


# Webinar Fontes Renováveis Variáveis

Contribuições para modelagem das fontes renováveis variáveis no planejamento e operação do SIN



## Contribuição LAMPS PUC-Rio

*Prof. Alexandre Street (street@ele.puc-rio.br)*

*Prof. Cristiano Fernandes (cris@ele.puc-rio.br)*

*GT METODOLOGIA  
28/10/2020*

Coordenação: CCEE

Assessoria Técnica:



1. **Introdução**
2. Ideia geral sobre Score Driven Models
3. Teoria sobre Score driven models (GAS)
4. Aplicação a dados de geração eólica no Brasil
5. Caso multivariado
6. Ferramentas open source
7. Outros exemplos

# Operação de um sistema hidrotérmico

Cálculo do custo  
marginal de  
oportunidade do uso  
da água

(NEWAVE+DECOMP)



Planejamento da operação  
do dia seguinte (on-off)  
Unit commitment utilizando  
o valor da água

(DESSEM)






Operação em tempo real


(PÓS-DESSEM +  
ANAREDE, ORGANON,  
regras operativas)





## As eólicas surfam nos reservatórios das hidros



## As eólicas surfam nos reservatórios das hidros




Rampas de alta magnitude serão cada vez mais amplificadas à medida que expandimos via renováveis








## As eólicas surfam nos reservatórios das hidros

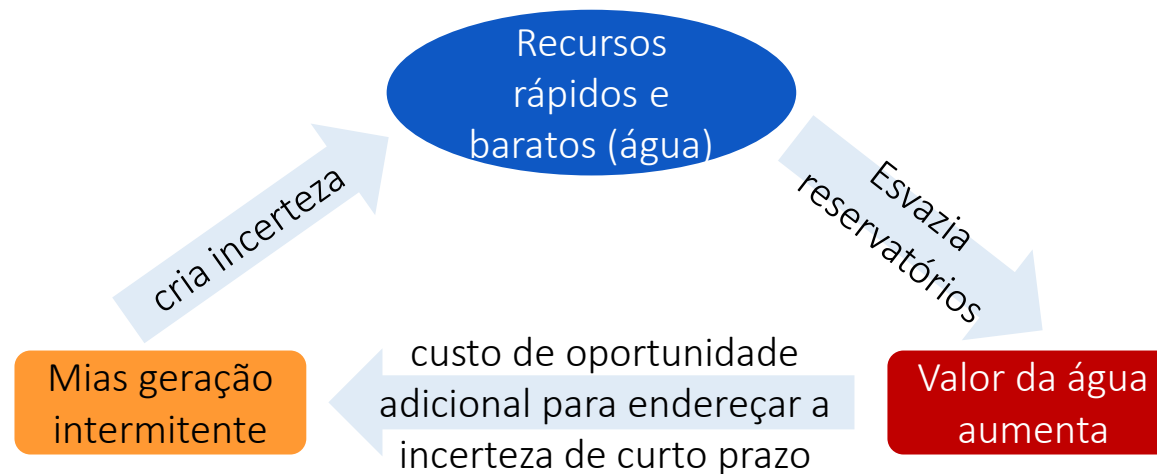


Rampas de alta magnitude serão cada vez mais amplificadas à medida que expandimos via renováveis



# A alta incerteza das renováveis intermitentes no curto prazo CRIA DESAFIOS PARA A GESTÃO DE LONGO PRAZO

- O cálculo do valor da água expressa o valor que cada hm3 terá para a operação futura
- Existe uma forte ligação (custo de oportunidade) entre a água armazenada e a capacidade de absorção das renováveis a custos baratos
- Dependendo do sistema, 1 MW de renovável intermitente pode ser bom ou ruim!



# O dilemma entre a simplificação e o viés otimista

Expectativas = Planejamento

Realidade = Operação real



Expectativas = Planejamento



$$g_{t,\omega}^{Plan} \leftarrow \arg \min_{g_t, y_t, f_t} c_t^T g_t + \beta Q_{t+1}^S(v_t)$$

Sujeito a:



$$A_t g_t + P_t u_t + C_t f_t = d_t$$

$$v_t + u_t + s_t = v_{t-1} + w_{t,\omega}$$

$$(u_t, s_t, g_t, f_t) \in \mathcal{X}_t^S$$

Realidade = Operação real

## Expectativas = Planejamento



$$\mathcal{P}(\{\mathcal{Q}_{t+1}^S\}_{t=1}^T, \{\mathcal{X}_t^S\}_{t=1}^T, \{w_{t,\omega}\}_{t,\omega=1}^{T,M}) \leftarrow \{g_{t,\omega}^{Plan}\}_{t,\omega=1}^{T,M}$$

$$g_{t,\omega}^{Plan} \leftarrow \arg \min_{g_t, y_t, f_t} c_t^T g_t + \beta \mathcal{Q}_{t+1}^S(v_t)$$

Sujeito a:



$$A_t g_t + P_t u_t + C_t f_t = d_t$$

$$v_t + u_t + s_t = v_{t-1} + w_{t,\omega}$$

$$(u_t, s_t, g_t, f_t) \in \mathcal{X}_t^S$$

## Realidade = Operação real

## Expectativas = Planejamento



$$\mathcal{P}(\{Q_{t+1}^S\}_{t=1}^T, \{x_t^S\}_{t=1}^T, \{w_{t,\omega}\}_{t,\omega=1}^{T,M}) \leftarrow \{g_{t,\omega}^{Plan}\}_{t,\omega=1}^{T,M}$$

$$g_{t,\omega}^{Plan} \leftarrow \arg \min_{g_t, y_t, f_t} c_t^T g_t + \beta Q_{t+1}^S(v_t)$$

Sujeito a:

$$A_t g_t + P_t u_t + C_t f_t = d_t$$

$$v_t + u_t + s_t = v_{t-1} + w_{t,\omega}$$

$$(u_t, s_t, g_t, f_t) \in x_t^S$$

## Realidade = Operação real



$$g_{t,\omega}^{Imp} \leftarrow \arg \min_{g_t, y_t, f_t} c_t^T g_t + \beta Q_{t+1}^S(v_t)$$


Sujeito a:

$$A_t g_t + P_t u_t + C_t f_t = d_t$$

$$v_t + u_t + s_t = v_{t-1} + w_{t,\omega}$$

$$(u_t, s_t, g_t, f_t) \in x_t^D$$

## Expectativas = Planejamento




$$\mathcal{P}(\{Q_{t+1}^S\}_{t=1}^T, \{x_t^S\}_{t=1}^T, \{w_{t,\omega}\}_{t,\omega=1}^{T,M}) \leftarrow \{g_{t,\omega}^{Plan}\}_{t,\omega=1}^{T,M}$$

$$g_{t,\omega}^{Plan} \leftarrow \arg \min_{g_t, y_t, f_t} c_t^T g_t + \beta Q_{t+1}^S(v_t)$$

Sujeito a:

$$\begin{aligned} A_t g_t + P_t u_t + C_t f_t &= d_t \\ v_t + u_t + s_t &= v_{t-1} + w_{t,\omega} \\ (u_t, s_t, g_t, f_t) &\in x_t^S \end{aligned}$$

