

Título: Proposta Metodológica para o Aprimoramento da Memória de Modelos Auto-Regressivos Periódicos.

Nº de Páginas: 24

Nº de Anexos: 0

Dados do Cliente:

Comissão Permanente Análise de Metodologias e Programas Computacionais do Setor Elétrico - GT Metodologia/CPAMP

Departamento: Departamento de Otimização Energética e Meio Ambiente - DEA

Centro de Lucro: C230000101

Centro de Custo: C203000006/C203000020

Resumo: Neste relatório foi proposta uma abordagem para ampliar a memória do modelo de series temporais PAR(p), utilizado pelo modelo GEVAZP na geração de cenários sintéticos de afluências aos modelos NEWAVE e DECOMP, denominada modelo Auto-Regressivo Periódico com Componente Anual - PAR(p)-A, por meio da inclusão de um novo termo na equação de auto-regressão de cada período sazonal, dado pela média das 12 últimas afluências. Os resultados obtidos mostraram que o novo modelo possibilitou representar melhor a persistência de uma tendência hidrológica incomum. Adicionalmente, foi apresentado o cálculo das estimativas dos parâmetros bem como a identificação da ordem do modelo proposto. A abordagem proposta foi aplicada ao Programa Mensal de Operação do mês de janeiro de 2019.

Autores:

Felipe Treistman – PUC/RJ*
Maria Elvira Piñeiro Maceira – Cepel
Jorge Machado Damázio - Cepel
Cristiane Barbosa da Cruz Oliveira – Cepel
* Atualmente, o pesquisador encontra-se no ONS.

Palavras-Chave:

Modelos auto-regressivos periódicos; hidrologia estocástica; geração de séries sintéticas; séries temporais; planejamento da operação de longo/médio prazo.

Classificação de acesso: Público

Aprovação e data de emissão

ANDRE LUIZ DINIZ SOUTO
LIMA:02833576730

Assinado de forma digital por
ANDRE LUIZ DINIZ SOUTO
LIMA:02833576730
Dados: 2020.10.09 11:12:52
-03'00'

André Luiz Diniz Souto Lima
Chefe do Departamento de Otimização Energética e Meio Ambiente

Tel.: 21-2598-6046

E-mail: diniz@cepel.br

Aprovação e data de emissão



Assinado de forma digital por MAURICIO BARRETO LISBOA:96400447768
Dados: 2020.10.14 17:53:44 -03'00'

Mauricio Barreto Lisboa

Diretor de Pesquisa, Desenvolvimento e Inovação

Proposta Metodológica para o Aprimoramento da Memória de Modelos Auto-Regressivos Periódicos

Relatório de Projeto CEPEL 1416/20

Projetos GEVAZP e NEWAVE

gevazp@cepel.br
newave@cepel.br

Fevereiro de 2020

SUMÁRIO

<u>SUMÁRIO EXECUTIVO</u>	<u>4</u>
<u>1 INTRODUÇÃO</u>	<u>5</u>
<u>2 MODELAGEM DE SÉRIES TEMPORAIS PERIÓDICAS</u>	<u>9</u>
2.1 O MODELO AUTO-REGRESSIVO PERIÓDICO	9
2.2 ESTIMADORES DE MOMENTOS DOS PARÂMETROS DO MODELO	10
2.3 IDENTIFICAÇÃO DA ORDEM DO MODELO	10
<u>3 ABORDAGEM PROPOSTA PARA A MODELAGEM DE SÉRIES TEMPORAIS PERIÓDICAS</u>	<u>12</u>
3.1 MODELO AUTO-REGRESSIVO PERIÓDICO COM COMPONENTE ANUAL – PAR(P)-A	12
3.2 ESTIMADORES DE MOMENTOS DOS PARÂMETROS DO MODELO	13
3.3 IDENTIFICAÇÃO DA ORDEM DO MODELO	13
<u>4 GERAÇÃO DE CENÁRIOS SINTÉTICOS - MODELOS PAR(P) E PAR(P)-A</u>	<u>15</u>
<u>5 APLICAÇÃO DA ABORDAGEM PROPOSTA</u>	<u>16</u>
<u>6 CONCLUSÕES</u>	<u>22</u>
<u>7 REFERÊNCIAS</u>	<u>23</u>

SUMÁRIO EXECUTIVO

O objetivo deste relatório técnico é descrever a abordagem proposta pelo CEPEL para ampliar a memória do modelo de series temporais PAR(p), utilizado pelo modelo GEVAZP na geração de cenários sintéticos de aflúncias aos modelos NEWAVE e DECOMP, denominada modelo Auto-Regressivo Periódico com Componente Anual - PAR(p)-A, por meio da inclusão de um novo termo na equação de auto-regressão de cada período sazonal, dado pela média das 12 últimas aflúncias.

Desde 2013, a região Nordeste e parte da região Sudeste do Brasil estão passando por um longo período mais seco, com vazões mensais na grande maioria inferiores às médias de longo termo, enquanto parte da região Sul está passando por um período mais úmido prolongado, com vazões mensais na grande maioria superiores às médias de longo termo. Durante esse período, a média dos cenários sintéticos de aflúncias mensais gerados pelo modelo PAR(p) apresenta o prognóstico usual de retorno à média histórica em aproximadamente alguns meses (tipicamente 6 meses), embora o regime incomum de aflúncias persistisse. Esse comportamento indica que o modelo de séries temporais PAR(p) pode ser aprimorado para incorporar mais memória nos cenários de aflúncias gerados.

Os resultados obtidos mostraram que o novo modelo possibilitou representar melhor a persistência de uma tendência hidrológica incomum. Adicionalmente, foi apresentado o cálculo das estimativas dos parâmetros bem como a identificação da ordem do modelo proposto. A abordagem proposta foi aplicada ao Programa Mensal de Operação do mês de janeiro de 2019.

1 INTRODUÇÃO

O planejamento da operação em sistemas hidrotérmicos de grande porte, devido a sua alta complexidade, é dividido, em diversos países, em diferentes etapas que consideram distintos horizontes de tempo e graus de detalhamento na representação do sistema elétrico [1][2][3]. No Brasil, o problema de planejamento da operação do sistema interligado nacional (SIN) é dividido em planejamento de médio e curto prazos, e programação da operação, sendo resolvido através de uma cadeia de modelos [2]. O sistema de geração de energia elétrica brasileiro apresenta uma alta parcela de fontes renováveis de energia, que inclui energia hidrelétrica, biomassa e energia eólica, representando mais de 80% do consumo de eletricidade do país, conforme ilustrado na Figura 1.1. A participação da fonte hidrelétrica é preponderante, caracterizada por grandes reservatórios com capacidade de regulação plurianual, dispostos em diversas cascatas localizadas em diferentes bacias hidrográficas, tendo como principal fonte de incertezas as afluências hidrológicas futuras.

