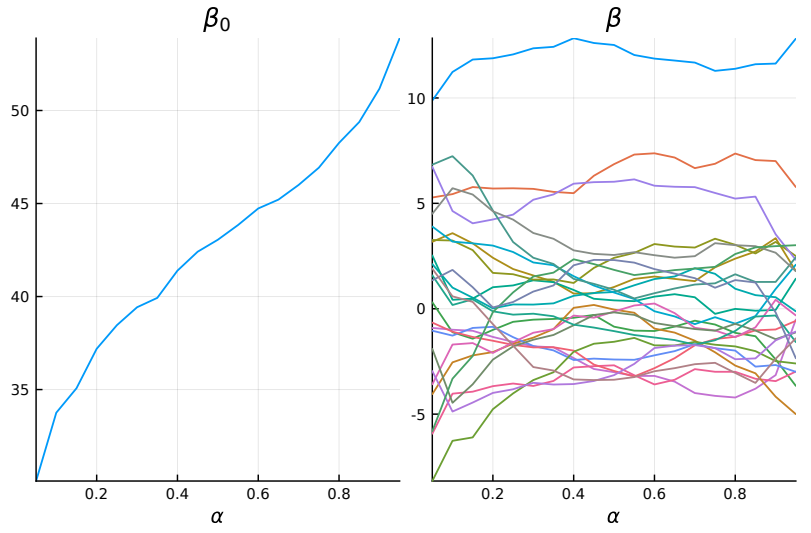


Figura 2: Coeficientes estimados para o modelo QRK.

cada um desses modelos, $\beta_0(\alpha)$ está mostrado no lado esquerdo da figura, enquanto $\beta(\alpha)$, para cada defasagem, está no lado direito. A principal diferença entre QRK e QRAL (via SIC) é que o último apresenta coeficientes β que possuem mais ruídos e possuem maior variabilidade entre quantis, já que no primeiro cada quantil é uma estimação completamente distinta da outra. O modelo proposto

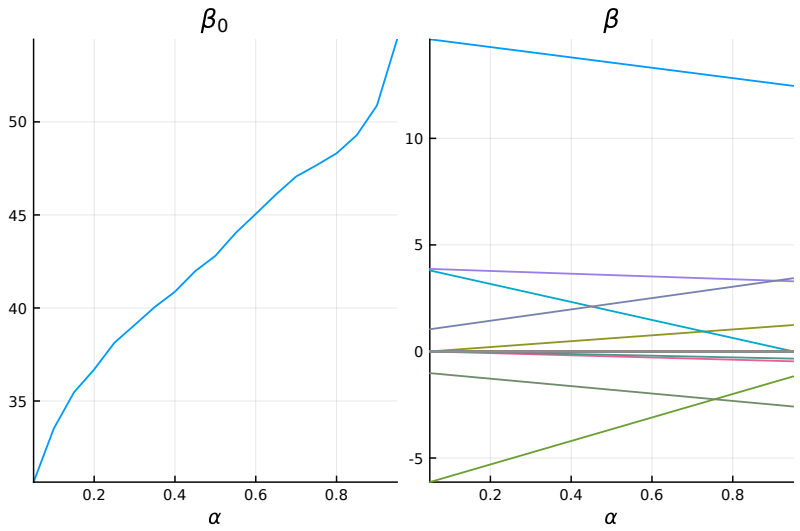


Figura 3: Coeficientes estimados para o modelo QRAL (utilizando seleção por QAC).

tem a vantagem de que múltiplos quantis são conjuntamente estimados num único modelo, ajudando a reduzir a variabilidade dos estimadores. A regularização na seleção de variáveis explicativas tem um papel mais importante quando os parâmetros são selecionados de acordo com a métrica QAC, quando menos coeficientes possuem valores maiores do que zero.

O modelo SARIMA é estimado com a utilização do pacote *forecast* [Hyndman e Khandakar, 2008] do R, através da função *auto.arima*, que seleciona o melhor modelo de acordo com um critério de informação (detalhes em [Hyndman et al., 2018]). O melhor modelo SARIMA estimado por esse procedimento foi o SARIMA $(2,0,2) \times (2,1,0)$ com drift e sazonalidade mensais.

Os parâmetros estimados segundo as métricas SIC e QAC são exibidos na tabela 1. Quando comparadas as performances do QRAL e QRL, percebe-se que para ambas as métricas o adaLASSO possui melhor performance. O QRAL regularizado por SIC é melhor que o QRK em ambas as métricas, mas gera cenários melhores que o SARIMA. Há um *tradeoff* entre ter um bom modelo no curto prazo (métrica SIC) e ter um bom modelo que produza cenários no longo prazo (métrica QAC). Quando escolhida a métrica QAC, que possui um melhor ajuste para gerar cenários, o modelo escolhido deve ser capaz de selecionar as variáveis de defasagem que contribuam com características importantes para o longo prazo. Por outro lado, quando o modelo é selecionado de acordo com a métrica SIC, mais variáveis são selecionadas para melhorar o ajuste no curto prazo. Com a seleção por QAC, os parâmetros de regularização ótimos são maiores do que aqueles obtidos via SIC.

