

# Série dos Seminários de Acompanhamento à Pesquisa

Cenários de geração de energia correlacionados,  
considerando diferentes fontes

Autor:

Anderson Mitterhofer Lung

# Série dos Seminários de Acompanhamento à Pesquisa

Número 37 | 05 2022

## Cenários de geração de energia correlacionados, considerando diferentes fontes

Autor:

Anderson Mitterhofer Lung

Orientador: Prof. Fernando Cyrino (DEI-PUC)

Co-orientador: Prof. Andre Marcato (UFJF)

### CRÉDITOS:

SISTEMA MAXWELL / LAMBDA  
<https://www.maxwell.vrac.puc-rio.br/>

Organizadores: Fernanda Baião / Soraida Aguilar

Layout da Capa: Aline Magalhães dos Santos

# Sobre Mim

## Anderson Mitterhofer lung

Doutorando – DEI/PUC – Rio - 2020

Diretor de Riscos de Mercado – Elera Renováveis

Northwestern University - Kellogg School of Management Evanston, IL - EUA  
Kellogg FDC Post-MBA Program Nov. - Dec. 2010

Fundação Dom Cabral Nova Lima, MG - Brasil  
MBA Empresarial Abr. 2006 - Out. 2007

Pontifícia Universidade Católica do Rio de Janeiro - PUC-Rio Rio de Janeiro, RJ - Brasil  
Mestrado em Engenharia Elétrica Mar. 1998 - Abr. 2000

Universidade Federal de Juiz de Fora - UFJF Juiz de Fora, MG - Brasil  
Especialização em Estatística Abr. 1997 - Jul. 1999

Universidade Federal de Juiz de Fora - UFJF Juiz de Fora, MG - Brasil  
Graduação em Engenharia Elétrica 1991 - 1996

**Orientador: Prof<sup>o</sup> Fernando Cyrino (DEI-PUC)**

**Co-orientador: Prof<sup>o</sup> Andre Marcato (UFJF)**

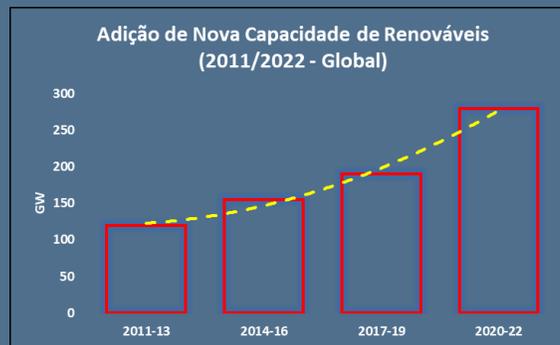


# Contexto

# 1

## GERAÇÃO DE ENERGIA

- Diversificação das fontes
- Crescimento e maior penetração de renováveis
- Renováveis: 90% da nova capacidade em 2021 e 2022



- ✓ Crescimento 2020/22 – 45% (280 GW)
- ✓ Maior crescimento ano-a-ano (desde 2019)
- ✓ Solar deve atingir 162 GW em 2022
- ✓ Em 2020 adição de capacidade eólica cresceu mais de 90% (114 GW)

Fonte: International Energy Agency (IEA). Renewable Energy Market Update – Outlook for 2021 and 2022, Paris 2021.

# 2

## INCERTEZA

- Maior dependência de recursos naturais

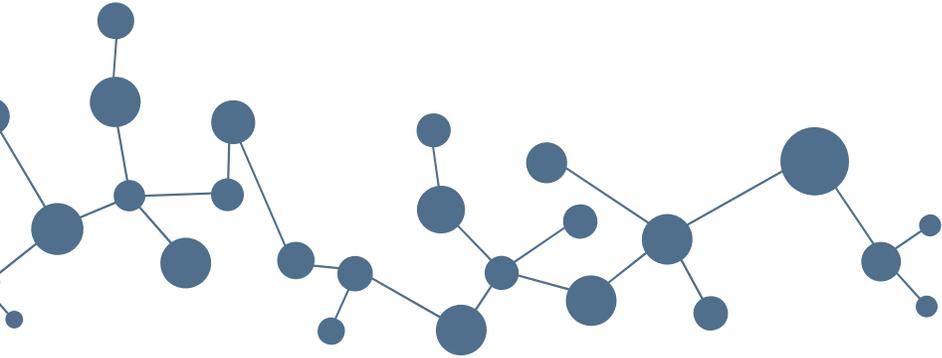
# 3

## DESAFIOS

- Otimização da operação do sistema
- Gerenciamento de riscos:
  - Sistêmico (atendimento da carga)
  - Comercial (gestão dos ativos)

*Considerando as correlações entre todas as fontes*

# Abordagens



1- Modeling Multiscale Variable Renewable Energy and Inflow Scenarios in Very large Regions with Nonparametric **Bayesian Networks** – Júlio A. Dias, Guilherme Machado, Alessandro Soares, Joaquim D. Garcia – ArXiv, 2020.

2- Complementary modeling of monthly streamflow and wind speed regimes based on a **copula-entropy** approach: A Brazilian case study – Leandro Ávila R., Miriam R.M. Mine, Eloy Kaviski, Daniel H.M. Detzel, Heinz D. Fill, Marcelo R. Bessa, Guilherme A.A. Pereira – Applied Energy 259, 2020.