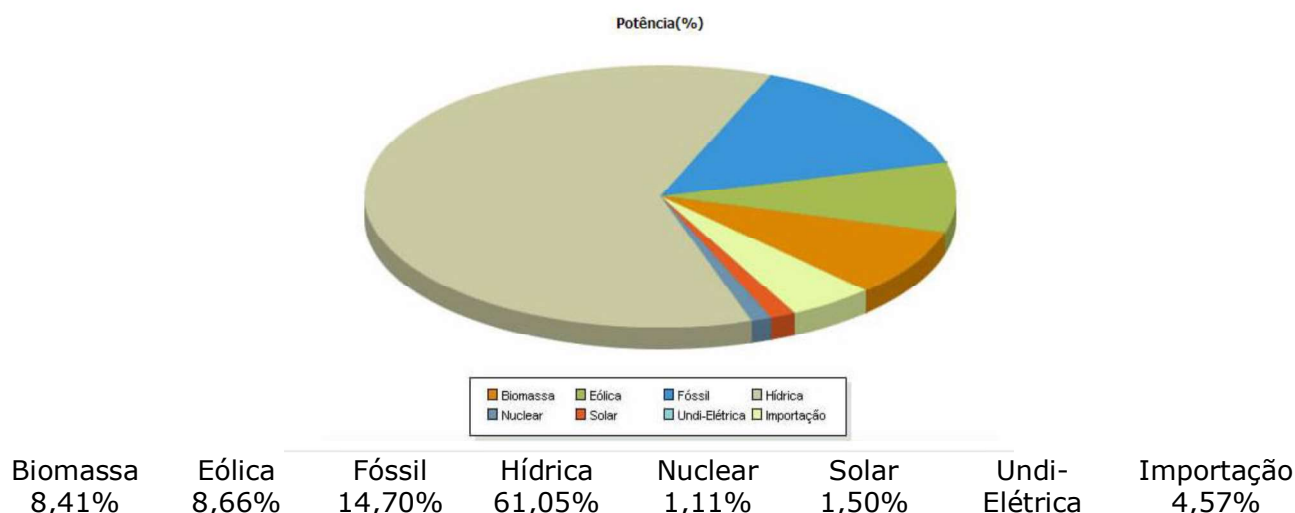


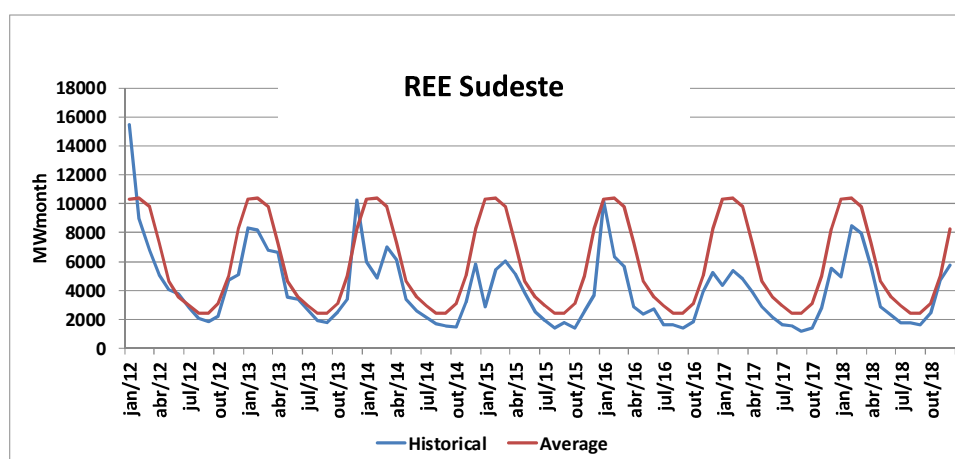
Figura 1.1 – Matriz de Energia Elétrica Brasileira - 2019.

Desde 1998, são empregados algoritmos de programação dinâmica dual estocástica (PDDE) para definir a programação das usinas geradoras do SIN, especialmente fontes hídricas e térmicas, no planejamento da operação a longo e médio prazo [4][5]. O modelo NEWAVE [6] é um modelo de planejamento da operação energética que emprega a técnica de PDDE para construir a política de operação. Esse modelo tem como objetivo determinar a estratégia de operação de longo/médio prazo, de forma a minimizar o valor esperado do custo total de operação ao longo do período de planejamento da operação, considerando mecanismos de aversão a risco; analisar as condições de atendimento energético no horizonte de longo/médio prazo; fornecer a política de operação por meio da função de custo futuro para o modelo de programação de curto prazo – DECOMP [7] e calcular, entre outras variáveis, os custos marginais de operação mensais para cada patamar de carga, utilizando 2.000 cenários hidrológicos sintéticos. Mensalmente, o Operador Nacional do Sistema Elétrico (ONS) elabora, com a participação dos agentes envolvidos, o Programa Mensal da Operação Energética – PMO, com os modelos NEWAVE e DECOMP, a fim de fornecer metas e diretrizes a serem seguidas pelos órgãos executivos da programação diária da operação e da operação em tempo real; e anualmente, o Plano da Operação Energética – PEN, este com o modelo NEWAVE. Em um processo correlato, a Câmara de Comercialização de Energia Elétrica (CCEE) também utiliza esses modelos para o cálculo do Preço de

Liquidação das Diferenças (PLD). Já o Ministério de Minas e Energia (MME) e a Empresa de Pesquisa Energética (EPE) utiliza o modelo NEWAVE na elaboração do Plano Decenal de Expansão de Energia (PDE), que traz uma indicação das perspectivas de expansão futura do setor de energia sob a ótica do Governo.

No modelo NEWAVE, o sistema de geração é representado por um conjunto de subsistemas eletricamente interligados (atualmente são quatro) e o problema de planejamento de operação a longo e médio prazos é modelado como um problema de programação linear estocástica multi-estágios. As variáveis que caracterizam o estado do sistema são o armazenamento dos reservatórios e a tendência hidrológica, esta representada pelas afluições passadas às usinas hidroelétricas. O objetivo do modelo é minimizar o valor esperado do custo da operação durante o período de planejamento ($t = 1$ até $t = T$, onde T varia de 5 a 30 anos discretizado em etapas mensais), dado um estado inicial conhecido do sistema (armazenamento e tendência hidrológica) e considerando mecanismos de aversão a risco; custos de combustível e penalidades pela falha no suprimento de energia compõem o custo da operação. As usinas hidrelétricas em cada subsistema podem ser representadas individualmente (UHEs) ou agregadas em reservatórios equivalentes de energia (REEs) [8][9]. As incertezas nas afluições - vazões quando a representação do sistema se dá a UHEs ou energia quando a representação do sistema se dá a REEs - são modeladas por um modelo auto-regressivo periódico da ordem p , PAR(p) [10], empregado no modelo GEVAZP, a fim de considerar as correlações temporais das afluições, e um esquema de simulação de Monte Carlo é usado para construir iterativamente as funções de custo futuro em cada estágio. O conjunto de funções de custo futuro representa a política ótima de operação. Cenários sintéticos de afluição condicionados a afluições observadas recentes devem ser fornecidos ao algoritmo iterativo de PDDE. Adicionalmente, após a política de operação ter sido construída, uma simulação final da operação do sistema com 2.000 cenários de afluições é executada para obter índices de desempenho do sistema.

Desde 2013, a região Nordeste e parte da região Sudeste do Brasil estão passando por um longo período mais seco, com vazões mensais na grande maioria inferiores às médias de longo termo, enquanto parte da região Sul está passando por um período mais úmido prolongado, com vazões mensais na grande maioria superiores às médias de longo termo, conforme ilustrado na Figura 1.2.



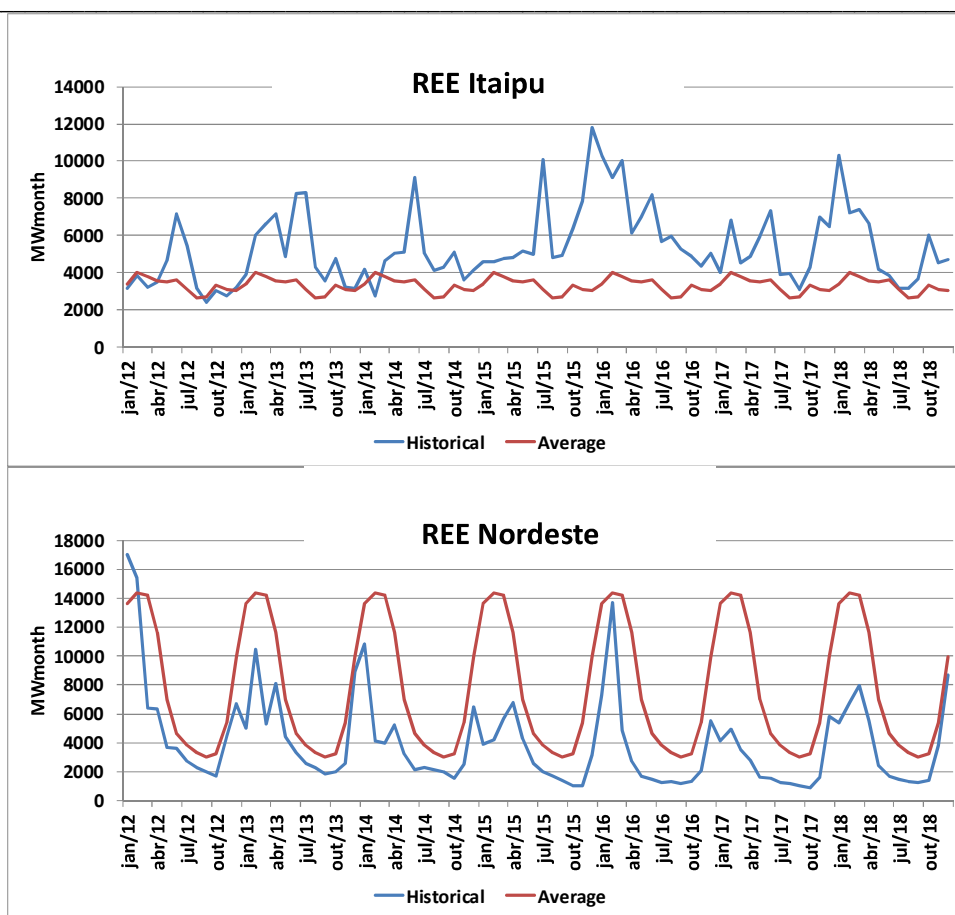


Figura 1.2 – Energias afluentes históricas recentes aos REEs Sudeste, Itaipu e Nordeste.