Tabela 1: Estatísticas agregadas para todos os quantis α_j

Modelo (critério)	λ	γ	SIC	QAC
QRL (SIC)	0.75	0.8	12.18	5.43
QRAL (SIC)	0.25	0.8	12.15	5.41
QRL (QAC)	9.02	33.1	13.68	4.58
QRAL (QAC)	1.82	90.01	13.63	4.23
QRK (-)	0	0	13.00	5.92
SARIMA (-)	-	-	-	5.15

Por fim, nas Figures 4 e 5, computa-se a mediana (50%), quantis extremos (5% e 95%) e os primeiros e terceiros quartis (25% e 75%), obtidos por ambos modelos QRAL e SARIMA via simulação, com os quantis históricos associados. O período de simulação é o mesmo empregado na métrica QAC, que é o ano de 2014. Como pode ser observado pela comparação entre as figuras, os resultados do QRAL são melhores para capturar a sazonalidade incondicional do que aqueles produzidos pelo SARIMA, assim como possui quantis estimados mais próximos dos históricos.

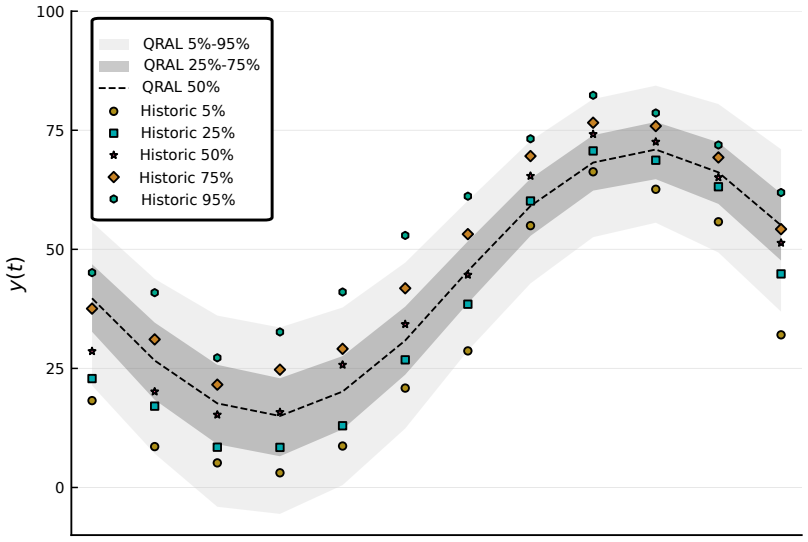


Figura 4: Comparação dos cenários incondicionais gerados (o terceiro ano de simulação) do QRAL (QAC) com os quantis históricos. As áreas escurecidas representam os quantis do QRAL ($5\% - 95\%$), enquanto os quantis históricos são marcados mensalmente por símbolos.

Resumindo, o QAC é uma boa métrica para forçar as simulações a produzir quantis similares aos históricos através de uma comparação direta dos dois valores. Selecionando os parâmetros de acordo com essa métrica, espera-se que as simulações reproduzam corretamente o comportamento sazonal. Essa regularidade é vista em diferentes tipos de séries de geração renovável, como vazão mensal e produção de energia solar mensal.

5. Conclusão

Neste trabalho, é proposto um modelo de séries temporais não paramétrico com função de distribuição condicional adaptativa. Este modelo é estimado através da estimação conjunta de quantis baseados em regressão quantílica. Há regularização através de dois termos: 1) um que seleciona as variáveis que entram no modelo através do encolhimento dos coeficientes e 2) um que força a ligação entre os quantis próximos com o objetivo de criar uma única estrutura de modelo de distribuição condicional. Foi desenvolvido um algoritmo que pode ser utilizado para gerar cenários sintéticos da produção de uma usina de geração eólica, mantendo propriedades relevantes da distribuição empírica e suas dinâmicas. Tais cenários podem ser entrada em inúmeras aplicações em sistemas de energia que dependam de cenários, como análise de risco em comercialização de energia, planejamento da expansão e problema do despacho, entre outros. Os resultados obtidos mostram que os cenários gerados através do modelo proposto possuem melhor performance do que os benchmarks escolhidos, como o modelo original de regressão quantílica do Koenker e o clássico modelo SARIMA. Além disso, o framework de estimação com base num problema de programação