3- Uma abordagem para representação das incertezas da fonte de **geração eólica no modelo NEWAVE** – Maria Elvira P. Maceira, Albert C.G. Melo, José F.M. Pessanha, Cristiane B. Cruz, Victor A. Almeida, Thatiana C. Justino – Cadernos do IME – Série Estatística, 2020.

# Abordagem Não-Paramétrica



**Passo 1:** Estimativa não paramétrica - Para cada variável aleatória, ou seja, cada estação renovável, aplicar o método selecionado aos dados históricos, obtendo uma função de distribuição para cada variável aleatória.

**Passo 2:** Transformação - Transforma as distribuições marginais não paramétricas em distribuições uniformes

**Passo 3:** Determinar a dependência estatística – aplicar a metodologia nas variáveis transformadas para estimar a dependência estatística entre as variáveis aleatórias

**Etapa 4:** Estimativa dos parâmetros de regressão - O modelo de regressão de cada variável aleatória



# Distribuições Marginais (PDF)

→ Para cada variável aleatória obter a função de distribuição

→ Abordagem não-paramétrica:

- Melhor ajuste do processo estocástico
- Custo computacional

## Bayesian Networks

- Metodologia: Kernel Density Estimation (KDE)

$$\hat{f}_h(x) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{x-x_i}{h}\right)$$

Onde:

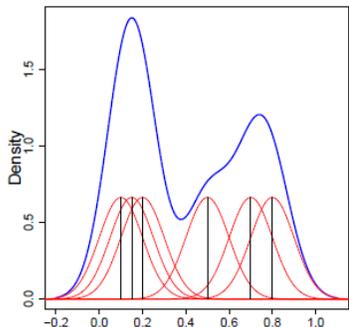
$K$  ⇒ Kernel – função não-negativa

$h$  ⇒ bandwidth (parâmetro de amortecimento),  $>0$

$n$  → n<sup>o</sup> de observações

$x$  → observações da variável

\*Funções Kernel: uniforme, triangular, biweight, triweight, Epanechnikov, normal etc.



Fonte: A Tutorial on Kernel Density Estimation and Recent Advances, Yen-Chi Chen, University of Washington, Sept, 2017

## Copula-Entropy

- Metodologia: Principle of Maximum Entropy (POME)

$$H(X) = - \int_a^b f(x) \log f(x) dx$$

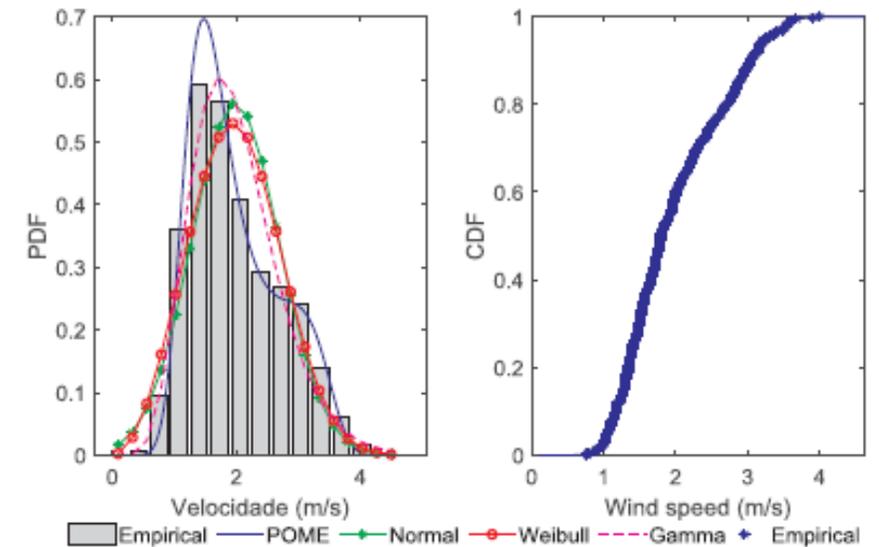
$H(X)$  → entropia da variável aleatória

$f(x)$  → PDF de X

$X$  → variável aleatória

Definição das restrições\* é crítico para o processo de definição da PDF

\*Média, desvio-padrão, assimetria e curtose foram utilizadas



Fonte Complementary modeling of monthly streamflow and wind speed regimes based on a copula-entropy approach: A Brazilian case study – Leandro Ávila R., Miriam R.M. Mine, Eloy Kaviski, Daniel H.M. Detzel, Heinz D. Fill, Marcelo R. Bessa, Guilherme A.A. Pereira – Applied Energy 259, 2020.

# Distribuições Uniformes

→ Melhora o processo de modelagem das dependências entre as diferentes variáveis aleatórias