Durante esse período, a média dos cenários sintéticos de afluências mensais gerados pelo modelo PAR(p) apresenta o prognóstico usual de retorno à média histórica em aproximadamente alguns meses (tipicamente 6 meses), embora o regime incomum de afluências persistisse, conforme ilustrado na Figura 1.3. Esse comportamento indica que o modelo de séries temporais PAR (p) pode ser aprimorado para incorporar mais memória nos cenários de afluências gerados.

Este relatório apresenta uma proposta de ampliação da memória do modelo PAR(p) por meio da inclusão de um novo termo na equação de auto-regressão de cada período sazonal. As próximas seções descrevem o modelo PAR(p) tradicional e a metodologia proposta para a sua extensão. Um estudo de caso com uma configuração real do sistema hidrotérmico interligado brasileiro (PMO Janeiro 2019) é apresentado e discutido.

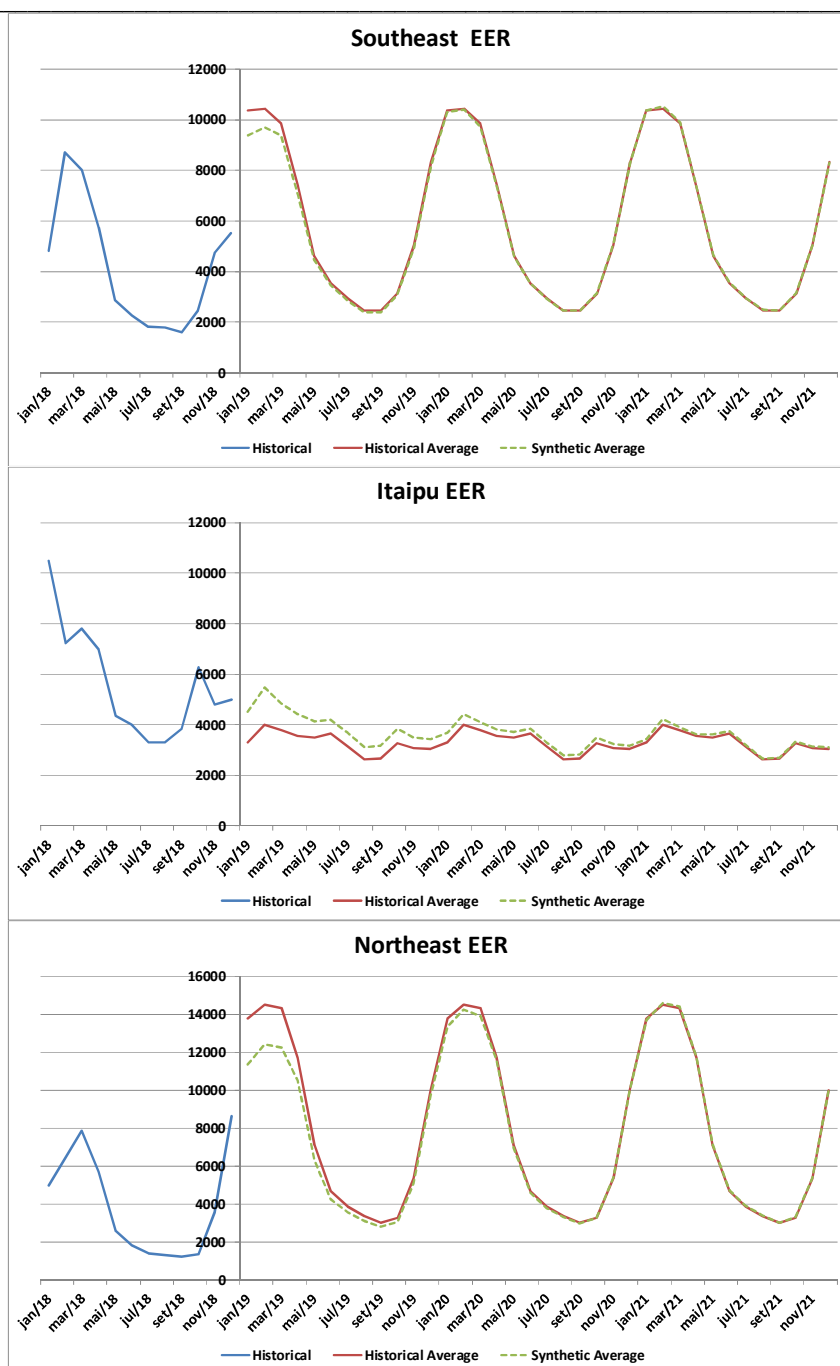


Figura 1.3 – Energias afluentes históricas recentes e a médias mensais do registro histórico e dos cenários sintéticos para os REEs Sudeste, Itaipu e Nordeste.

2 MODELAGEM DE SÉRIES TEMPORAIS PERIÓDICAS

2.1 O Modelo Auto-Regressivo Periódico

Os modelos de séries temporais em que parte dos parâmetros, ou todos, variam dentro do ano são conhecidos como modelos auto-regressivos com parâmetros periódicos e são denotados por modelos PAR(p).

O modelo auto-regressivo periódico, caracterizado por PAR(p_1, \dots, p_s), pode ser escrito como:

$$\phi^m(B) \left(\frac{Z_t - \mu_m}{\sigma_m} \right) = a_t \quad (1)$$

onde:

Z_t é a variável aleatória do processo estocástico com s períodos sazonais;

O índice de tempo t pode ser considerado como uma função do ano T, e do período sazonal m: $t = (T - 1)s + m$;

$$\phi^m(B) = (1 - \phi_1^m B - \dots - \phi_{p_m}^m B^{p_m});$$

B é o operador defasagem no estágio t. $B Z_t = Z_{t-1}$;

μ_m é a média do processo estocástico do período sazonal m correspondente ao estágio t;

σ_m é o desvio-padrão do processo estocástico do sazonal período m correspondente ao estágio t.

A série a_t não correlacionada temporalmente é independente de Z_t , possui média zero e variância $\sigma_a^{2(m)}$ e pode ser escrita como uma função das auto-correlações $\rho^m(k)$ de Z_t e dos coeficientes auto-regressivos periódicos [11][12].

$$\sigma_a^{2(m)} = 1 - \phi_1^m \rho^m(1) - \dots - \phi_{p_m}^m \rho^m(p_m) \quad (2)$$

A função de auto-correlação $\rho^m(k)$ de Z_t é obtida multiplicando-se ambos os lados da equação (1) por $\left(\frac{Z_{t-k} - \mu_{m-k}}{\sigma_{m-k}} \right)$ e aplicando o valor esperado a todos os termos desta equação. Ela satisfaz a equação de diferenças (sistema de equações de Yule-Walker).

$$\rho^m(k) = E \left[\left(\frac{Z_t - \mu_m}{\sigma_m} \right) \left(\frac{Z_{t-k} - \mu_{m-k}}{\sigma_{m-k}} \right) \right] \quad (3)$$

$$\rho^m(k) = \phi_1^m \rho^{m-1}(k-1) + \phi_2^m \rho^{m-2}(k-2) + \dots + \phi_{p_m}^m \rho^{m-p_m}(k-p_m) \quad (4)$$

Para cada período m, variando k de 1 a p_m na equação (4), obtém-se um conjunto de equações lineares, o sistema de equações de Yule Walker estendido para modelos PAR(p).