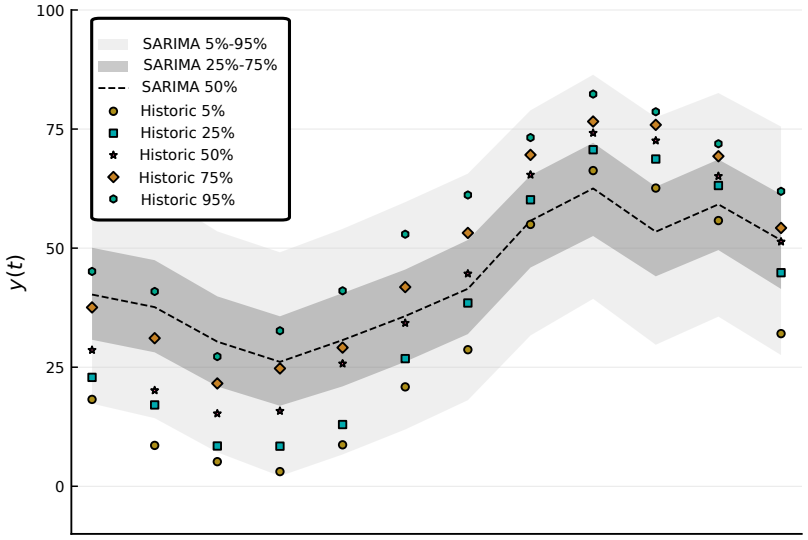


Figura 5: Comparação dos cenários incondicionais gerados (o terceiro ano de simulação) do SARIMA com os quantis históricos. As áreas escurecidas representam os quantis do SARIMA ($5\% - 95\%$), enquanto os quantis históricos são marcados mensalmente por símbolos.

linear é comum para diversos agentes do setor elétrico, sendo um ferramental de uso conveniente para os mesmos.

Referências

Belloni, A. e Chernozhukov, V. (2009). L1-Penalized Quantile Regression in High-Dimensional Sparse Models. *arXiv:0904.2931*. URL http://arxiv.org/abs/0904.2931.

Bessa, R. J., Miranda, V., Botterud, A., Wang, J., e Constantinescu, M. (2012). Time adaptive conditional kernel density estimation for wind power forecasting. *Sustainable Energy, IEEE Transactions on*, 3(4):660–669.

Bezanson, J., Karpinski, S., Shah, V. B., e Edelman, A. (2012). Julia: A fast dynamic language for technical computing. *arXiv preprint arXiv:1209.5145*.

Birge, J. R. e Louveaux, F. (2011). *Introduction to stochastic programming*. Springer Science & Business Media.

Bosch (1995). A convergent algorithm for quantile regression with smoothing splines - ScienceDirect. URL http://www.sciencedirect.com/science/article/pii/016794739400018E.

Bremnes, J. B. (2004). Probabilistic wind power forecasts using local quantile regression. *Wind Energy*, 7(1):47–54. ISSN 1099-1824. URL http://onlinelibrary.wiley.com/doi/10.1002/we.107/abstract.

Chao, S.-K., Härdle, W. K., e Wang, W. (2012). Quantile Regression in Risk Calibration. SSRN Scholarly Paper ID 2894219, Social Science Research Network, Rochester, NY. URL https://papers.ssrn.com/abstract=2894219.

Ciuperca, G. (2016). Adaptive LASSO model selection in a multiphase quantile regression. *Statistics*, 50(5):1100–1131. ISSN 0233-1888. URL http://dx.doi.org/10.1080/02331888.2016.1151427.

Dunning, I., Huchette, J., e Lubin, M. (2017). Jump: A modeling language for mathematical optimization. *SIAM Review*, 59(2):295–320.

Fanzeres, B., Street, A., e Barroso, L. A. (2015). Contracting strategies for renewable generators: A hybrid stochastic and robust optimization approach. *IEEE Transactions on Power Systems*, 30 (4):1825–1837. ISSN 0885-8950.

Gallego-Castillo, C., Bessa, R., Cavalcante, L., e Lopez-Garcia, O. (2016). On-line quantile regression in the rkhs (reproducing kernel hilbert space) for operational probabilistic forecasting of wind power. *Energy*, 113:355–365.

Hoeltgebaum, H., Fernandes, C., e Street, A. (2018). Generating joint scenarios for renewable generation: The case for non-gaussian models with time-varying parameters. *IEEE Transactions on Power Systems*, 33(6):7011–7019.

Hyndman, R., Athanasopoulos, G., Bergmeir, C., Caceres, G., Chhay, L., O'Hara-Wild, M., Petropoulos, F., Razbash, S., Wang, E., e Yasmeen, F. *forecast: Forecasting functions for time series and linear models*, 2018. URL http://pkg.robjhyndman.com/forecast.