## Bayesian Network

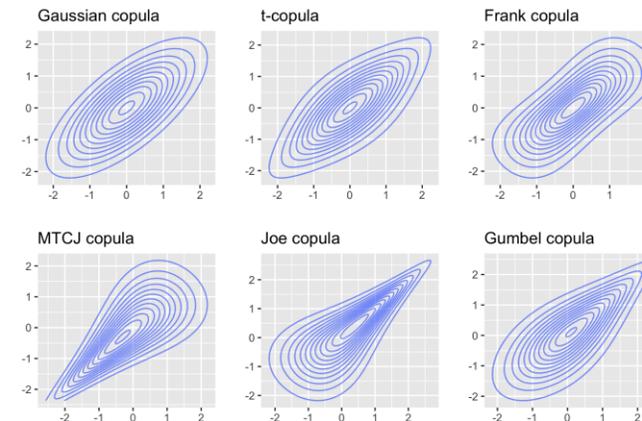
- Metodologia: transformação Nataf (Equivalente a escolher implicitamente uma cópula gaussiana)
- 1) Obter a CDF  $\rightarrow F_x$
- 2) Existe uma  $F_x^{-1} \rightarrow u_i = F_x^{-1}(X_i)$
- 3) Nova série temporal  $u_1, u_2, \dots, u_n$  e  $u_i \sim U(0,1)$
- 4) Aplicar função quantil normal:  
 $Q_N(u_i) = \inf \{x \in R: u_i \leq F_x(X)\}$
- 5) Variáveis com distribuição normal:  
 $q_1 = Q_N(u_1), q_2 = Q_N(u_2), \dots, q_n = Q_N(u_n)$

Assim, a distribuição conjunta é assumida uma gaussiana multivariada.

**Possível calcular a matriz de covariância e estimar a correlação**

## Copula-entropy

- Metodologia: copulas
- 1) Obter a CDF  $\rightarrow F_x$
- 2)  $F(X_1, \dots, X_d) = C\{F_1(x_1), \dots, F_d(x_d)\} = C(u_1, \dots, u_d)$
- 3)  $C \rightarrow$  cópula que modela a estrutura de dependência do vetor aleatório  $X = (X_1, \dots, X_d)$
- 4) Escolha da cópula via Bayesian Information Criterion (BIC)

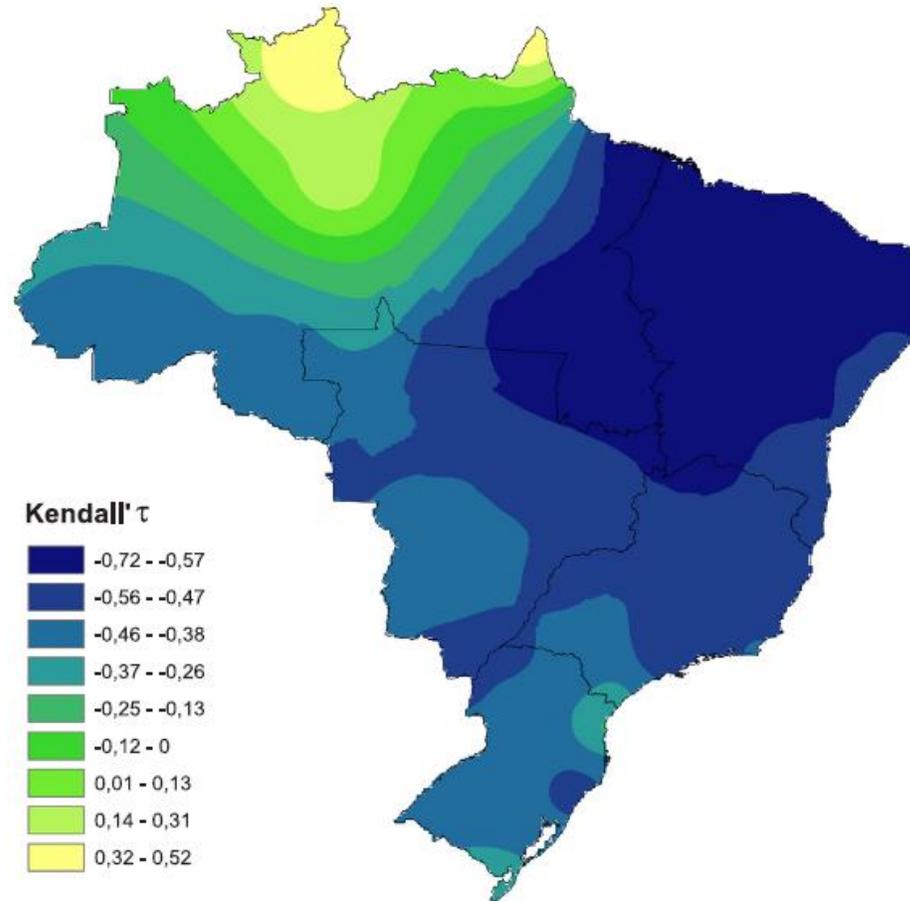


Fonte: Copula: A Very Short Introduction - <https://bochang.me/blog/posts/copula/>

**Frank Cópula foi a que melhor representou a estrutura de dependência entre vazões e velocidade do vento**

# Escolha da Cópula (Copula-entropy)

Comparação entre a correlação empírica entre vazões e velocidade do vento (dados históricos) e a correlação simulada, baseada no Kendall  $\tau$ .



**Fig. 4.** Empirical cross-correlation based on Kendall's  $\tau$  between historical streamflow and wind speed time series.

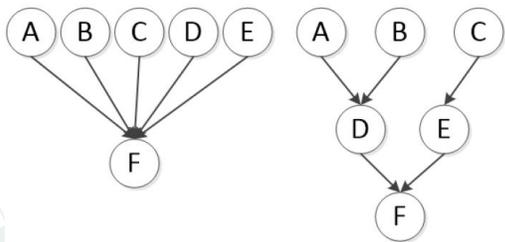
Fonte Complementary modeling of monthly streamflow and wind speed regimes based on a copula-entropy approach: A Brazilian case study – Leandro Ávila R., Miriam R.M. Mine, Eloy Kaviski, Daniel H.M. Detzel, Heinz D. Fill, Marcelo R. Bessa, Guilherme A.A. Pereira – Applied Energy 259, 2020.