$$\begin{bmatrix} 1 & \rho^{m-1}(1) & \rho^{m-1}(2) & \dots & \rho^{m-1}(p_m - 1) \\ \rho^{m-1}(1) & 1 & \rho^{m-2}(1) & \dots & \rho^{m-2}(p_m - 2) \\ \rho^{m-1}(2) & \rho^{m-2}(1) & 1 & \dots & \rho^{m-3}(p_m - 3) \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \rho^{m-1}(p_m - 1) & \rho^{m-2}(p_m - 2) & \rho^{m-3}(p_m - 3) & \dots & 1 \end{bmatrix} \cdot \begin{bmatrix} \phi_1^m \\ \phi_2^m \\ \phi_3^m \\ \vdots \\ \phi_{p_m}^m \end{bmatrix} = \begin{bmatrix} \rho^m(1) \\ \rho^m(2) \\ \rho^m(3) \\ \vdots \\ \rho^m(p_m) \end{bmatrix} \quad (5)$$

2.2 Estimadores de Momentos dos Parâmetros do Modelo

Seja Z_t , $t = 1, 2, \dots$, uma série temporal de período s (um ano tem s períodos sazonais). O índice de tempo pode ser considerado uma função do ano T ($T = 1, \dots, N$) e do período sazonal m ($m = 1, \dots, s$): $t = (T - 1) s + m$, ilustrado na Figura 2.1.

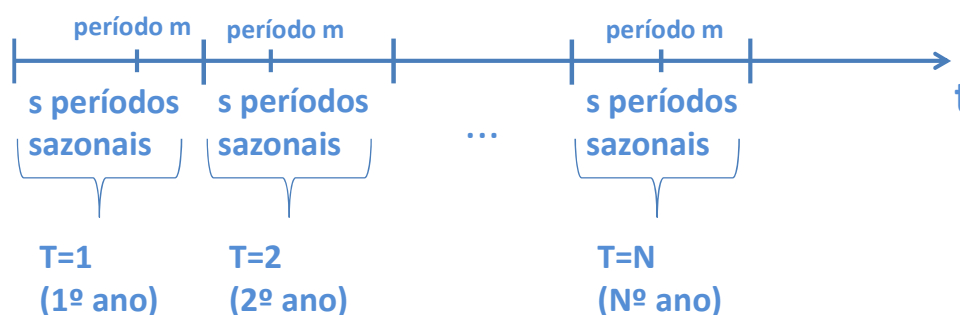


Figura 2.1 – Esquema ilustrativo relacionando tempo, ano e períodos sazonais.

As estimativas de momento dos parâmetros μ_m e σ_m^2 são:

$$\hat{\mu}_m = \frac{1}{N} \sum_{i=1}^N Z_{(i-1)s+m} \quad (6)$$

$$\hat{\sigma}_m^2 = \frac{1}{N} \sum_{i=1}^N (Z_{(i-1)s+m} - \hat{\mu}_m)^2 \quad (7)$$

Os coeficientes auto-regressivos periódicos $\phi_1^m, \phi_2^m, \dots, \phi_{p_m}^m$ são estimados resolvendo o sistema de equações lineares p_m dadas pela expressão (5), onde os coeficientes de auto-correlação periódicos da população são substituídos pelas estimativas dadas por (8).

$$\hat{\rho}^m(k) = \frac{1}{N} \sum_{i=1}^N \left(\frac{Z_{(i-1)s+m} - \hat{\mu}_m}{\hat{\sigma}_m} \right) \left(\frac{Z_{(i-1)s+m-k} - \hat{\mu}_m}{\hat{\sigma}_m} \right) \quad (8)$$

2.3 Identificação da Ordem do Modelo

A função de auto-correlação parcial (FACP) é outra forma de se representar a estrutura de dependência temporal de um modelo. É útil na identificação da ordem do modelo auto-regressivo que deve ser ajustado a uma série temporal histórica.

Hipel e McLeod [13] definiram a FACP periódica para um modelo PAR(p) de forma semelhante à feita para um modelo de auto-regressivo não periódico - AR(p). Para cada período m , a FACP periódica é definida pelo conjunto dos últimos parâmetros auto-regressivos dos modelos auto-regressivos de ordem k , $k = 1, \dots$, deste período m , usualmente denominados de ϕ_{kk}^m . Como decorrência dessa definição, a FACP do período m deve ser igual a zero após o lag p_m , quando a ordem do modelo de AR(p) nesse período é p_m [13]. Também como consequência dessa definição, a resolução de cada um

dos sistemas de equações de Yule-Walker dadas por (5) fornece ϕ_{kk}^m até lag $k = p_m$. Os valores da FACP teórica do período m podem ser calculados resolvendo-se k sucessivos sistemas de equações de Yule-Walker, onde $k = 1, \dots$. As auto-correlações parciais estimadas para cada período m podem ser obtidas substituindo em (5) as estimativas $\hat{\rho}^m(k)$ das autocorrelações teóricas e resolvendo-se sucessivos sistemas de equações de Yule-Walker com lags crescentes.

Na referência [14], pode-se encontrar uma definição mais geral, o coeficiente ϕ_{kk} é chamado de auto-correlação parcial lag k do processo estocástico Z_t , já que é igual à correlação parcial entre as variáveis Z_t e Z_{t-k} ajustadas para as variáveis intermediárias $Z_{t-1}, Z_{t-2}, \dots, Z_{t-k+1}$ (ou a correlação entre Z_t e Z_{t-k} não explicada por $Z_{t-1}, Z_{t-2}, \dots, Z_{t-k+1}$). Pode ser interpretada como a correlação condicionada entre Z_t e Z_{t-k} , dado o conhecimento das variáveis intermediárias $Z_{t-1}, Z_{t-2}, \dots, Z_{t-k+1}$, expressa em (9).

$$E \left[\left(\frac{Z_t - \mu_m}{\sigma_m} \right) \left(\frac{Z_{t-k} - \mu_{m-k}}{\sigma_{m-k}} \right) \mid Z_{t-1}, \dots, Z_{t-k+1} \right] \quad (9)$$

3 ABORDAGEM PROPOSTA PARA A MODELAGEM DE SÉRIES TEMPORAIS PERIÓDICAS

A abordagem proposta que será descrita na próxima seção introduz um novo termo na equação auto-regressiva periódica. Ela representa a média das últimas 12 afluições periódicas. No caso do modelo NEWAVE, que possui discretização mensal, representa a média das últimas 12 afluições. Este termo tem o objetivo de estender a memória da formulação do modelo PAR(p) tradicional.

3.1 Modelo Auto-Regressivo Periódico com Componente Anual – PAR(p)-A

O modelo Auto-regressivo periódico com componente anual, denominado de PAR(p₁, ..., p_s)-A pode ser escrito da seguinte forma:

$$\phi^m(B) \left(\frac{Z_t - \mu_m}{\sigma_m} \right) - \psi^m \left(\frac{A_{t-1} - \mu_{m-1}^A}{\sigma_{m-1}^A} \right) = a_t \quad (10)$$

Onde A_{t-1} representa a média das últimas 12 observações do processo estocástico Z_t com referência a (t-1).

$$A_{t-1} = \sum_{\tau=1}^{12} \frac{Z_{t-\tau}}{12} \quad (11)$$

A função de auto-correlação ρ^m(k) de Z_t pode ser obtida multiplicando-se ambos os lados da equação (10) por $\left(\frac{Z_{t-k} - \mu_{m-k}}{\sigma_{m-k}} \right)$ e aplicando o valor esperado a cada termo.

$$\rho^m(k) = \phi_1^m \rho^{m-1}(k-1) + \phi_2^m \rho^{m-2}(k-2) + \dots + \phi_p^m + \psi^m \rho_{Z,A}^{m-1}(k-1) \quad (12)$$

onde:

$$\rho_{Z,A}^{m-1}(k-1) = E \left[\left(\frac{A_{t-1} - \mu_{m-1}^A}{\sigma_{m-1}^A} \right) \left(\frac{Z_{t-k} - \mu_{m-k}}{\sigma_{m-k}} \right) \right] \quad (13)$$

Multiplicando ambos os lados da equação (10) por $\frac{A_{t-1} - \mu_{m-1}^A}{\sigma_{m-1}^A}$ e aplicando o valor esperado a cada termo, obtém-se uma equação adicional.