## Realidade = Operação real



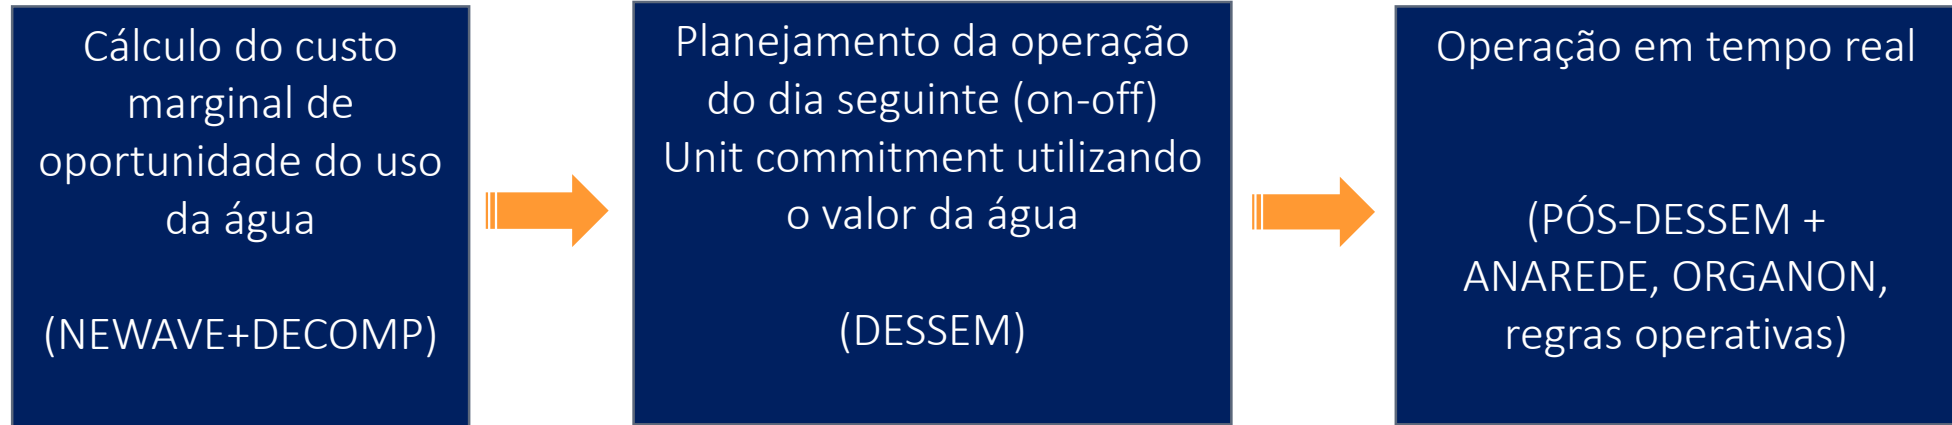
$$\mathcal{P}(\{Q_{t+1}^S\}_{t=1}^T, \{x_t^D\}_{t=1}^T, \{w_{t,\omega}\}_{t,\omega=1}^{T,M}) \leftarrow \{g_{t,\omega}^{Imp}\}_{t,\omega=1}^{T,M}$$

$$g_{t,\omega}^{Imp} \leftarrow \arg \min_{g_t, y_t, f_t} c_t^T g_t + \beta Q_{t+1}^S(v_t)$$

Sujeito a:

$$\begin{aligned} A_t g_t + P_t u_t + C_t f_t &= d_t \\ v_t + u_t + s_t &= v_{t-1} + w_{t,\omega} \\ (u_t, s_t, g_t, f_t) &\in x_t^D \end{aligned}$$

# Operação de um sistema hidrotérmico



# Operação de um sistema hidrotérmico

Cálculo do custo  
marginal de  
oportunidade do uso  
da água

(NEWAVE+DECOMP)



Planejamento da operação  
do dia seguinte (on-off)  
Unit commitment utilizando  
o valor da água

(DESSEM)



Operação em tempo real

(PÓS-DESSEM +  
ANAREDE, ORGANON,  
regras operativas)





# Operação de um sistema hidrotérmico

Cálculo do custo  
marginal de  
oportunidade do uso  
da água

(NEWAVE+DECOMP)



Planejamento da operação  
do dia seguinte (on-off)  
Unit commitment utilizando  
o valor da água

(DESSEM)



Operação em tempo real

(PÓS-DESSEM +  
ANAREDE, ORGANON,  
regras operativas)



# Operação de um sistema hidrotérmico

Cálculo do custo  
marginal de  
oportunidade do uso  
da água

(NEWAVE+DECOMP)



Planejamento da operação  
do dia seguinte (on-off)  
Unit commitment utilizando  
o valor da água

(DESSEM)



Operação em tempo real

(PÓS-DESSEM +  
ANAREDE, ORGANON,  
regras operativas)



# Inserção da geração eólica nos modelos de planejamento de longo prazo



- Precisa ser feito em três etapas:
  - **Primeira etapa:** simulação de longo prazo.
  - **Segunda etapa:** desagregação em escala horária (ou menor).
  - **Terceira etapa:** inclusão de efeitos climáticos de curto no curto e longo prazo, ciclos plurianuais, etc.

Nessa apresentação vamos abordar apenas a primeira etapa: **simulação de longo prazo.**



# Inserção da geração eólica nos modelos de planejamento de longo prazo



- Precisa ser feito em três etapas:
  - **Primeira etapa:** simulação de longo prazo.
  - **Segunda etapa:** desagregação em escala horária (ou menor).
  - **Terceira etapa:** inclusão de efeitos climáticos de curto no curto e longo prazo, ciclos plurianuais, etc.
- A inserção da variabilidade de renováveis precisa ser acompanhada com avanços no Newave e Decomp para considerar o efeito de restrições de curto prazo

Nessa apresentação vamos abordar apenas  
a primeira etapa: **simulação de longo prazo.**

# Inserção da geração eólica nos modelos de planejamento de longo prazo



- Precisa ser feito em três etapas:
  - **Primeira etapa:** simulação de longo prazo.
  - **Segunda etapa:** desagregação em escala horária (ou menor).
  - **Terceira etapa:** inclusão de efeitos climáticos de curto no curto e longo prazo, ciclos plurianuais, etc.
- A inserção da variabilidade de renováveis precisa ser acompanhada com avanços no Newave e Decomp para considerar o efeito de restrições de curto prazo
- O modelo precisa ser capaz de receber cenários exógenos e uma aproximação linear do valor esperado condicional um passo à frente: regressão nos cenários simulados

Nessa apresentação vamos abordar apenas

# Inserção da geração eólica nos modelos de planejamento de longo prazo



- Precisa ser feito em três etapas:
  - **Primeira etapa:** simulação de longo prazo.
  - **Segunda etapa:** desagregação em escala horária (ou menor).
  - **Terceira etapa:** inclusão de efeitos climáticos de curto no curto e longo prazo, ciclos plurianuais, etc.
- A inserção da variabilidade de renováveis precisa ser acompanhada com avanços no Newave e Decomp para considerar o efeito de restrições de curto prazo
- O modelo precisa ser capaz de receber cenários exógenos e uma aproximação linear do valor esperado condicional um passo à frente: regressão nos cenários simulados

P&D ANEEL PD-00405-1701/2017 (Grupo Energisa)

## Incorporando a Incerteza de Contingências e Variações Climáticas na Contratação Ótima dos Montantes de Uso (MUST/D) em Redes com Forte Inserção de Geração Distribuída Renovável

Alexandre Street, PUC-Rio, Erica Telles, PUC-Rio, Guilherme Bodin, PUC-Rio, Raphael Saavedra, PUC-Rio, Cristiano Fernandes, PUC-Rio, André Milhorange, PUC-Rio, Armando Leite, PUC-Rio.

*Resumo*—Este artigo propõe um novo *framework* metodológico para apoio à decisão de contratação ótima do MUST/D considerando as incertezas de carga, geração e contingências. Neste novo *framework*, incertezas antes não modeladas, como *drivers* de tendência de longo prazo e contingências com respectivas manobras, são consideradas na otimização dos contratos em conjunto com as incertezas típicas de carga e geração. O *framework* é dividido em quatro metodologias, cada uma apresentando pontos de inovação: 1) simulação de longo prazo das incertezas de carga e geração (neste módulo é onde a incerteza climática é capturada); 2) simulação das incertezas por barra e horas (uma nova tecnologia de modelagem dinâmica da curva de carga é proposta); 3) simulação do fluxo de potência probabilístico (as manobras operativas são automatizadas durante a simulação); 4) otimização dos contratos (consideramos o perfil de risco do acionista, o interesse dos consumidores e ampla flexibilidade contratual). Por fim, o impacto acadêmico e na indústria do projeto é ilustrado com resultados obtidos até a presente data.