# Representação da Probabilidade Conjunta

➔ Objetivo: evitar o crescimento exponencial do modelo, a medida que cresce o número de variáveis

## Bayesian Network

- Metodologia: Rede Bayesiana – representa apenas as correlações mais importantes
- 1) Estrutura acíclica direcionada de grafo – nós são as variáveis aleatórias  $X = \{X_i, \dots, X_n\}$  e os arcos as dependências condicionais entre as variáveis
- 2) Propriedade:  $X_i \perp X_j | pa(X_i) \forall X_j \notin pa(X_i)$
- 3) Distribuição de probabilidade conjunta:  
$$P(X_1, \dots, X_n) = \prod_{i=1}^n P(X_i | pa(X_i))$$



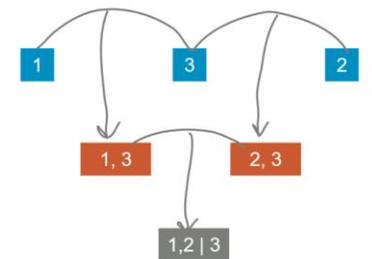
$$P(F) = f(P(D|A, B) \cdot P(A) \cdot P(B) \cdot P(E|C) \cdot P(C))$$

Fonte: Modeling Multiscale Variable Renewable Energy and Inflow Scenarios in Very large Regions with Nonparametric Bayesian Networks – Júlio A. Dias, Guilherme Machado, Alessandro Soares, Joaquim D. Garcia – ArXiv, 2020.

## Copula-entropy

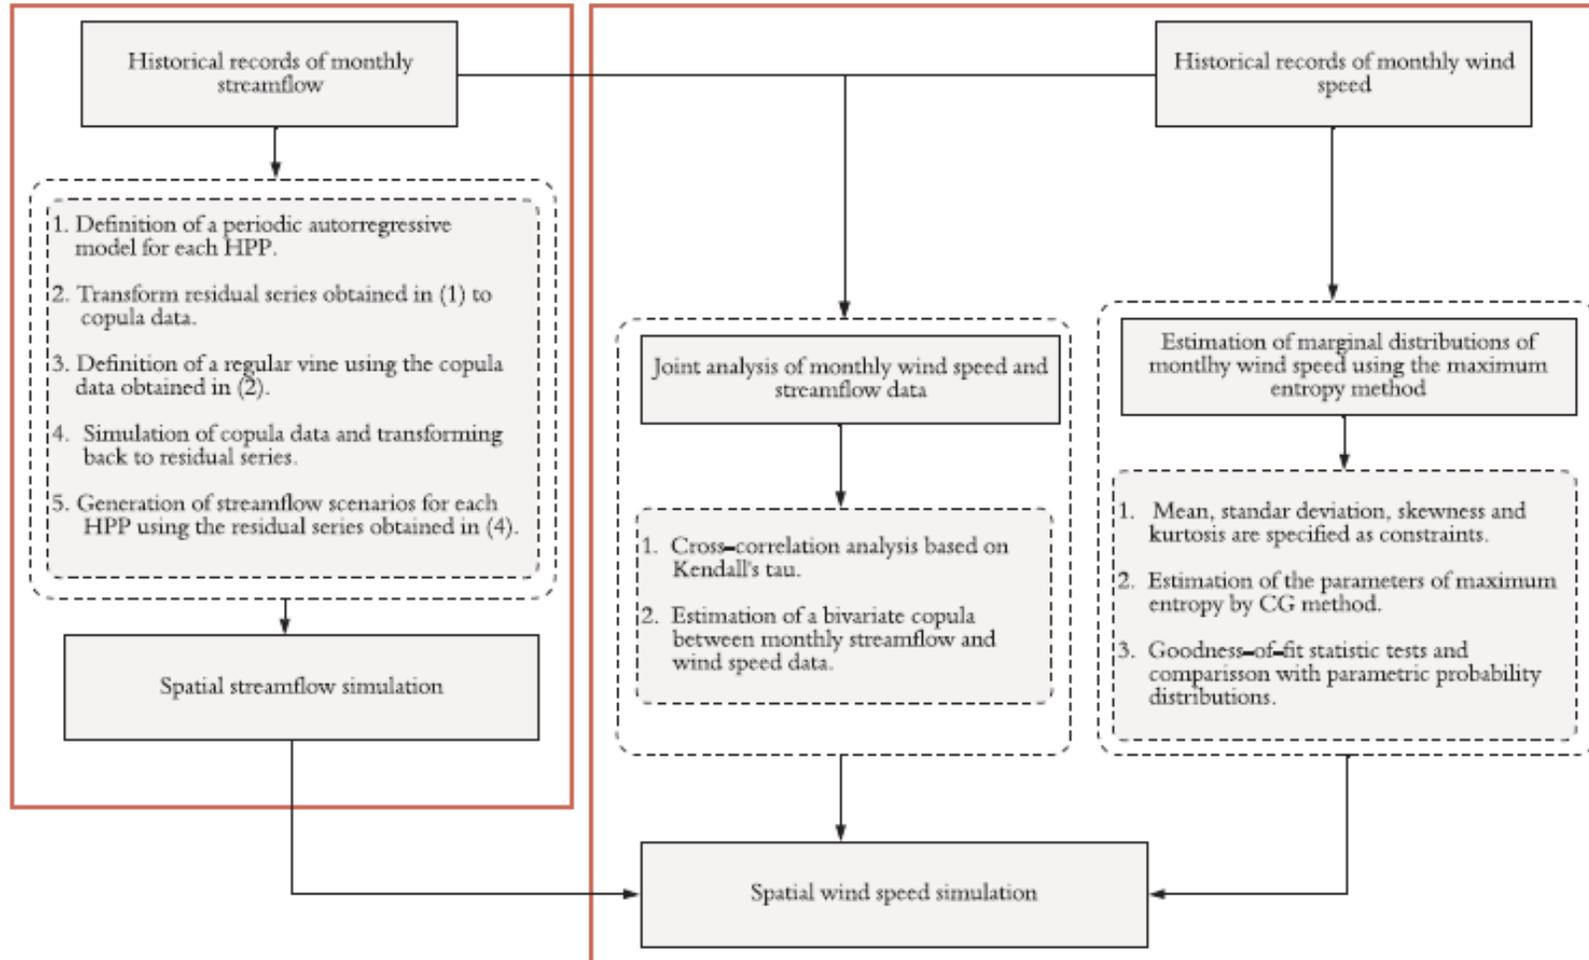
- Metodologia: Pair-copula construction (PCC) e Regular Vine Copula
- 1) Permite a decomposição da função densidade de probabilidade multivariada em probabilidades condicionais e incondicionais
- 2) Vine copula para árvore com 3 variáveis aleatórias