$$\rho_{Z,A}^{m-1}(-1) = \phi_1^m \rho_{Z,A}^{m-1}(0) + \phi_2^m \rho_{Z,A}^{m-1}(1) + \dots + \phi_p^m \rho_{Z,A}^{m-1}(p-1) + \psi^m \quad (14)$$

onde:

$$\rho_{Z,A}^{m-1}(-1) = E \left[\left(\frac{A_{t-1} - \mu_{m-1}^A}{\sigma_{m-1}^A} \right) \left(\frac{Z_t - \mu_m}{\sigma_m} \right) \right] \quad (15)$$

Assim como no modelo PAR(p), para cada período m, variando-se k de 1 a p_m na equação (12), obtém-se um conjunto de equações. A fim de se obter tantas equações quantos forem o número de parâmetros, a equação (14) deve ser adicionada ao conjunto original de equações lineares, conforme exemplificado em (16).

$$\begin{bmatrix} 1 & \rho^{m-1}(1) & \rho^{m-1}(2) & \dots & \rho^{m-1}(p_m - 1) & \rho_{Z,A}^{m-1}(0) \\ \rho^{m-1}(1) & 1 & \rho^{m-2}(1) & \dots & \rho^{m-2}(p_m - 2) & \rho_{Z,A}^{m-1}(1) \\ \rho^{m-1}(2) & \rho^{m-2}(1) & 1 & \dots & \rho^{m-3}(p_m - 3) & \rho_{Z,A}^{m-1}(2) \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ \rho^{m-1}(p_m - 1) & \rho^{m-2}(p_m - 2) & \rho^{m-3}(p_m - 3) & \dots & 1 & \rho_{Z,A}^{m-1}(p - 1) \\ \rho_{Z,A}^{m-1}(0) & \rho_{Z,A}^{m-1}(1) & \rho_{Z,A}^{m-1}(2) & \dots & \rho_{Z,A}^{m-1}(p - 1) & 1 \end{bmatrix} \cdot \begin{bmatrix} \phi_1^m \\ \phi_2^m \\ \phi_3^m \\ \vdots \\ \phi_p^m \\ \psi^m \end{bmatrix} = \begin{bmatrix} \rho^m(1) \\ \rho^m(2) \\ \rho^m(3) \\ \vdots \\ \rho^m(p) \\ \rho_{Z,A}^{m-1}(-1) \end{bmatrix} \quad (16)$$

3.2 Estimadores de Momentos dos Parâmetros do Modelo

As estimativas de momento dos parâmetros μ_m e σ_m^2 são dados pelas equações (6) e (7) respectivamente. De forma correlata, as estimativas de momento dos parâmetros μ_m^A e $\sigma_m^{(2)A}$ são dados pelas expressões (17) e (18) respectivamente.

$$\hat{\mu}_m^A = \frac{1}{N} \sum_{i=1}^N A_{(i-1)s+m} \quad (17)$$

$$\hat{\sigma}_m^{(2)A} = \frac{1}{N} \sum_{i=1}^N (A_{(i-1)s+m} - \hat{\mu}_m^A)^2 \quad (18)$$

Os coeficientes auto-regressivos de cada período m , $\phi_1^m, \phi_2^m, \dots, \phi_{p_m}^m$, e o coeficiente anual ψ^m são estimados resolvendo-se o sistema de (p_m+1) equações lineares dadas por (16), onde os coeficientes de auto-correlação periódicos são substituídos pelas estimativas de momento dadas por (8) e (19).

$$\hat{\rho}_{Z,A}^{m-1}(k-1) = \frac{1}{N} \sum_{i=1}^N \left(\frac{A_{(i-1)s+m-1} - \hat{\mu}_{m-1}^A}{\hat{\sigma}_{m-1}^A} \right) \left(\frac{Z_{(i-1)s+m-k} - \hat{\mu}_{m-k}}{\hat{\sigma}_{m-k}} \right) \quad (19)$$

3.3 Identificação da Ordem do Modelo

Para derivar a FACP do modelo PAR(p)-A deve-se aplicar a definição dada em [14]: ela representa a correlação entre as variáveis Z_t e Z_{t-k} condicionada aos valores intermediários $Z_{t-1}, Z_{t-2}, \dots, Z_{t-k+1}$ e A_{t-1} .

$$E \left[\left(\frac{Z_t - \mu_m}{\sigma_m} \right) \left(\frac{Z_{t-k} - \mu_{m-k}}{\sigma_{m-k}} \right) \mid Z_{t-1}, \dots, Z_{t-k+1}, A_{t-1} \right] \quad (20)$$

A auto-correlação parcial entre Z_t e Z_{t-k} pode ser obtida conforme [15] usando:

$$\bar{\Sigma} = \Sigma_{11} - \Sigma_{12} \Sigma_{22}^{-1} \Sigma_{21} \quad (21)$$

Onde:

Σ_{11} é a matriz de auto-covariância entre Z_t e Z_{t-k} ;

Σ_{12} é a matriz de auto-covariância entre $\{z_t, z_{t-k}\}$ e $\{z_{t-1}, z_{t-2}, \dots, z_{t-k+1}, A_{t-1}\}$;

Σ_{22} é a matriz de auto-covariância entre $\{z_{t-1}, z_{t-2}, \dots, z_{t-k+1}\}$ e A_{t-1} .

$\bar{\Sigma}$ é a matriz de auto-covariância parcial entre z_t e z_{t-k} condicionada a $\{z_{t-1}, z_{t-2}, \dots, z_{t-k+1}, A_{t-1}\}$.

A FACP do período m deve ser igual a zero a partir do lag p_m quando a ordem das componentes auto-regressivas neste período é p_m .

4 GERAÇÃO DE CENÁRIOS SINTÉTICOS - MODELOS PAR(P) E PAR(P)-A

Para gerar cenários sintéticos de aflúências é necessário, inicialmente, obter uma amostra de ruídos, a_t , não correlacionados temporalmente, uma para cada período de tempo e para cada cenário de aflúências. Atualmente, essas amostras são produzidas por amostragem seletiva a partir de uma distribuição Lognormal multivariada [16]. A Figura 4.1 ilustra o esquema de geração de cenários sintéticos em um período de tempo T.




Figura 4.1 – Esquema de geração de cenários sintéticos.

O método de amostragem seletiva consiste na aplicação de técnicas de agrupamento no processo de geração de cenários de aflúências. Nesse caso, as técnicas de agrupamento são usadas para obter amostras de séries de ruídos, a_t , multivariados e não correlacionados no tempo, usadas pelos modelos PAR(p) e PAR(p)-A.

O esquema adotado para geração de cenários sintéticos de aflúências pode ser resumido da seguinte forma:

- ✓ Obter as aflúências incrementais mensais históricas para cada usina hidrelétrica ou reservatório equivalente de energia. A vazão incremental a uma UHE pode ser obtida pela diferença entre a vazão total a uma UHE e a soma das vazões totais das UHEs imediatamente a montante;
- ✓ Escolher a ordem do modelo AR de cada período sazonal para cada usina hidroelétrica ou reservatório equivalente de energia, examinando as parcelas da FACP;
- ✓ Estimar os coeficientes dos modelos PAR(p) ou PAR(p)-A através das expressões (5) ou (16), respectivamente;
- ✓ Gerar uma amostra muito grande (por exemplo, 100.000) de resíduos a_t normais, não correlacionados temporalmente e espacialmente, usando amostragem aleatória simples onde são tratados como equiprováveis;
- ✓ Aplicar o método K-means para reduzir a cardinalidade da amostra original; os resíduos resultantes passam, então, a ser tratados como não equiprováveis;
- ✓ Uma distribuição Lognormal três parâmetros é ajustada aos resíduos espacialmente correlacionados;
- ✓ Os cenários sintéticos são obtidos usando-se as expressões (1) ou (10) conforme o modelo selecionado, PAR(p) ou PAR(p)-A respectivamente;
- ✓ A soma das aflúências incrementais ao longo da cascata de UHEs, em cada período e cenário, é realizada para obter as aflúências totais.

Maiores detalhes da metodologia para geração de cenários sintéticos são obtidos em [10] e [16].