*Palavras-chave*— Decisão ótima sob incerteza, fluxo de potência probabilístico, modelos em espaço de estados, regressão quantílica, variáveis climáticas.

sejam realizados de forma separada. Isso porque, essencialmente, ambos os processos buscam a melhor previsão do máximo valor que será exigido do sistema com o qual a distribuidora está conectada.

Idealmente, a demanda de cada distribuidora poderia ser prevista pelo operador ou planejador da rede. Contudo, é de se esperar que as distribuidoras tenham muito mais sucesso do que uma entidade única em prever suas próprias demandas. Bastaria apenas que essas tivessem os incentivos corretos para fornecerem sua melhor previsão. Dessa forma, o cálculo do MUST pode ser encarado como um processo de previsão descentralizado e baseado em incentivos econômicos. Existe uma banda de repasse (sem custos para o acionista) centrada no valor do MUST e penalidades para erros acima de 110% e abaixo de 90% desse valor. Tudo o que a distribuidora precisa fazer é posicionar o centro desse intervalo (valor do contrato de MUST) de forma a minimizar o custo esperado ajustado pelo perfil de risco do investidor em relação às penalidades que são incorridas quando a carga verificada fica fora desses limites. A acurácia dessa previsão é crucial para que o planejador

Nessa apresentação vamos abordar apenas



# Inserção da geração eólica nos modelos de planejamento de longo prazo



- Precisa ser feito em três etapas:
  - **Primeira etapa:** simulação de longo prazo.
  - **Segunda etapa:** desagregação em escala horária (ou menor).
  - **Terceira etapa:** inclusão de efeitos climáticos de curto no curto e longo prazo, ciclos plurianuais, etc.
- A inserção da variabilidade de renováveis precisa ser acompanhada com avanços no Newave e Decomp para considerar o efeito de restrições de curto prazo
- O modelo precisa ser capaz de receber cenários exógenos e uma aproximação linear do valor esperado condicional um passo à frente: regressão nos cenários simulados

P&D ANEEL PD-00405-1701/2017 (Grupo Energisa)

## Incorporando a Incerteza de Contingências e Variações Climáticas na Contratação Ótima dos Montantes de Uso (MUST/D) em Redes com Forte Inserção de Geração Distribuída Renovável

Alexandre Street, PUC-Rio, Erica Telles, PUC-Rio, Guilherme Bodin, PUC-Rio, Raphael Saavedra, PUC-Rio, Cristiano Fernandes, PUC-Rio, André Milhorange, PUC-Rio, Armando Leite, PUC-Rio.

*Resumo*—Este artigo propõe um novo *framework* metodológico para apoio à decisão de contratação ótima do MUST/D considerando as incertezas de carga, geração e contingências. Neste novo *framework*, incertezas antes não modeladas, como *drivers* de tendência de longo prazo e contingências com respectivas manobras, são consideradas na otimização dos contratos em conjunto com as incertezas típicas de carga e geração. O *framework* é dividido em quatro metodologias, cada uma apresentando pontos de inovação: 1) simulação de longo prazo das incertezas de carga e geração (neste módulo é onde a incerteza climática é capturada); 2) simulação das incertezas por barra e horas (uma nova tecnologia de modelagem dinâmica da curva de carga é proposta); 3) simulação do fluxo de potência probabilístico (as manobras operativas são automatizadas durante a simulação); 4) otimização dos contratos (consideramos o perfil de risco do acionista, o interesse dos consumidores e ampla flexibilidade contratual). Por fim, o impacto acadêmico e na indústria do projeto é ilustrado com resultados obtidos até a presente data.

*Palavras-chave*— Decisão ótima sob incerteza, fluxo de potência probabilístico, modelos em espaço de estados, regressão quantílica, variáveis climáticas.

sejam realizados de forma separada. Isso porque, essencialmente, ambos os processos buscam a melhor previsão do máximo valor que será exigido do sistema com o qual a distribuidora está conectada.

Idealmente, a demanda de cada distribuidora poderia ser prevista pelo operador ou planejador da rede. Contudo, é de se esperar que as distribuidoras tenham muito mais sucesso do que uma entidade única em prever suas próprias demandas. Bastaria apenas que essas tivessem os incentivos corretos para fornecerem sua melhor previsão. Dessa forma, o cálculo do MUST pode ser encarado como um processo de previsão descentralizado e baseado em incentivos econômicos. Existe uma banda de repasse (sem custos para o acionista) centrada no valor do MUST e penalidades para erros acima de 110% e abaixo de 90% desse valor. Tudo o que a distribuidora precisa fazer é posicionar o centro desse intervalo (valor do contrato de MUST) de forma a minimizar o custo esperado ajustado pelo perfil de risco do investidor em relação às penalidades que são incorridas quando a carga verificada fica fora desses limites. A acurácia dessa previsão é crucial para que o planejador

Nessa apresentação vamos abordar apenas a primeira etapa: **simulação de longo prazo.**

1. Introdução
2. **Ideia geral sobre Score Driven Models**
3. Teoria sobre Score driven models (GAS)
4. Aplicação a dados de geração eólica no Brasil
5. Caso multivariado
6. Ferramentas open source
7. Outros exemplos

# Score Driven Models or Generalized Autoregressive Score (GAS) Models

- ❑ **Score driven models**, também conhecidos com **GAS** (*Generalized Autoregressive Score*; Creal, Koopman & Lucas (2013)) ou **DCS** (*Dynamic Conditional Score*; Harvey (2013)) é um arcabouço geral e flexível para a construção de modelos para séries temporais, possibilitando:
  - ✓ distribuições discretas (Poisson, Bernoulli etc) , contínuas (T Student, Gama, Beta, Weibull etc) ou mistas;
  - ✓ distribuições multivariadas (Gaussiana, T Student, Poisson etc);
  - ✓ alguns ou todos os parâmetros da distribuição podem variar (condicionalmente) no tempo;
  - ✓ a equação de atualização dos parâmetros pode seguir:
    - mecanismo ARMA
    - componentes não observáveis (CNO)
    - misto de ARMA e CNO

# Score Driven Models or Generalized Autoregressive Score (GAS) Models



❑ Estimação dos parâmetros fixos do modelo (hiperparâmetros):

- parâmetros fixos da distribuição;
- parâmetros fixos do mecanismo de atualização dos parâmetros variantes no tempo,