$$\begin{aligned} f(x_1, x_2, x_3) &= f_1(x_1) f_2(x_2) f_3(x_3) \\ &\times c_{23}(F_2(x_2), F_3(x_3)) \cdot c_{13}(F_1(x_1), F_3(x_3)) \\ &\times c_{12|3}(F_{1|3}(x_1|x_3), F_{2|3}(x_2|x_3)) \end{aligned}$$



Fonte: Copula for Statistical Arbitrage: A Practical Intro to Vine Copula, Hansen Pei - <https://hudsonthames.org/a-practical-intro-to-vine-copula/>

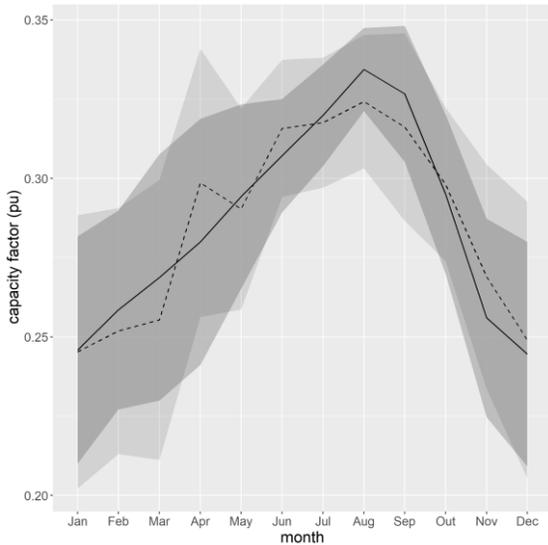
# Framework – Copula-Entropy



**Fig. 2.** General framework for the spatial simulation of monthly streamflow and wind speed time series.

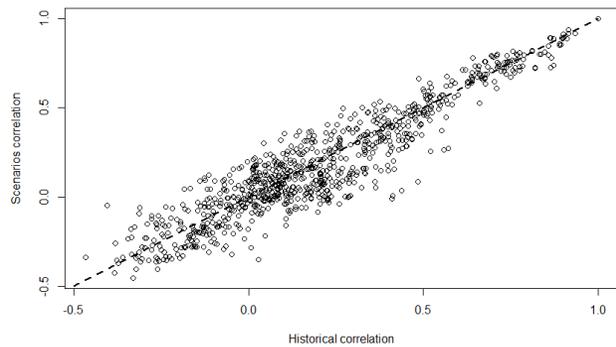
# Resultados – Cenários Correlacionados: Veloc. Vento | Vazão

## Bayesian Network



- Linha pontilhada: média dos cenários sintéticos
- Linha cheia: média do histórico
- Cinza claro: intervalo de confiança dos cenários sintéticos
- Cinza escuro: intervalo de confiança do histórico