5 APLICAÇÃO DA ABORDAGEM PROPOSTA

O desempenho do modelo de séries temporais proposto foi avaliado com uma configuração oficial do sistema interligado brasileiro, o PMO de janeiro de 2019. O PMO é realizado pelo ONS todos os meses, considerando um horizonte de cinco anos discretizado em períodos mensais. Os resultados apresentados foram obtidos com 2.000 cenários sintéticos mensais multivariados e referem-se aos três primeiros anos do horizonte do PMO. Esse número de cenários é atualmente utilizado nos estudos oficiais do setor elétrico brasileiro [17][18].

A configuração hidrelétrica foi representada por 11 REEs, agregando mais de 160 usinas hidrelétricas distribuídas pelos quatro subsistemas do país, conforme ilustrado na Figura 5.1. Os resultados apresentados referem-se aos mesmos três REEs apresentados na Figura 1.3, a saber, Sudeste, Nordeste e Itaipu, cada um com um regime hidrológico distinto.




Figura 5.1 Topologia do sistema elétrico brasileiro – 4 subsistemas e 11 REEs.

Como ilustração, a Tabela 5.1 apresenta as ordens dos modelos auto-regressivos escolhidas pelos modelos PAR(p) e PAR(p)-A para janeiro (estação chuvosa) e julho (estação seca). Observa-se que o modelo PAR(p)-A reduziu a ordem em janeiro para o REE Itaipu, e em julho para os REEs Itaipu e Nordeste. No entanto devemos lembrar que o modelo PAR(p)-A possui sempre um coeficiente adicional associado à média das 12 afluições anteriores. Esse coeficiente adicional contabiliza a contribuição de Z_{t-1} a Z_{t-12} , substituindo, às vezes, ordens mensais mais altas. Um comportamento semelhante é encontrado para outros meses e REEs, quando a auto-correlação anual é significativa. Observe que, se uma modelagem de periodicidade sazonal diferente da periodicidade mensal for usada, poderão aparecer resultados com comportamento diferente.

Tabela 5.1 Ordem selecionada dos modelos auto-regressivos dos meses de Janeiro e Julho dos modelos PAR(p) e PAR(p)-A.

	PAR(p)		PAR-A(p)	
	jan	jul	jan	jul
Southeast	1	2	1	2
Itaipu	6	3	6	1
Northeast	3	2	1	1

A Figura 5.2, a Figura 5.3 e a Figura 5.4 exibem as funções de auto-correlação amostral mensal histórica comparadas com àquelas produzidas pelos cenários sintéticos gerados pelos modelos PAR(p) e PAR(p)-A dos REEs Sudeste, Itaipu e Nordeste, nos meses de janeiro e julho.

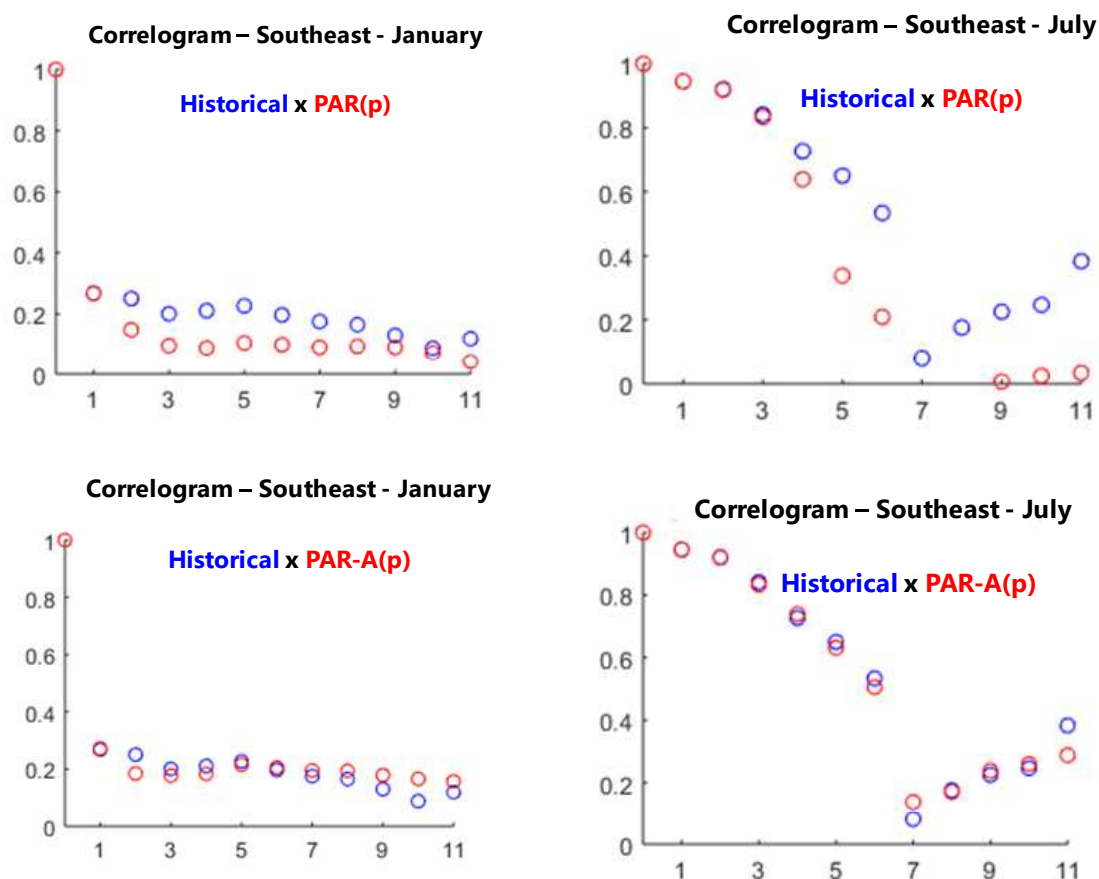


Figura 5.2 Função de auto-correlação mensal amostral das séries sintéticas produzidas pelos modelos PAR(p) e PAR(p)-A e da série histórica – REE Sudeste.