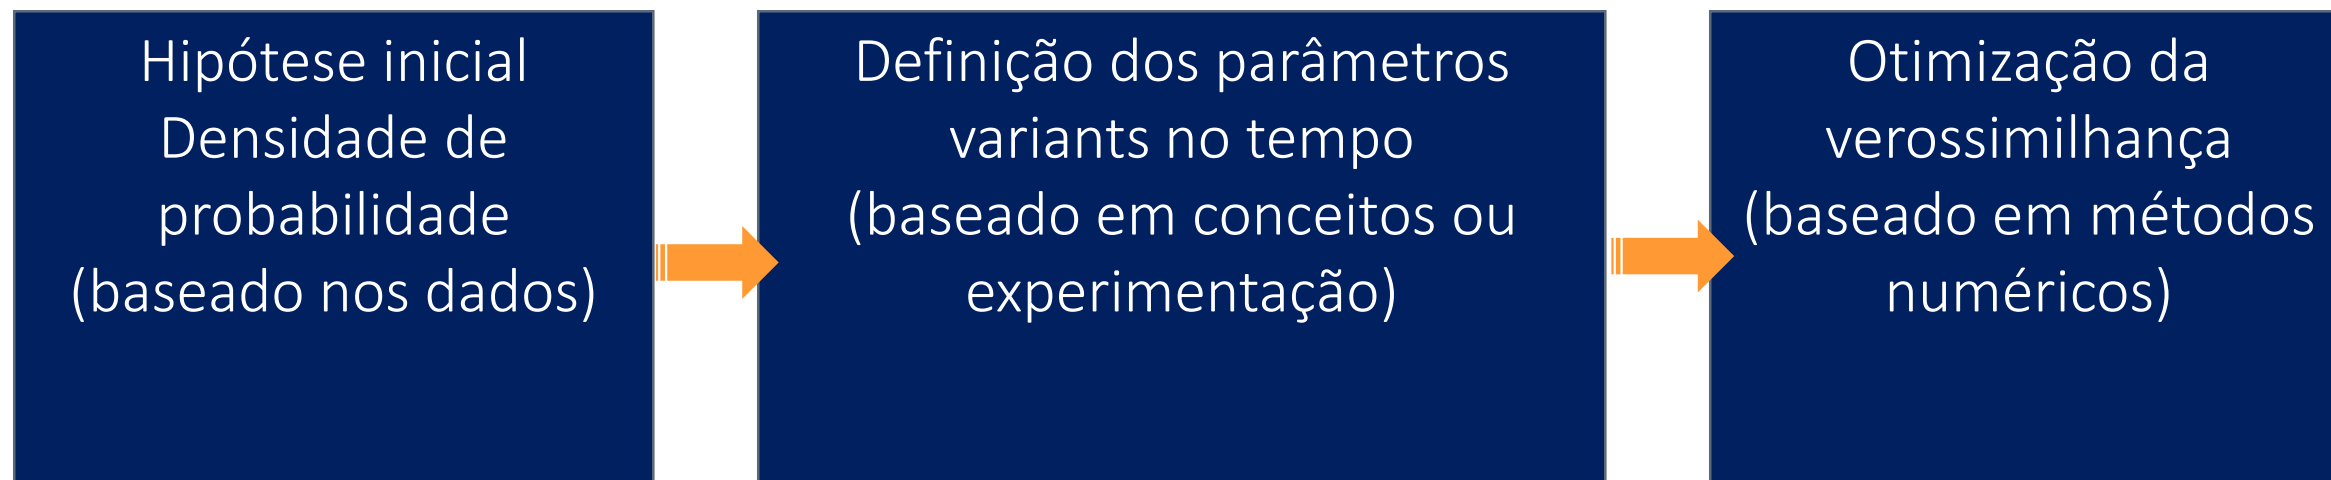
é realizado pela maximização da verossimilhança.

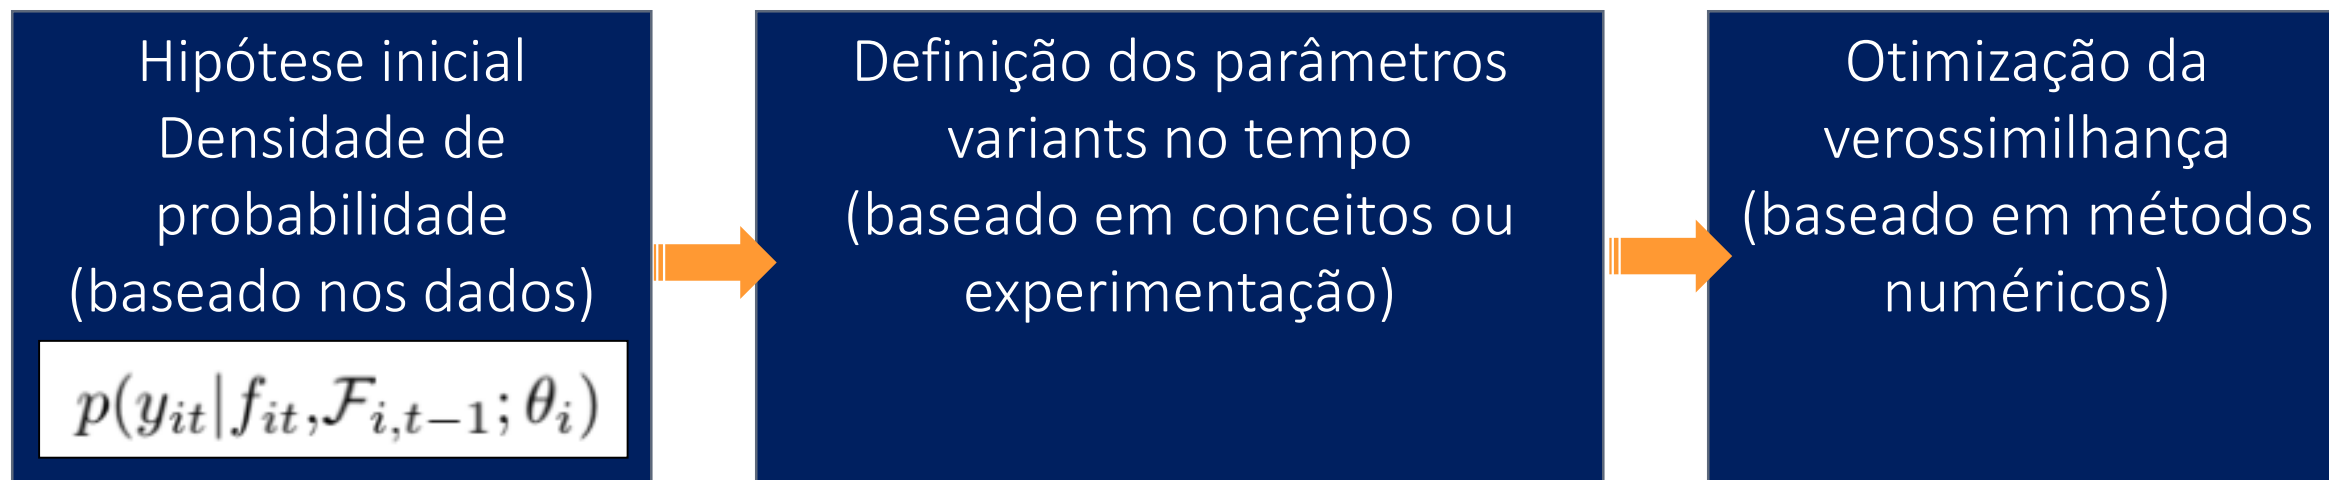
❑ Distribuição  $k$  passos à frente ( $k > 1$ ) e momentos, quantis e intervalos de confiança podem ser obtidos por simulação de Monte Carlo.

❑ Incerteza na estimação dos hiperparâmetros pode ser incorporada à distribuição  $k$ -passos à frente.

❑ Diagnósticos dos modelos podem ser realizados via resíduos de Pearson e/ou resíduos quantílicos.

❑ Possibilidade de tratamento de valores faltantes.







Hipótese inicial  
Densidade de  
probabilidade  
(baseado nos dados)

$$p(y_{it}|f_{it}, \mathcal{F}_{i,t-1}; \theta_i)$$



Definição dos parâmetros  
variants no tempo  
(baseado em conceitos ou  
experimentação)

$$f_{i,t+1} = \omega_i + \sum_{l=1}^p A_{i,l} s_{i,t-l+1} + \sum_{l=1}^q B_{i,l} f_{i,t-l+1}$$



Otimização da  
verossimilhança  
(baseado em métodos  
numéricos)

Hipótese inicial  
Densidade de  
probabilidade  
(baseado nos dados)

$$p(y_{it}|f_{it}, \mathcal{F}_{i,t-1}; \theta_i)$$



Definição dos parâmetros  
variants no tempo  
(baseado em conceitos ou  
experimentação)

$$f_{i,t+1} = \omega_i + \sum_{l=1}^p A_{i,l} s_{i,t-l+1} + \sum_{l=1}^q B_{i,l} f_{i,t-l+1}$$



Otimização da  
verossimilhança  
(baseado em métodos  
numéricos)

$$\hat{\theta}_i = \operatorname{argmax}_{\theta_i} l_i(\theta_i)$$

1. Introdução
2. Ideia geral sobre Score Driven Models
3. **Teoria sobre Score driven models (GAS)**
4. Aplicação a dados de geração eólica no Brasil
5. Caso multivariado
6. Ferramentas open source
7. Outros exemplos