## Intervalo de confiança - Solar



## Correlação histórica x sintética

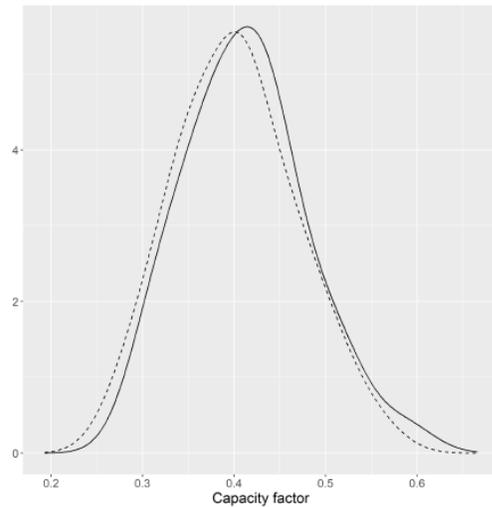


Fig. 5 Wind station PDF

## PDF Eólica

## Copula-Entropy

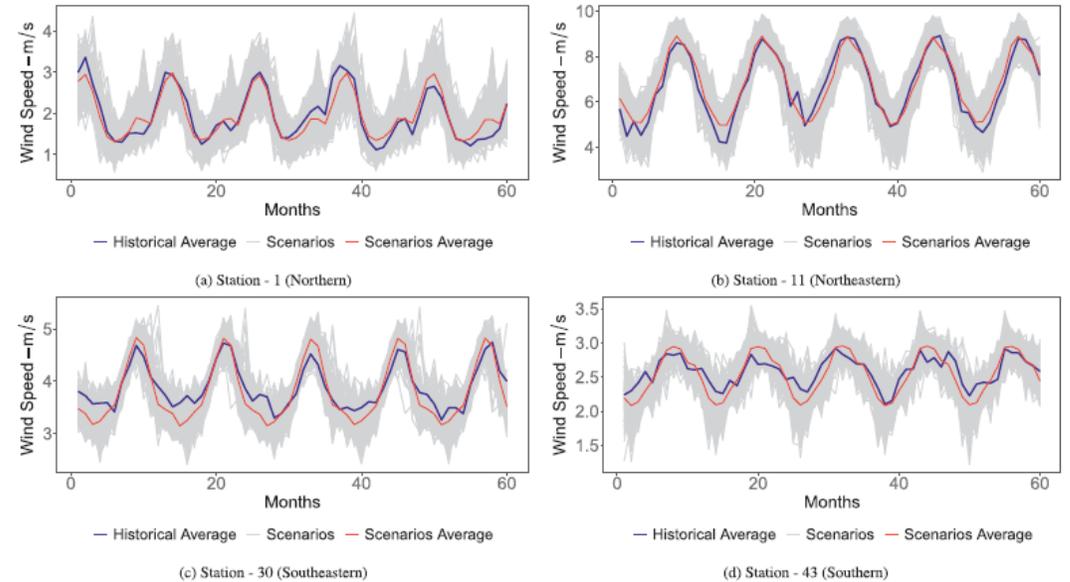


Fig. 12. Simulated wind speed scenarios for four wind speed stations.

Fonte: Complementary modeling of monthly streamflow and wind speed regimes based on a copula-entropy approach: A Brazilian case study – Leandro Ávila R., Miriam R.M. Mine, Eloy Kaviski, Daniel H.M. Detzel, Heinz D. Fill, Marcelo R. Bessa, Guilherme A.A. Pereira – Applied Energy 259, 2020.

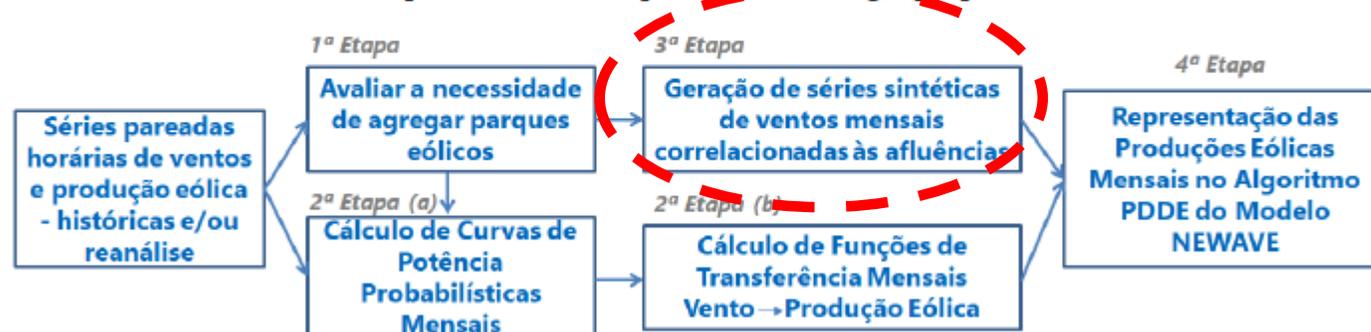
# Geração Eólica no Modelo Newave

- NEWAVE: modelo oficial para planejamento da operação e expansão do sistema elétrico brasileiro
  - Solução do problema de programação linear estocástica multi-estágio, através do algoritmo de programação dinâmica dual estocástica (PDDE)
  - Representação das incertezas das vazões das hidroelétricas
  - Representação da geração eólica de forma simplificada (média mensal dos últimos 5 anos)
  - Objetivo do estudo: definir uma estratégia de consideração de cenários de produção de fontes renováveis (**eólica** e solar), aderente ao algoritmo de solução (PDDE)

# Abordagem Proposta

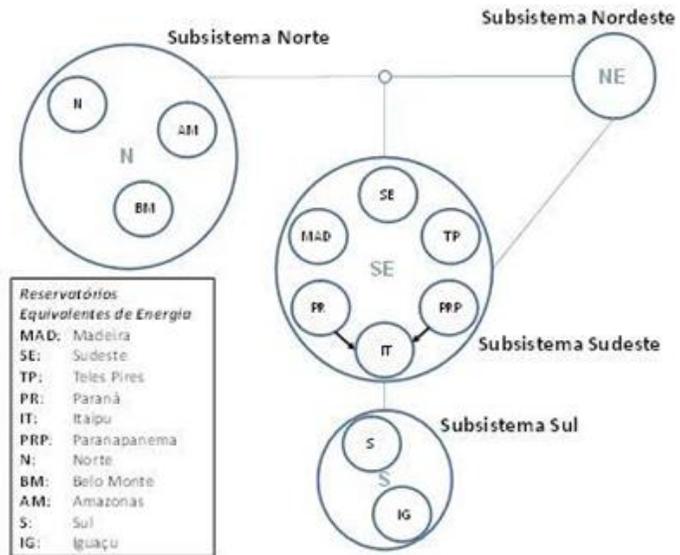
- Representação dos parques eólicos – individual ou parques eólicos equivalentes (PEEs)
- Modelar as correlações espaciais – entre os parques eólicos e entre os parques eólicos e as hidroelétricas (Reservatórios equivalentes)
- Construção de funções de transferências entre velocidade do vento e produção eólica