Hyndman, R. J. e Khandakar, Y. (2008). Automatic time series forecasting: the forecast package for R. *Journal of Statistical Software*, 26(3):1–22. URL http://www.jstatsoft.org/article/view/v027i03.

Jeon, J. e Taylor, J. W. (2012). Using conditional kernel density estimation for wind power density forecasting. *Journal of the American Statistical Association*, 107(497):66–79.

Jiang, L., Bondell, H. D., e Wang, H. J. (2014). Interquantile shrinkage and variable selection in quantile regression. *Computational Statistics & Data Analysis*, 69:208–219. ISSN 0167-9473. URL http://www.sciencedirect.com/science/article/pii/S0167947313002922.

Kim, S.-J., Koh, K., Boyd, S., e Gorinevsky, D. (2009). ℓ_1 trend filtering. *SIAM review*, 51(2): 339–360.

Koenker, R. (2005). *Quantile regression*. Number 38. Cambridge university press.

Koenker, R. e Bassett Jr, G. (1978). Regression quantiles. *Econometrica: journal of the Econometric Society*, p. 33–50.

Li, Y., Liu, Y., e Zhu, J. (2007). Quantile Regression in Reproducing Kernel Hilbert Spaces. *Journal of the American Statistical Association*, 102(477):255–268. ISSN 0162-1459. URL http://www.jstor.org/stable/27639837.

Li, Y. e Zhu, J. (2008). L1-Norm Quantile Regression. *Journal of Computational and Graphical Statistics*, 17(1):163–185. ISSN 1061-8600. URL http://dx.doi.org/10.1198/106186008X289155.

Munoz, F. D. e Watson, J.-P. (2015). A scalable solution framework for stochastic transmission and generation planning problems. *Computational Management Science*, 12(4):491–518.

Møller, J. K., Nielsen, H. A., e Madsen, H. (2008). Time-adaptive quantile regression. *Computational Statistics & Data Analysis*, 52(3):1292–1303. ISSN 0167-9473. URL http://www.sciencedirect.com/science/article/pii/S0167947307002502.

Nielsen, H. A., Madsen, H., e Nielsen, T. S. (2006). Using quantile regression to extend an existing wind power forecasting system with probabilistic forecasts. *Wind Energy*, 9(1-2):95–108.

Papavasiliou, A. e Oren, S. S. (2013). Multiarea stochastic unit commitment for high wind penetration in a transmission constrained network. *Operations Research*, 61(3):578–592.

Papavasiliou, A., Oren, S. S., e Rountree, B. (2015). Applying high performance computing to transmission-constrained stochastic unit commitment for renewable energy integration. *IEEE Transactions on Power Systems*, 30(3):1109–1120.

Passos, A. C., Street, A., e Barroso, L. A. (2017). A dynamic real option-based investment model for renewable energy portfolios. *IEEE Transactions on Power Systems*, 32(2):883–895. ISSN 0885-8950.

Pinson, P., Madsen, H., Nielsen, H. A., Papaefthymiou, G., e Klöckl, B. (2009). From probabilistic forecasts to statistical scenarios of short-term wind power production. *Wind Energy*, 12(1):51–62. ISSN 1099-1824. URL http://onlinelibrary.wiley.com/doi/10.1002/we.284/abstract.

R Development Core Team. *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing, Vienna, Austria, 2008. URL http://www.R-project.org.

Saldarriaga-Cortés, C., Salazar, H., Moreno, R., e Jiménez-Estévez, G. (2019). Stochastic planning of electricity and gas networks: An asynchronous column generation approach. *Applied Energy*, 233-234:1065 – 1077. ISSN 0306-2619.

Taylor, J. W. e Jeon, J. (2015). Forecasting wind power quantiles using conditional kernel estimation. *Renewable Energy*, 80:370–379.

Tibshirani, R. (1996). Regression shrinkage and selection via the lasso. *Journal of the Royal Statistical Society. Series B (Methodological)*, p. 267–288.

Wan, C., Lin, J., Wang, J., Song, Y., e Dong, Z. Y. (2017). Direct Quantile Regression for Nonparametric Probabilistic Forecasting of Wind Power Generation. *IEEE Transactions on Power Systems*, 32(4):2767–2778. ISSN 0885-8950.

Zhang, Y., Wang, J., e Wang, X. (2014). Review on probabilistic forecasting of wind power generation. *Renewable and Sustainable Energy Reviews*, 32:255–270. ISSN 1364-0321. URL http://www.sciencedirect.com/science/article/pii/S1364032114000446.

Zou, H. e Yuan, M. (2008). Regularized simultaneous model selection in multiple quantiles regression. *Computational Statistics & Data Analysis*, 52(12):5296–5304. ISSN 0167-9473. URL http://www.sciencedirect.com/science/article/pii/S0167947308002739.

https://proceedings.science/p/106671?lang=pt-br