## Generating Joint Scenarios for Renewable Generation: The Case for non-Gaussian Models with Time-Varying Parameters

Henrique Hoeltgebaum, Cristiano Fernandes, Alexandre Street, *Senior Member, IEEE*

**Abstract**—The development of medium/long-term studies for power-system operation and planning under the uncertainty of renewable generation is a key challenge faced by power-system agents worldwide. There is a vast literature on stochastic optimization models devoted to addressing the relevant issues on both operation and planning applications. Notwithstanding, few papers focus on addressing the gaps within the subject of joint scenario generation despite the high sensibility of stochastic optimization models with regard to their input scenarios. Characterizing wind power generation (WPG) stochastic processes to devise time- and spatial-dependent scenarios, based on simulation procedures, for time horizons of one to a few years is a difficult task. Multiple regimes and non-Gaussian distributions are two of the main issues that significantly change the risk described through generated scenarios. In this paper, a new methodology to simulate long-term joint scenarios for multivariate WPG time series is presented. The proposed framework, known as Generalized Auto Regressive Score (GAS) models, is derived based on a new class of time-series model with time-varying parameters and an arbitrary non-Gaussian distribution. Our case study shows, based on real data from the Brazilian power system, that the proposed methodology is capable of producing scenarios with coherent temporal and spatial dependence that are needed in power system studies.

**Index Terms**—Dynamic copula, probabilistic forecasting, score-driven models, time-varying parameters, wind power.

grid expansion planning, and (iv) investment decisions (see [2]–[5] and references therein). There is a vast literature on stochastic optimization models devoted to addressing the relevant issues on the aforementioned power-system applications. Notwithstanding, few papers focus on addressing the gaps within the subject of joint scenario generation despite the high sensibility of the stochastic optimization models with regard to their input scenarios.

For example, [6] and [7] use importance sampling to model tail dependencies under a reduced number of scenarios for stochastic unit commitment and transmission planning, respectively. While in [6] a transformed wind speed time series is modeled by an autoregressive process to generate wind power scenarios, in [7], an interesting clusterization method is applied to historical data to capture empirical information of the wind power variability. Furthermore, [8] focus on two-stage transmission planning using a sample of hourly data to empirically characterize the correlations in demand and wind power generation among different regions. Within the subject of two-stage robust optimization models applied to planning and operation, in [2] a robust model is proposed to address reliability in co-optimized generation and transmission planning, while in [9] a unit commitment problem is addressed

- In this study,  $\beta_{it}$  is considered as a time-varying parameter
- We assume:  $\beta_{i,t} = e^{\phi_i' X_{i,t} + f_{i,t}}$ .
- The rest are fixed parameters

- In this study,  $\beta_{it}$  is considered as a time-varying parameter
- We assume:  $\beta_{i,t} = e^{\phi'_i X_{i,t} + f_{i,t}}$ .
- The rest are fixed parameters

$$\begin{aligned} p(y_{it}|f_{it}, \mathcal{F}_{i,t-1}; \theta_i) \\ = \frac{\Gamma(\beta_{it} + \alpha_i)}{\Gamma(\beta_{it})\Gamma(\alpha_i)} \cdot \frac{(y_{it} - a_{it})^{\beta_{it}-1} (b_{it} - y_{it})^{\alpha_i-1}}{(b_i - a_{it})^{\beta_{it}+\alpha_i-1}} \quad (1) \end{aligned}$$



- In this study,  $\beta_{it}$  is considered as a time-varying parameter
- We assume:  $\beta_{i,t} = e^{\phi'_i X_{i,t} + f_{i,t}}$ .
- The rest are fixed parameters

$$p(y_{it}|f_{it}, \mathcal{F}_{i,t-1}; \theta_i) = \frac{\Gamma(\beta_{it} + \alpha_i)}{\Gamma(\beta_{it})\Gamma(\alpha_i)} \cdot \frac{(y_{it} - a_{it})^{\beta_{it}-1} (b_{it} - y_{it})^{\alpha_i-1}}{(b_{it} - a_{it})^{\beta_{it}+\alpha_i-1}} \quad (1)$$

The time-varying parameter GAS( $p, q$ ) updating mechanism for parameter  $f_{it}$ ,  $\forall i \in \mathcal{K}$  and  $t \in T$ , is given by

$$f_{i,t+1} = \omega_i + \sum_{l=1}^p A_{i,l} s_{i,t-l+1} + \sum_{l=1}^q B_{i,l} f_{i,t-l+1}. \quad (2)$$

- In this study,  $\beta_{it}$  is considered as a time-varying parameter
- We assume:  $\beta_{i,t} = e^{\phi'_i X_{i,t} + f_{i,t}}$ .
- The rest are fixed parameters

$$s_{i,t} = \mathcal{I}_{i,t|t-1}^{-d} \cdot \nabla_{i,t}, \quad (3)$$

$$\nabla_{i,t} = \frac{\partial \ln p(y_{i,t} | f_{i,t}, \mathcal{F}_{i,t-1}; \theta_i)}{\partial f_{i,t}}, \quad (4)$$

$$\mathcal{I}_{i,t|t-1} = E_{t|t-1}[\nabla'_{i,t} \nabla_{i,t}] \quad (5)$$

$$\begin{aligned} p(y_{it} | f_{it}, \mathcal{F}_{i,t-1}; \theta_i) \\ = \frac{\Gamma(\beta_{it} + \alpha_i)}{\Gamma(\beta_{it})\Gamma(\alpha_i)} \cdot \frac{(y_{it} - a_{it})^{\beta_{it}-1} (b_{it} - y_{it})^{\alpha_i-1}}{(b_{it} - a_{it})^{\beta_{it}+\alpha_i-1}} \end{aligned} \quad (1)$$

The time-varying parameter GAS( $p, q$ ) updating mechanism for parameter  $f_{it}$ ,  $\forall i \in \mathcal{K}$  and  $t \in T$ , is given by

$$f_{i,t+1} = \omega_i + \sum_{l=1}^p A_{i,l} s_{i,t-l+1} + \sum_{l=1}^q B_{i,l} f_{i,t-l+1}. \quad (2)$$

- In this study,  $\beta_{it}$  is considered as a time-varying parameter
- We assume:  $\beta_{i,t} = e^{\phi'_i X_{i,t} + f_{i,t}}$ .
- The rest are fixed parameters

$$p(y_{it}|f_{it}, \mathcal{F}_{i,t-1}; \theta_i) = \frac{\Gamma(\beta_{it} + \alpha_i)}{\Gamma(\beta_{it})\Gamma(\alpha_i)} \cdot \frac{(y_{it} - a_{it})^{\beta_{it}-1} (b_{it} - y_{it})^{\alpha_i-1}}{(b_{it} - a_{it})^{\beta_{it}+\alpha_i-1}} \quad (1)$$

The time-varying parameter GAS( $p, q$ ) updating mechanism for parameter  $f_{it}$ ,  $\forall i \in \mathcal{K}$  and  $t \in T$ , is given by

$$f_{i,t+1} = \omega_i + \sum_{l=1}^p A_{i,l} s_{i,t-l+1} + \sum_{l=1}^q B_{i,l} f_{i,t-l+1}. \quad (2)$$

$$s_{i,t} = \mathcal{I}_{i,t|t-1}^{-d} \cdot \nabla_{i,t}, \quad (3)$$

$$\nabla_{i,t} = \frac{\partial \ln p(y_{i,t}|f_{i,t}, \mathcal{F}_{i,t-1}; \theta_i)}{\partial f_{i,t}}, \quad (4)$$

$$\mathcal{I}_{i,t|t-1} = E_{t|t-1}[\nabla'_{i,t} \nabla_{i,t}] \quad (5)$$

$$\hat{\theta}_i = \underset{\theta_i}{\operatorname{argmax}} l_i(\theta_i). \quad (7)$$