Figura 3.1. Representação das incertezas da fonte eólica no modelo NEWAVE – diagrama esquemático das etapas da metodologia proposta



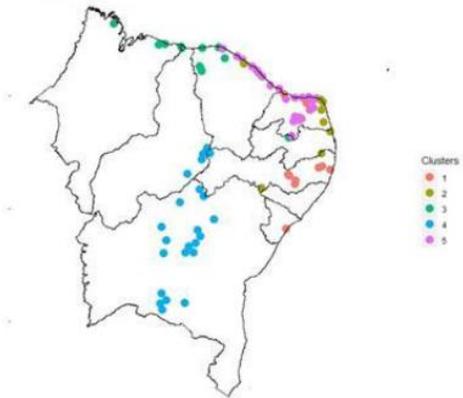
# Representação Hidroelétricas e Eólicas

- Agregação de usinas hidroelétricas em Reservatórios Equivalentes de Energia (REEs)
- Agregação de usinas eólicas em Parques Eólicos Equivalentes (PEEs)



Fonte: adaptado CEPEL-Eletróbrás

Figura 4.3 – Representação espacial dos agrupamentos dos aproveitamentos eólicos



Fonte Uma abordagem para representação das incertezas da fonte de geração eólica no modelo NEWAVE – Maria Elvira P. Maceira, Albert C.G. Melo, José F.M. Pessanha, Cristiane B. Cruz, Victor A. Almeida, Thatiana C. Justino – Cadernos do IME – Série Estatística, 2020.– Júlio A. Dias, Guilherme Machado, Alessandro Soares, Joaquim D. Garcia – ArXiv, 2020.

- Representação da correlação espacial verificada entre os processos estocásticos de ventos (PEEs) e afluências aos REEs

Tabela 6.1 - Correlação espacial entre os PEEs NE-L, NE-I e Sul e alguns REEs do SIN.

NE-L	Sudeste	Paraná	Nordeste	Norte	NE-I	Sudeste	Paraná	Nordeste	Norte	Sul	Paraná	Belo Monte	Sul	Iguaçu
<b>Fevereiro</b>	-0.38	-0.45	-0.36	-0.36	<b>Maio</b>	0.47	0.31	0.49	0.23	<b>Fevereiro</b>	0.51	0.29	0.33	0.37
<b>Agosto</b>	-0.54	-0.60	-0.36	-0.30	<b>Junho</b>	-0.45	-0.62	-0.27	-0.39	<b>Abril</b>	-0.32	-0.57	0.26	0.40
<b>Setembro</b>	-0.70	-0.89	-0.56	-0.69	<b>Setembro</b>	-0.33	-0.44	-0.22	-0.31	<b>Maio</b>	0.16	-0.32	0.35	0.32
<b>Outubro</b>	-0.59	-0.69	-0.49	-0.75	<b>Dezembro</b>	-0.52	0.20	-0.28	-0.52	<b>Outubro</b>	-0.38	-0.30	0.36	0.31

Fonte: Autores

# Geração das Séries Sintéticas

- Processo estocástico que representa o vento com  $s$  períodos sazonais:

$$\left( \frac{V_t - \mu_m^v}{\sigma_m^v} \right) = \text{componente explicativa} + a_t$$

$$V_t = \text{componente explicativa} + \sigma_m^v a_t$$

componente explicativa  $\rightarrow$  média do processo estocástico vento no período sazonal  $m$  correspondente ao estágio  $t$  ou conter uma parcela relacionada às afluências do próprio estágio  $t$  ou do estágio  $t-1$ .

- Para gerar afluências e ventos mensais multivariados, assume-se que os ruídos  $a_t$ , não correlacionados espacialmente, podem ser transformados em ruídos espacialmente correlacionados  $e_t$

$$e_t = D a_t$$

$D$  pode ser estimada por:

$$D D^T = \hat{U}$$

$\hat{U} \rightarrow$  estimativa da matriz de covariâncias os PEEs e REEs, correspondentes às afluências e ventos.

# Geração das Séries Sintéticas

- Uma Lognormal três parâmetros é ajustada aos resíduos espacialmente correlacionados, reproduzir assimetria observada no processo estocástico. Em caso de assimetria negativa a distribuição Weibull três parâmetros substitui a Lognormal
- São gerados 100.000 resíduos não correlacionados, aplica-se o método k-means para redução da cardinalidade, reduzindo a amostra para 2000 ruídos (que não são amis equiprováveis). Os 2000 ruídos resultantes passam pelo processo de correlação.