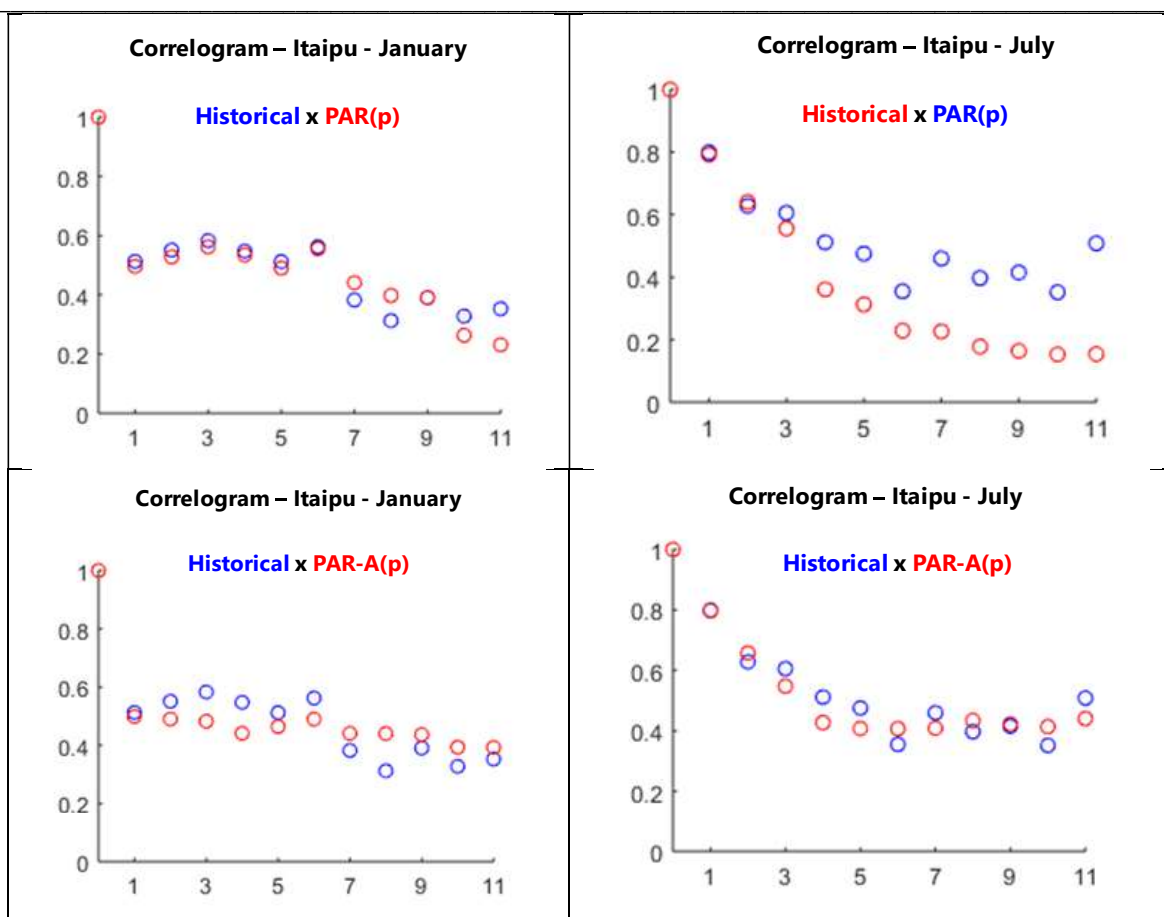
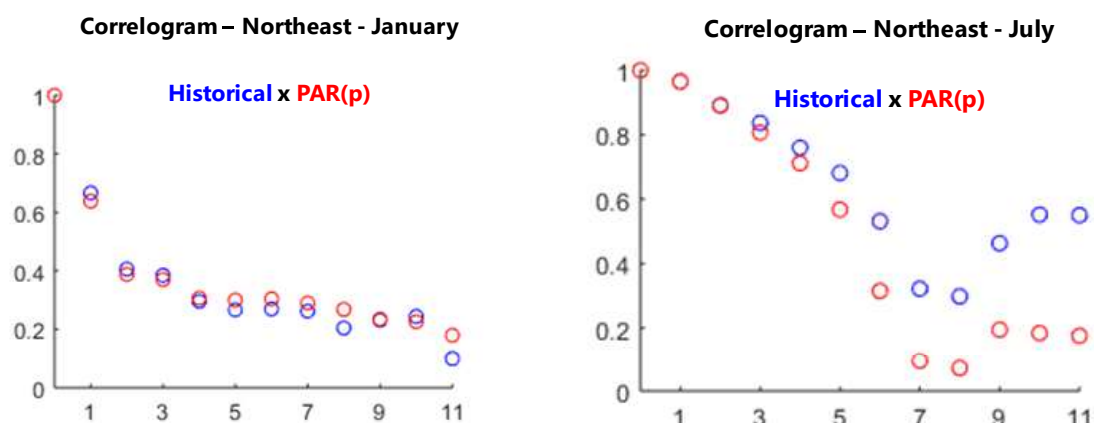


Figura 5.3 Função de auto-correlação mensal amostral das séries sintéticas produzidas pelos modelos PAR(p) e PAR(p)-A e da série histórica – REE Itaipu.



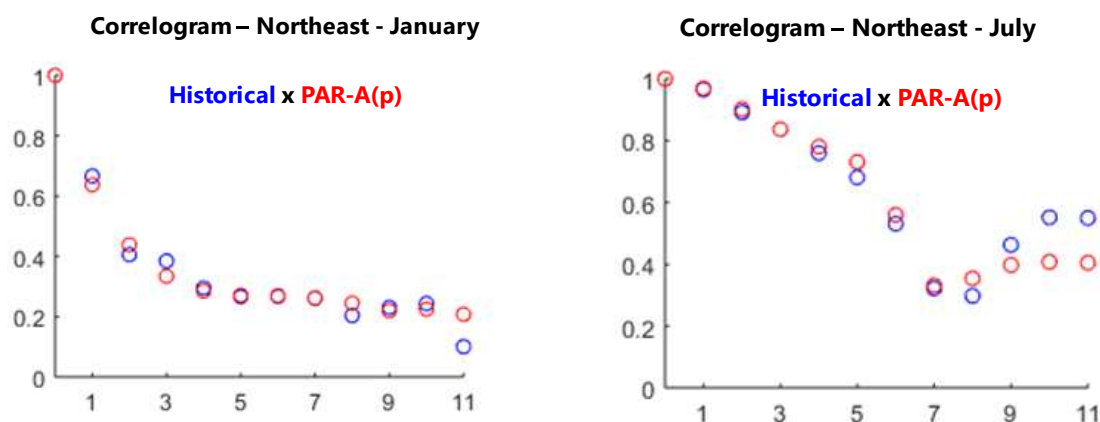


Figura 5.4 Função de auto-correlação mensal amostral dos modelos PAR(p) e PAR(p)-A e da série histórica – REE Nordeste.

Observa-se que, para lags inferiores às ordens do modelo, não há diferença significativa entre as funções mensais dos dois modelos e o histórico. Para lags maiores que as ordens do modelo, a função de auto-correlação amostral mensal produzida pelo modelo PAR(p) apresenta valores inferiores à do histórico. Já a função de auto-correlação amostral mensal produzida pelo modelo PAR(p)-A aproximou-se bem mais da função de auto-correlação mensal histórica, melhorando a memória do modelo mensal. Esse recurso contribui para preservar a auto-correlação anual lag um conforme ilustrado na **Erro! Fonte de referência não encontrada..** A auto-correlação anual observada nos cenários sintéticos produzidos pelo modelo PAR(p)-A é muito mais próxima da auto-correlação anual presente no registro histórico do que aquela observada nos cenários sintéticos produzidos pelo modelo PAR(p).




Figura 5.5 Auto-correlação anual obtida do registro histórico e dos cenários sintéticos de afluições

A Figura 5.6 ilustra as médias mensais do registro histórico de afliências e dos cenários sintéticos gerados pelos dois modelos periódicos, PAR(p) e PAR(p)-A para os REEs Sudeste, Itaipu e Nordeste.