- In this study,  $\beta_{it}$  is considered as a time-varying parameter
- We assume:  $\beta_{i,t} = e^{\phi'_i X_{i,t} + f_{i,t}}$ .
- The rest are fixed parameters

$$p(y_{it}|f_{it}, \mathcal{F}_{i,t-1}; \theta_i) = \frac{\Gamma(\beta_{it} + \alpha_i)}{\Gamma(\beta_{it})\Gamma(\alpha_i)} \cdot \frac{(y_{it} - a_{it})^{\beta_{it}-1} (b_{it} - y_{it})^{\alpha_i-1}}{(b_{it} - a_{it})^{\beta_{it}+\alpha_i-1}} \quad (1)$$

The time-varying parameter GAS( $p, q$ ) updating mechanism for parameter  $f_{it}$ ,  $\forall i \in \mathcal{K}$  and  $t \in T$ , is given by

$$f_{i,t+1} = \omega_i + \sum_{l=1}^p A_{i,l} s_{i,t-l+1} + \sum_{l=1}^q B_{i,l} f_{i,t-l+1}. \quad (2)$$

$$s_{i,t} = \mathcal{I}_{i,t|t-1}^{-d} \cdot \nabla_{i,t}, \quad (3)$$



$$\nabla_{i,t} = \frac{\partial \ln p(y_{i,t}|f_{i,t}, \mathcal{F}_{i,t-1}; \theta_i)}{\partial f_{i,t}}, \quad (4)$$

$$\mathcal{I}_{i,t|t-1} = E_{t|t-1}[\nabla'_{i,t} \nabla_{i,t}] \quad (5)$$

$$\hat{\theta}_i = \underset{\theta_i}{\operatorname{argmax}} l_i(\theta_i). \quad (7)$$

$$l_i(\theta_i) = \sum_{t=1}^T \left\{ -\ln(b_{it} - a_{it})(\beta_{it} + \alpha_i - 1) + \ln \Gamma(\beta_{it} + \alpha_i) - \ln \Gamma(\beta_{it}) - \ln \Gamma(\alpha_i) + \beta_{it} \ln(y_{it} - a_{it}) - \ln(y_{it} - a_{it}) + \alpha_{it}(b_{it} - y_{it}) - \ln(b_{it} - y_{it}) \right\}. \quad (8)$$

1. Introdução
2. Ideia geral sobre Score Driven Models
3. Teoria sobre Score driven models (GAS)
4. **Aplicação a dados de geração eólica no Brasil**
5. Caso multivariado
6. Ferramentas open source
7. Outros exemplos



- Rio do Fogo (RF), Icaraizinho (IC), and Enacel (EN)

TABLE II  
P VALUES OF STANDARD DIAGNOSTIC TESTS.

Test	RF	IC	EN
Normality	0.731	0.272	0.075
Autocorrelation	0.604	0.836	0.641
ARCH effect	0.477	0.145	0.390

TABLE III  
FORECASTING EVALUATION BETWEEN BETA GAS(12,12) AND SARIMA  
MODELS 36 MONTHS AHEAD.

Model	Fit	RF	IC	EN
beta GAS(12,12)	RMSE	6.438	8.976	8.789
	MAE	5.527	7.573	7.358
	Pseudo R <sup>2</sup>	0.676	0.856	0.773
SARIMA	RMSE	8.473	10.391	11.746
	MAE	6.850	9.059	10.218
	Pseudo R <sup>2</sup>	0.460	0.812	0.677



1. Introdução
2. Ideia geral sobre Score Driven Models
3. Teoria sobre Score driven models (GAS)
4. Aplicação a dados de geração eólica no Brasil
5. **Caso multivariado**
6. Ferramentas open source
7. Outros exemplos

- Copula with time-varying correlation

- Copula with time-varying correlation

$$u_{i,t} = F(y_{i,t} | f_{i,t}, \mathcal{F}_{i,t-1}, \hat{\theta}_i).$$

- Copula with time-varying correlation

$$u_{i,t} = F(y_{i,t} | f_{i,t}, \mathcal{F}_{i,t-1}, \hat{\theta}_i).$$

$$g(\tilde{\mathbf{y}}_t | \Sigma_t; \nu) = \frac{\Gamma\left(\frac{\nu+K}{2}\right)}{\Gamma\left(\frac{\nu}{2}\right) [(\nu-2)\pi]^{K/2} |\Sigma_t|^{1/2}} \cdot \left[ 1 + \frac{\tilde{\mathbf{y}}_t' \Sigma_t^{-1} \tilde{\mathbf{y}}_t}{(\nu-2)} \right]^{-\frac{\nu+K}{2}}$$

- Copula with time-varying correlation

$$u_{i,t} = F(y_{i,t} | f_{i,t}, \mathcal{F}_{i,t-1}, \hat{\theta}_i).$$

$$g(\tilde{\mathbf{y}}_t | \Sigma_t; \nu) = \frac{\Gamma\left(\frac{\nu+K}{2}\right)}{\Gamma\left(\frac{\nu}{2}\right) [(\nu-2)\pi]^{K/2} |\Sigma_t|^{1/2}} \cdot \left[ 1 + \frac{\tilde{\mathbf{y}}_t' \Sigma_t^{-1} \tilde{\mathbf{y}}_t}{(\nu-2)} \right]^{-\frac{\nu+K}{2}}$$

$$\Sigma_t = \text{diag}(Q_t)^{-1/2} \cdot Q_t \cdot \text{diag}(Q_t)^{-1/2}$$

- Copula with time-varying correlation

$$u_{i,t} = F(y_{i,t} | f_{i,t}, \mathcal{F}_{i,t-1}, \hat{\theta}_i).$$

$$g(\tilde{\mathbf{y}}_t | \Sigma_t; \nu) = \frac{\Gamma\left(\frac{\nu+K}{2}\right)}{\Gamma\left(\frac{\nu}{2}\right) [(\nu-2)\pi]^{K/2} |\Sigma_t|^{1/2}} \cdot \left[ 1 + \frac{\tilde{\mathbf{y}}_t' \Sigma_t^{-1} \tilde{\mathbf{y}}_t}{(\nu-2)} \right]^{-\frac{\nu+K}{2}}$$

$$\Sigma_t = \text{diag}(Q_t)^{-1/2} \cdot Q_t \cdot \text{diag}(Q_t)^{-1/2}$$

$$\text{vech}(Q_{t+1}) = \Omega + \Pi s_t + \Upsilon \text{vech}(Q_t)$$




- Copula with time-varying correlation

$$u_{i,t} = F(y_{i,t} | f_{i,t}, \mathcal{F}_{i,t-1}, \hat{\theta}_i).$$

$$g(\tilde{\mathbf{y}}_t | \Sigma_t; \nu) = \frac{\Gamma\left(\frac{\nu+K}{2}\right)}{\Gamma\left(\frac{\nu}{2}\right) [(\nu-2)\pi]^{K/2} |\Sigma_t|^{1/2}} \cdot \left[1 + \frac{\tilde{\mathbf{y}}_t' \Sigma_t^{-1} \tilde{\mathbf{y}}_t}{(\nu-2)}\right]^{-\frac{\nu+K}{2}}$$

$$\Sigma_t = \text{diag}(Q_t)^{-1/2} \cdot Q_t \cdot \text{diag}(Q_t)^{-1/2}$$

$$\text{vech}(Q_{t+1}) = \Omega + \Pi s_t + \Upsilon \text{vech}(Q_t)$$



- Copula with time-varying correlation

TABLE IV  
MAXIMUM LIKELIHOOD ESTIMATION OF THE SECOND-STEP GAS MODEL  
APPLIED TO THE PIT VARIABLES OF THREE BRAZILIAN WIND PLANTS.

Parameter	t-GAS		
	Estimate	S.E.	p-value
$\Omega$	1.674	0.356	<0.001
$\Pi$	0.143	0.005	<0.001
$\Upsilon$	0.994	0.001	<0.001

TABLE V  
MEAN ABSOLUTE ERRORS.