Figura 6.1 – Distribuição de frequências dos ruídos Normais e dos ruídos Weibull

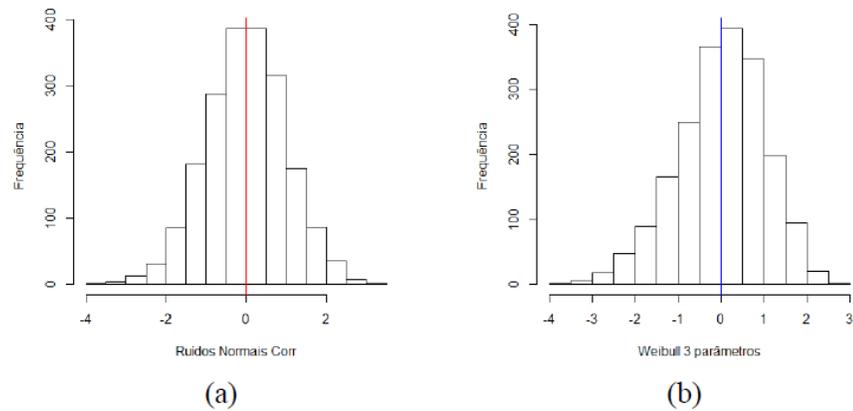
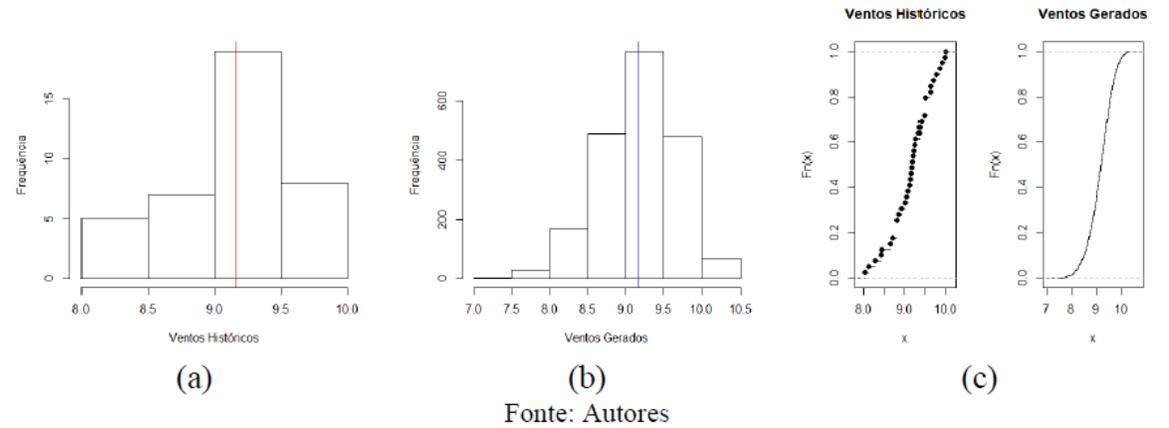


Figura 6.2 – Histogramas e distribuição de frequências acumuladas dos ventos históricos e sintéticos



Fonte: Autores



# Considerações Finais

## 1

- As abordagens propostas nos artigos mostram capacidade para gerar cenários correlacionados entre vazões, velocidades de vento e radiação
- Os artigos com as metodologias de Cópulas e Redes Bayesianas apresentaram resultados mais detalhados
- O trabalho voltado para representação das incertezas da geração eólica no modelo NEWAVE está em uma estágio mais inicial
- A abordagem para implementação no NEWAVE traz a necessidade de adequação à PDDE

## 2

- O custo computacional das abordagens não-paramétricas não foi endereçado nos trabalhos
- Também não foi alvo de nenhum dos trabalhos fazer uma comparação com outras abordagens propostas na literatura

## 3

- Desafios adicionais relacionados ao problema:
  - Dados: disponibilidade, dados de reanálise, diferentes resolução (mensal, horária etc.)
  - Dimensionalidade: nº de usinas

## 4

- *Work in Progress:*
    - Revisão sistemática da literatura
    - Geração de cenários correlacionados – assunto “novo”
    - Cópula abordagem mais usada
    - Muitos estudos sobre complementariedade (média)
    - Foco no curto-prazo (horário) – problemas operativos (*real-time*)
- 

**OBRIGADO!**

# Bibliografia

- Modeling Multiscale Variable Renewable Energy and Inflow Scenarios in Very large Regions with Nonparametric Bayesian Networks – Júlio A. Dias, Guilherme Machado, Alessandro Soares, Joaquim D. Garcia – ArXiv, 2020.
- Complementary modeling of monthly streamflow and wind speed regimes based on a copula-entropy approach: A Brazilian case study – Leandro Ávila R., Miriam R.M. Mine, Eloy Kaviski, Daniel H.M. Detzel, Heinz D. Fill, Marcelo R. Bessa, Guilherme A.A. Pereira – Applied Energy 259, 2020.
- Uma abordagem para representação das incertezas da fonte de geração eólica no modelo NEWAVE – Maria Elvira P. Maceira, Albert C.G. Melo, José F.M. Pessanha, Cristiane B. Cruz, Victor A. Almeida, Thatiana C. Justino – Cadernos do IME – Série Estatística, 2020.
- *A Tutorial on Kernel Density Estimation and Recent Advances* - Yen-Chi Chen, Department of Statistics - University of Washington, Sept, 2017
- Principle of Maximum Entropy - <https://mtlsites.mit.edu/Courses/6.050/2003/notes/chapter10.pdf>
- Copula for Statistical Arbitrage: A Practical Intro to Vine Copula, Hansen Pei - <https://hudsonthames.org/a-practical-intro-to-vine-copula/>