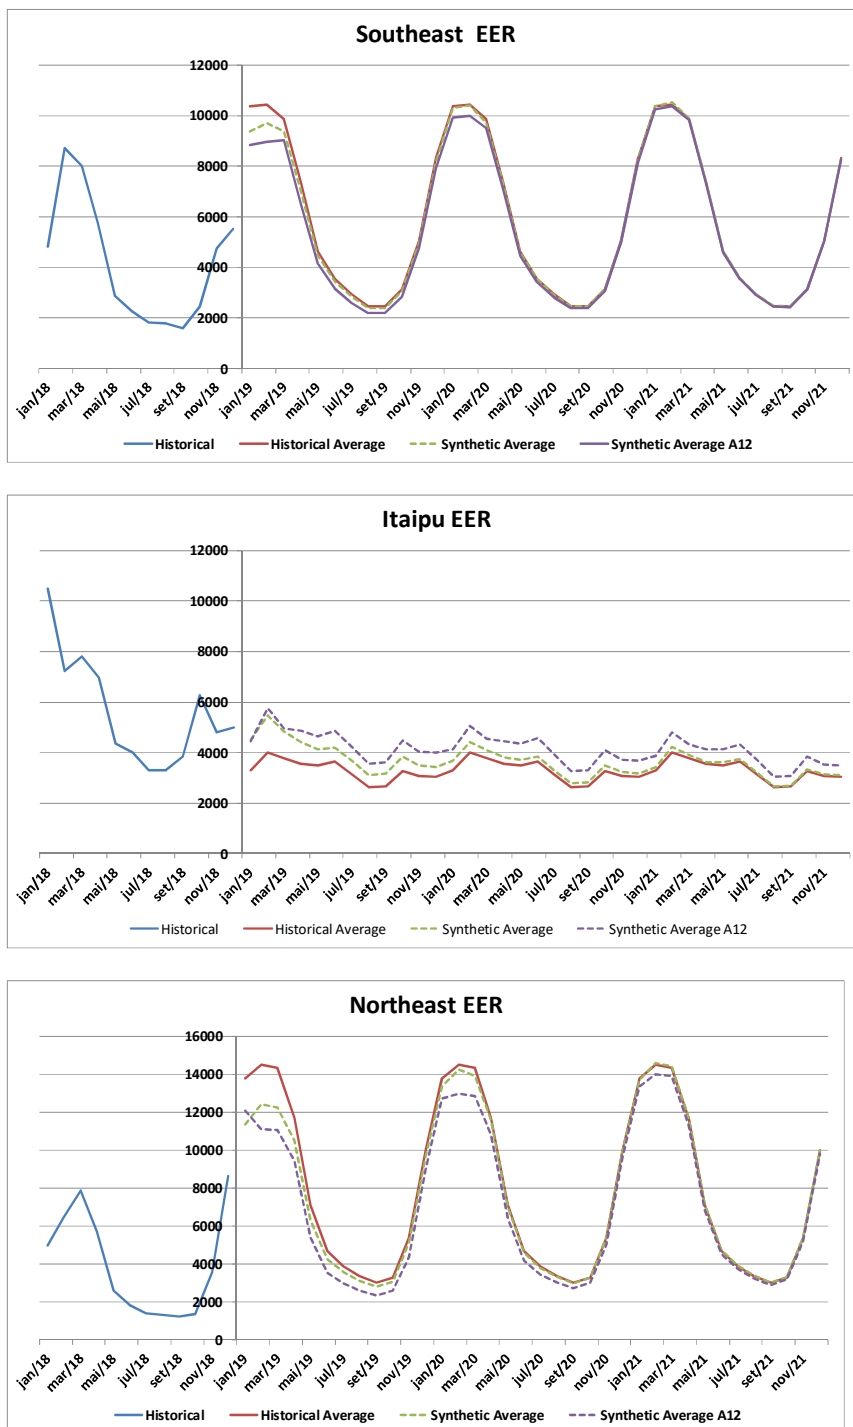


Figura 5.6 Comparação entre os cenários gerados pelos modelos PAR(p) e PAR(p)-A

A análise dessa figura permite avaliar o impacto do modelo proposto, PAR(p)-A, que teve por objetivo estender a memória do modelo PAR(p). A abordagem proposta reduz o otimismo do modelo tradicional PAR(p) quando as afluências anteriores eram muito baixas, como foi o caso dos REEs Sudeste e Nordeste e reduz o comportamento pessimista sempre que as afluências anteriores resultam de períodos mais favoráveis. Outros REEs apresentaram comportamento similar.

6 CONCLUSÕES

Nos países que apresentam elevada participação da fonte hidrelétrica em suas matrizes elétricas, como é o caso do Brasil, o planejamento da operação é baseado em modelos de otimização que requerem a geração de cenários sintéticos de afluências hidrológicas por meio de modelos que representam o comportamento periódico intrínseco dessas afluências. No caso do Brasil, a modelagem PAR(p) é empregada nos modelos NEWAVE, DECOMP e GEVAZP, desenvolvidos pelo CEPEL, para representar as incertezas nas afluências, quer na forma de vazões - quando a representação das UHEs se dá individualmente, ou de energia - quando se utiliza reservatórios equivalentes de energia. Por sua vez, estes modelos são utilizados pelo ONS na elaboração Programa Mensal da Operação Energética - PMO, e do Plano da Operação Energética - PEN; pela CCEE para o cálculo do Preço de Liquidação das Diferenças - PLD; e pelo MME e EPE na elaboração do Plano Decenal de Expansão de Energia - PDE).

Verifica-se nos anos recentes um comportamento atípico das afluências em algumas regiões do Brasil: a região Nordeste e parte da região Sudeste estão passando por um período de seca prolongado, enquanto a região Sul está atravessando um longo período de chuvas acima da média. Durante esta fase, a média dos cenários sintéticos de afluências mensais gerados pelo modelo PAR (p) tem apresentado o prognóstico usual de retorno à média histórica, aproximadamente em alguns meses (geralmente 6 meses), embora o regime incomum persistisse. Esse comportamento indica que o modelo de séries temporais PAR(p) pode ser aprimorado para incorporar mais memória nos cenários de afluências gerados

Neste relatório foi proposta uma abordagem para ampliar a memória do modelo PAR(p), denominada modelo Auto-Regressivo Periódico com Componente Anual - PAR(p)-A, por meio da inclusão de um novo termo na equação de auto-regressão de cada período sazonal, dado pela média das 12 últimas afluências. Adicionalmente, foi apresentado o cálculo das estimativas dos parâmetros bem como a identificação da ordem do modelo proposto.

A abordagem proposta foi aplicada ao Programa Mensal de Operação do Mês de janeiro de 2019. Os resultados obtidos mostraram que a inclusão deste novo termo na equação de auto-regressão periódica - modelo PAR(p)-A melhorou, de fato, a memória do modelo PAR (p) original e conseguiu reproduzir com mais acurácia a função de autocorrelação mensal das afluências.

7 REFERÊNCIAS

- [1] O.B. Fosso, A. Gjelsvik, A. Haugstad, B. Mo, I. Wangensteen, "Generation scheduling in a deregulated system. The norwegian case", IEEE Transactions on Power Systems, v. 14, n. 1, pp. 75-81, Feb. 1999.
- [2] M.E.P. Maceira, L.A. Terry, F.S. Costa, J.M. Damázio, A.C.G. Melo, "Chain of Optimization Models for Setting the Energy Dispatch and Spot Price in the Brazilian System", 14th Power System Computation Conference - PSCC, Seville, Spain, 2002.
- [3] E. Gil, J. Bustos, H. Rudnick, "Short term hydrothermal generation scheduling model using a genetic algorithm", IEEE Transactions on Power Systems, v. 18, n. 4, pp. 1256-1264, Nov. 2003.
- [4] M.V.F. Pereira, L.M.V.G. Pinto, "Multi Stage Stochastic Optimization Applied to Energy Planning", Mathematical Programming 52, 1991.
- [5] M.E.P. Maceira, "Programação dinâmica Dual Estocástica considerando a Correlação Temporal das Afluências aos Reservatórios", Relatório Técnico CEPEL 237/93, Rio de Janeiro, Brazil, 1993.
- [6] M.E.P. Maceira, D.D.J. Penna, A.L. Diniz, R.J. Pinto, A.C.G. Melo, C.V. Vasconcellos, C.B. Cruz, "Twenty Years of Application of Stochastic Dual Dynamic Programming in Official and Agent Studies in Brazil – Main Features and Improvements on the NEWAVE Model", 20th PSCC, Dublin, Ireland, June 2018.
- [7] A.L. Diniz, F.S. Costa, M.E.P. Maceira, T.N. Santos, L.C. Brandão, R.N. Cabral, "Short/Mid-Term Hydrothermal Dispatch and Spot Pricing for Large-Scale Systems - the Case of Brazil", 20th Power Systems Computation Conference, Dublin, Ireland, June 2018.
- [8] N. V. Arvantidis, J. Rosing, "Composite representation of multireservoir hydroelectric power system", IEEE Transactions on Power Apparatus and Systems, v. 89, n. 2, pp. 319-326, Feb. 1970.
- [9] M.E.P. Maceira, V.S. Duarte, D.D.J. Penna, M.P. Tcheou, "An approach to consider hydraulic coupled systems in the construction of equivalent reservoir model in hydrothermal operation planning", PSCC 2011.
- [10] M.E.P. Maceira, C.V. Bezerra, Stochastic Streamflow Model for Hydroelectric Systems, 5th PMAPS, Vancouver, Canada, September 1997.
- [11] J.D. Salas, J.W. Delleur, V. Yevjevich, W.L. Lane, "Applied Modeling of Hydrologic Time Series", *Water Resources Publications*, 1980.
- [12] P.H. Franses, R. Paap, Periodic Time Series Models, Oxford University Press, 2006.
- [13] W.H. Hippel, A.I. Mcleod, "Time series modeling of water resources and environmental system. Elsevier. 1994

-
- [14] G.E.P. Box, G.M. Jenkins, G.C. Reinsel, G M. Ljung, Time Series Analysis – Forecasting and Control, 5th edition, Wiley, 2016.
- [15] W.H. Greene, Econometric Analysis, 3th edition, Prentice-Hall, 1997.
- [16] D.D.J. Penna, M.E.P. Maceira, J.M. Damázio, "Selective Sampling Applied to Long-Term Hydrothermal Generation Planning ", 17th PSCC, Stockholm, Sweden August 2011.
- [17] http://www.ons.org.br/AcervoDigitalDocumentosEPublicacoes/SUMARIO_EXECUTIVO_PMO_202005_REV1.pdf#search=pmo.
- [18] <http://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/plano-decenal-de-expansao-de-energia-2029>.