$\alpha$	GAS			SARIMA		
	RF	EN	IC	RF	EN	IC
5%	0.1020	0.1163	0.1471	0.2417	0.3788	0.4030
25%	0.0877	0.1220	0.1860	0.1338	0.3740	0.2263
50%	0.0615	0.0509	0.1005	0.0995	0.2388	0.1692
75%	0.0346	0.0518	0.0523	0.0867	0.1826	0.1136
95%	0.0317	0.0296	0.0466	0.1140	0.1534	0.1583

1. Introdução
2. Ideia geral sobre Score Driven Models
3. Teoria sobre Score driven models (GAS)
4. Aplicação a dados de geração eólica no Brasil
5. Caso multivariado
6. **Ferramentas open source**
7. Outros exemplos



- ❑ O LAMPS criou o ScoreDrivenModels.jl: open source, onde podem ser estimadas e simuladas séries temporais com diversas distribuições: <https://github.com/LAMPSPUC/ScoreDrivenModels.jl>
- ❑ O artigo <https://arxiv.org/pdf/2008.05506.pdf> explica toda a metodologia e o uso do pacote ScoreDrivenModels.jl

- ❑ O LAMPS criou o ScoreDrivenModels.jl: open source, onde podem ser estimadas e simuladas séries temporais com diversas distribuições: <https://github.com/LAMPSPUC/ScoreDrivenModels.jl>
- ❑ O artigo <https://arxiv.org/pdf/2008.05506.pdf> explica toda a metodologia e o uso do pacote ScoreDrivenModels.jl

Distribution	Number of parameters	Identity scaling	Inverse scaling	Inverse square-root scaling
Beta	2	✓	✓	✓
BetaLocationScale	4	✓	—	—
Exponential	1	✓	✓	✓
Gamma	2	✓	✓	✓
LogitNormal	2	✓	✓	✓
LogNormal	2	✓	✓	✓
NegativeBinomial	2	✓	—	—
Normal	2	✓	✓	✓
Poisson	1	✓	✓	✓
TDist	1	✓	✓	✓
TDistLocationScale	3	✓	✓	✓
Weibull	2	✓	—	—



- ❑ O LAMPS criou o ScoreDrivenModels.jl: open source, onde podem ser estimadas e simuladas séries temporais com diversas distribuições: <https://github.com/LAMPSPUC/ScoreDrivenModels.jl>
- ❑ O artigo <https://arxiv.org/pdf/2008.05506.pdf> explica toda a metodologia e o uso do pacote ScoreDrivenModels.jl

Distribution	Number of parameters	Identity scaling	Inverse scaling	Inverse square-root scaling
Beta	2	✓	✓	✓
BetaLocationScale	4	✓	—	—
Exponential	1	✓	✓	✓
Gamma	2	✓	✓	✓
LogitNormal	2	✓	✓	✓
LogNormal	2	✓	✓	✓
NegativeBinomial	2	✓	—	—
Normal	2	✓	✓	✓
Poisson	1	✓	✓	✓
TDist	1	✓	✓	✓
TDistLocationScale	3	✓	✓	✓
Weibull	2	✓	—	—




Figure 3: ANE scenarios in the Northeastern region of Brazil

- ❑ A possibilidade de especificação de modelos não Gaussianos torna o arcabouço particularmente atraente na indústria de energia pois os modelos respeitam o suporte das variáveis (não necessidade de tomar o log):

- ❑ A possibilidade de especificação de modelos não Gaussianos torna o arcabouço particularmente atraente na indústria de energia pois os modelos respeitam o suporte das variáveis (não necessidade de tomar o log):

Variável	Suporte	Distribuições adequadas
Veloc. vento (m/s)	$[0, 100)$	log normal, Weibull, gama
Fator de capacidade	$[0, a), a < 1$	Beta
Vazão ( $m^3/s$ )	$[0, b)$	log normal, Weibull, gama
Carga (GWh)	$(0, c)$	normal, log normal
variáveis contínuas com zeros: vento diário, precipitação diária etc	0 = não ocorre; 1 = ocorre e $\epsilon > 0$	distribuições mistas envolvendo Bernoulli e gama

1. Introdução
2. Ideia geral sobre Score Driven Models
3. Teoria sobre Score driven models (GAS)
4. Aplicação a dados de geração eólica no Brasil
5. Caso multivariado
6. Ferramentas open source
7. Outros exemplos

- ❑ **Ilustração:** modelo Gama-Beta bivariado para séries mensais de fator de capacidade de usina eólica no Nordeste e vazão do Paraibuna ( $\text{m}^3/\text{s}$ ) (jan 1976 a jul de 2009) (Fonte: Matos(2013)).




Figure: Streamflow and wind power factor series.




Figure: Scatter plot of the series and regression line.

- ❑ A complementariedade entre as séries será capturada pela correlação do modelo bivariado, especificado a seguir.

- We considered a modified version of a bivariate distribution proposed by Nadarajah (2009). Let  $u$  and  $v$  be gamma variables with:

$$u \sim \text{Gamma}(\alpha, \lambda/\alpha), \quad v \sim \text{Gamma}(\beta, \lambda/\alpha). \quad (21)$$

- Now, define  $y_1$  and  $y_2$  as follows:

$$y_1 = u, \quad y_2 = k \frac{v}{u + v} \quad (22)$$

- Thus,  $y_1$  and  $y_2$  have gamma and beta distributions, respectively. The bivariate  $\text{Gamma} - \text{Beta}(\alpha, \beta, \lambda)$  is easily obtained through a change of variables.

$$p(y_1, y_2) = \frac{k y_1^{\alpha+\beta-1} y_2^{\beta-1} (k - y_2)^{-(\beta+1)} \exp\{-k\alpha y_1 / [(k - y_2)\lambda]\}}{(\lambda/\alpha)^{\alpha+\beta} \Gamma(\alpha) \Gamma(\beta)} \quad (23)$$

$y_1$  = vazão (gama)  
 $y_2$  = fator de capacidade (beta)

Moments:

$$E(y_1) = \lambda, \quad V(y_1) = \lambda^2 / \alpha$$

$$E(y_2) = k \frac{\beta}{\alpha + \beta}, \quad V(y_2) = k^2 \frac{\alpha\beta}{(\alpha + \beta)^2 (\alpha + \beta + 1)}$$

$$\text{Corr}(y_1, y_2) = - \left( 1 + \frac{\alpha + 1}{\beta} \right)^{-\frac{1}{2}}$$

> vamos fazer os parâmetros  $\beta$  e  $\lambda$  variantes no tempo através de um mecanismo GAS(p,q) com lags sazonais.



$$(\beta_t, \lambda_t) = (\exp [f_{1,t} + exo_{1,t}], \exp [f_{2,t} + exo_{2,t}])'$$

$$\begin{bmatrix} f_{1,t+1} \\ f_{2,t+1} \end{bmatrix} = \begin{bmatrix} 2.10 \\ 0.38 \end{bmatrix} + \begin{bmatrix} 0.40 & 0 \\ 0 & 0.51 \end{bmatrix} \begin{bmatrix} s_{1,t} \\ s_{2,t} \end{bmatrix} + \begin{bmatrix} -0.04 & 0 \\ 0 & 0.40 \end{bmatrix} \begin{bmatrix} s_{1,t-1} \\ s_{2,t-1} \end{bmatrix} + \begin{bmatrix} 0.33 & 0 \\ 0 & 0.23 \end{bmatrix} \begin{bmatrix} s_{1,t-2} \\ s_{2,t-2} \end{bmatrix} + \begin{bmatrix} 0.004 & 0 \\ 0 & 0.22 \end{bmatrix} \begin{bmatrix} s_{1,t-10} \\ s_{2,t-10} \end{bmatrix} + \begin{bmatrix} 0.12 & 0 \\ 0 & 0.18 \end{bmatrix} \begin{bmatrix} s_{1,t-11} \\ s_{2,t-11} \end{bmatrix} + \begin{bmatrix} 0.57 & 0.11 \\ 0.01 & -0.03 \end{bmatrix} \begin{bmatrix} f_{1,t} \\ f_{2,t} \end{bmatrix} + \begin{bmatrix} -0.53 & 0 \\ 0 & 0.02 \end{bmatrix} \begin{bmatrix} f_{1,t-1} \\ f_{2,t-1} \end{bmatrix} + \begin{bmatrix} 0.21 & 0 \\ 0 & 0.13 \end{bmatrix} \begin{bmatrix} f_{1,t-2} \\ f_{2,t-2} \end{bmatrix} + \begin{bmatrix} -0.14 & 0 \\ 0 & 0.12 \end{bmatrix} \begin{bmatrix} f_{1,t-10} \\ f_{2,t-10} \end{bmatrix} + \begin{bmatrix} 0.10 & -0.25 \\ -0.23 & 0.83 \end{bmatrix} \begin{bmatrix} f_{1,t-11} \\ f_{2,t-11} \end{bmatrix}$$

$$\begin{aligned} exo_{1,t} = & \quad 0.67SE_t - 0.05NE_t + 0.10NO_t + 0.06SU_t \\ & (0.09) \quad (0.07) \quad (0.14) \quad (0.14) \\ & -0.41SE_{t-1} + 0.20NE_{t-1} - 0.24NO_{t-1} + 0.01SU_{t-1} + \\ & (0.12) \quad (0.10) \quad (0.20) \quad (0.18) \\ & 0.12I_{\{t=109\}} + 0.53I_{\{t=242\}} + 0.61I_{\{t=352\}} \\ & (0.29) \quad (0.87) \quad (0.20) \end{aligned}$$

$$\begin{aligned} exo_{2,t} = & \quad 0.03SE_t + 0.06NE_t - 0.66NO_t - 0.03SU_t + \\ & (0.14) \quad (0.12) \quad (0.19) \quad (0.09) \\ & 0.351SE_{t-1} - 0.12NE_{t-1} + 0.55NO_{t-1} - 0.08SU_{t-1} \\ & (0.12) \quad (0.13) \quad (0.20) \quad (0.28) \end{aligned}$$

The chosen parameterization is given by:

$$(\beta_t, \lambda_t) = \left( \exp \left[ f_{\mathbf{1},t} + \sum_{k=1}^{r_1} \phi_{\mathbf{1}k} g_{\mathbf{1}}(x_{t-k+1}) \right], \exp \left[ f_{\mathbf{2},t} + \sum_{k=1}^{r_2} \phi_{\mathbf{2}k} g_{\mathbf{2}}(x_{t-k+1}) \right] \right)'$$

Score vector and the Fisher Information matrix to  $f_t = (f_{1t}, f_{2t})'$ :

$$\nabla_t = \left[ \begin{array}{c} \beta_t \{ \ln [y_{1t}y_{2t}/(k - y_{2t})] - \ln \lambda_t + \ln \alpha - \psi_1(\beta_t) \} \\ k\alpha y_{1t}/[(k - y_{2t})\lambda_t] - (\alpha + \beta_t) \end{array} \right]$$

$$I_{t/t-1} = \left[ \begin{array}{cc} \beta_t^2 \psi_2(\beta_t) & \beta_t \\ \beta_t & (\alpha + \beta_t) \end{array} \right]$$

$$\begin{aligned} s_t &= (s_{1,t}, s_{2,t})' \\ &= \left( \begin{array}{cc} \beta_t^2 \psi_2(\beta_t) & \beta_t \\ \beta_t & (\alpha + \beta_t) \end{array} \right)^{-1} \left( \begin{array}{c} \beta_t \left[ \ln \left( \frac{u_t v_t}{k - v_t} \right) - \ln \lambda_t + \ln \alpha - \psi_1(\beta_t) \right] \\ \frac{k \alpha u_t}{(k - v_t) \lambda_t} - (\alpha + \beta_t) \end{array} \right) \end{aligned}$$

## Simulação fora da amostra

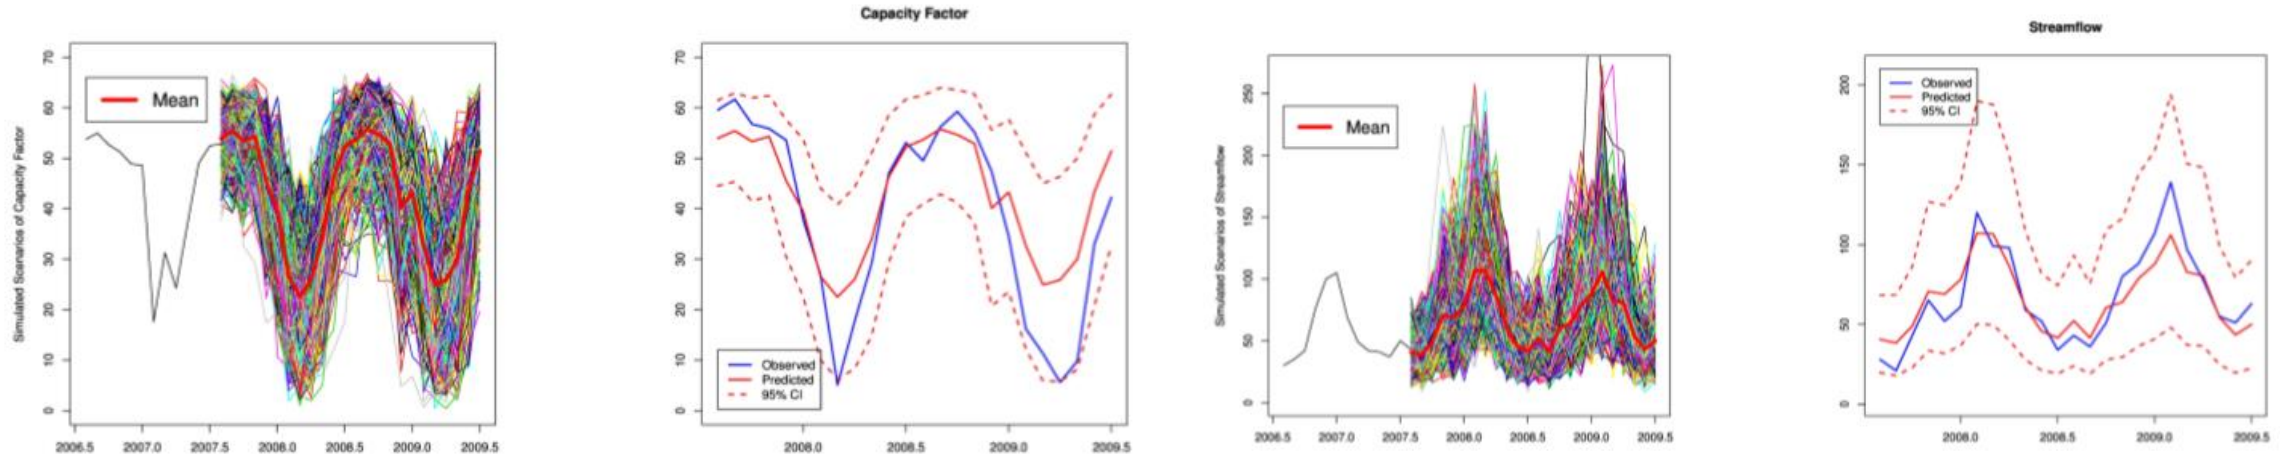


Figure: Power wind factor series - simulated paths and  $k$ -step ahead predictions.

Figure: Streamflow - simulated paths and  $k$ -step ahead predictions.

# Contato

*Alexandre Street:*

*Street@puc-rio.br*

*<http://www.puc-rio.br/lamps>*

*Coordenação do GT Metodologia*  
*[gtmet.cpamp@ccee.org.br](mailto:gtmet.cpamp@ccee.org.br)*

Assessoria Técnica:

