




Impactos das Mudanças Climáticas no Planejamento da Geração de Energia Elétrica

Séries Climáticas Influencia Mudanças Climáticas

Como empresa federal de utilidade pública, a Deutsche Gesellschaft für Internationale Zusammenarbeit (GIZ) GmbH apoia o Governo Federal da Alemanha em seus objetivos na área de cooperação internacional.

Publicado por

Projeto Sistemas de Energia do Futuro – Diretor do Projeto – Daniel Almarza

Deutsche Gesellschaft für Internationale Zusammenarbeit (GIZ) GmbH

Deutsche Gesellschaft für Internationale Zusammenarbeit (GIZ) GmbH Sede social Bonn e Eschborn, Alemanha SCN Quadra 1 Bloco C Sala 1501, 15 andar, Ed. Brasília Trade Center. CEP 70711-902, Brasília-DF, Brasil Telefone: (61) 2101-2170 www.giz.de/brasil	Empresa de Pesquisa Energética Escritório-central (corpo técnico e base operacional) Praça Pio X, n. 54 – 5º andar, Centro Rio de Janeiro – RJ – CEP: 20091-040 Tel.: (21) 3512-3100 www.epe.gov.br
--	--

Coordenação

Gustavo Ponte (EPE)
Roberto Luis Castro Thome (GIZ BR)
Letícia Benso (GIZ BR)
Rafael Kelman (PSR)

Autores:

Julio Alberto (PSR)
Rafael Kelman (PSR)

(As informações podem ser alteradas de acordo com a necessidade do projeto e consulta prévia ao NCPD)

O Projeto Sistemas de Energia do Futuro é fruto da Cooperação Brasil-Alemanha para o Desenvolvimento Sustentável, executado pela Deutsche Gesellschaft für Internationale Zusammenarbeit (GIZ) GmbH em parceria com o Ministério de Minas e Energia (MME) e com recursos do Ministério Federal da Cooperação Econômica e do Desenvolvimento (BMZ) da Alemanha. O projeto tem como objetivo principal apoiar a integração das energias renováveis e eficiência energética no sistema brasileiro de energia.

Rio de Janeiro, 23 de janeiro de 2025.

1. Mudanças Climáticas e os Desafios para o Setor Elétrico Brasileiro

As mudanças climáticas representam um desafio sem precedentes com impactos diretos no setor elétrico brasileiro, fortemente dependente de recursos naturais renováveis. É essencial compreender como essas mudanças afetam os regimes de vento, irradiação solar e das chuvas e suas consequências na disponibilidade de água nos reservatórios hidrelétricos e de recursos para a geração de energia elétrica. Não menos importante, o aumento de temperatura em regiões do Brasil provoca uma mudança no perfil de consumo e na maioria dos casos, uma maior demanda por energia elétrica.

Nesse contexto, a Empresa de Pesquisa Energética (EPE) em parceria com a Cooperação Brasil Alemanha para o Desenvolvimento, por meio da Deutsche Gesellschaft für Internationale Zusammenarbeit (GIZ) GmbH, e sob a coordenação do Ministério de Minas e Energia e com recursos do Ministério Alemão para Cooperação Econômica e Desenvolvimento (BMZ) apresenta o estudo: **“Impactos das Mudanças Climáticas no Planejamento da Geração de Energia Elétrica”**.

O estudo contou com a participação de relevantes instituições do setor elétrico e de pesquisa, como o Instituto de Pesquisas Espaciais (INPE), a Agência Nacional de Águas (ANA) e o Operador Nacional do Sistema (ONS), que aportaram, de forma significativa, conhecimento sobre os impactos das mudanças climáticas na geração de energia elétrica.

O estudo consolida projeções climáticas e modelagens de recursos energéticos para o Brasil, além de simular cenários selecionados de expansão e operação do sistema elétrico brasileiro sob o impacto das mudanças do clima. O objetivo é oferecer um diagnóstico sobre o comportamento da matriz elétrica diante das mudanças do clima, permitindo indicações para um planejamento mais resiliente, justo e adaptado a um futuro incerto.

Além dos aspectos técnicos energéticos, o projeto incorpora dimensões sociais, abordando temas como a pobreza energética e a transição energética justa, com atenção especial às regiões vulneráveis, como o Nordeste.

O estudo utiliza projeções do projeto CMIP6 (Coupled Model Intercomparison Project Phase 6), que embasam os relatórios do Painel Intergovernamental sobre Mudança do Clima (IPCC) e, a partir desses insumos, apresenta três possíveis configurações futuras da matriz elétrica e suas respectivas simulações de geração, avaliando os impactos climáticos sobre a operação do Sistema Interligado Nacional (SIN).

Os resultados mostram que manter o planejamento baseado no clima do passado poderá gerar maiores custos operacionais, riscos de interrupções no fornecimento de energia e agravamento das desigualdades sociais. Por outro lado, a adaptação antecipada se revela técnica e economicamente viável, além de ser essencial para proteger os mais vulneráveis.

Por fim, o estudo busca se consolidar como referência no aspecto do planejamento energético, oferecendo subsídios técnicos e regulatórios para políticas públicas que tornem o setor elétrico brasileiro mais eficiente, resiliente e preparado para os desafios climáticos. Além de apresentar para o conhecimento coletivo possíveis consequências dessas mudanças, por parte de agentes do setor e da sociedade em geral.

Séries Climáticas Sob a Influência das Mudanças Climáticas

Índice

1. Mudanças Climáticas e os Desafios para o Setor Elétrico	3
2. Lista de Abreviaturas	6
3. Introdução	7
4. Metodologia	8
Representação da Geração Hidrelétrica.....	8
Representação da Geração de Energia Renovável Variável - Eólica e Solar	15
5. Avaliação da Performance dos Modelos GCM	25
Análise da Temperatura	29
Análise da Precipitação	35
Análise da Velocidade do Vento a 10m de altura	43
Análise da Radiação Solar	48
Análise Combinada	57
6. Apresentação e Análise Estatística das Séries Geradas	59
Séries de Geração Hidrelétrica	60
Séries de Geração Eólica	67
Séries de Geração Solar	70
7. Impacto das Mudanças Climáticas sobre Bioeletricidade.....	73
8. Referências	76

2. Lista de Abreviaturas

ARp	Autoregressive Periodic/Modelo estocástico auto-regressivo periódico
CMIP6	Coupled Model Intercomparison Project Phase 6
DJF	Período de três meses compreendendo dezembro, janeiro e fevereiro
ERV	Energia renovável variável
GCM	Global Circulation Models/Modelos globais de circulação
GSEE	Global Solar Energy Estimation/Modelo de estimação de energia solar
JJA	Período de três meses compreendendo junho, julho e agosto
MLT	Média de longo termo
MAM	Período de três meses compreendendo março, abril e maio
NEX-GDDP	NASA Earth Exchange Global Daily Downscaled Projections
PMO	Programação mensal de operação
SDDP	Stochastic Dual Dynamic Programming
SIN	Sistema interligado nacional
SON	Período de três meses compreendendo setembro, outubro e novembro
SSP compartilhados	Shared Socioeconomic Pathways/Cenários socioeconômicos futuros
VWF	Virtual Wind Farm/Modelo de usina eólica

3. Introdução

O Produto 2 deste projeto, foco deste relatório, concentra-se na análise de variáveis climáticas para os períodos históricos (1980-2014) e projeção futuras (2040-2070), com base nos cenários de mudança climática SSP245 e SSP585 do CMIP6. Tais cenários fornecem uma perspectiva fundamentada sobre potenciais alterações nos padrões climáticos e suas implicações para o setor energético.

Para oferecer uma análise abrangente, o relatório é estruturado nas seguintes partes principais:

Metodologia: Esta seção detalha os procedimentos adotados para gerar as séries de disponibilidade de geração (hidrelétrica, a partir das séries de vazões, e fontes renováveis variáveis) a partir dos modelos climáticos globais (GCMs) escolhidos e cenários de emissão.

Avaliação da Performance dos Modelos GCM: Nesta seção, será realizada uma análise da capacidade dos modelos GCM escolhidos para representar a climatologia das regiões de interesse. Essa avaliação busca assegurar que as projeções dos modelos sejam representativas e adequadas para o contexto brasileiro, abordando a precisão na simulação das variáveis climáticas.

Apresentação e Análise Estatística das Séries Geradas: Esta seção apresenta as séries de dados geradas a partir do emprego dos cenários dos modelos GCM e realiza uma análise estatística aprofundada.

Impacto das Mudanças Climáticas sobre Bioeletricidade: Por fim, esta seção apresenta uma revisão bibliográfica preliminar de como as mudanças climáticas poderiam ser consideradas na representação da bioeletricidade.

4. Metodologia

Esta seção apresenta em detalhe os procedimentos adotados para a geração das séries de disponibilidade de energia com base nos modelos climáticos globais selecionados e nos cenários de emissões considerados. A seção está organizada em duas subseções: a primeira aborda os métodos utilizados para representar a geração hidrelétrica, enquanto a segunda descreve os procedimentos empregados para modelar a geração de energia renovável variável.

Destaca-se que para o processo de geração de cenários de energia, os insumos utilizados são as projeções das variáveis climáticas disponibilizadas dentro do projeto NEX-GDDP (*NASA Earth Exchange Global Daily Downscaled Projections*), e não as projeções originalmente disponibilizadas pelos próprios modelos GCM participantes do CMIP6. A principal razão desta escolha por parte do projeto foi manter a compatibilidade com a fonte de dados utilizada pela ANA para gerar os cenários de vazões afluentes, que são aproveitados aqui neste estudo.

O uso do NEX-GDDP apresenta vantagens em relação as projeções originais dos modelos CMIP6. Primeiramente, o NEX-GDDP oferece dados em alta resolução espacial (0,25° x 0,25°), o que possibilita análises mais detalhadas e regionais, enquanto os modelos CMIP6 possuem resoluções mais grosseiras e não padronizadas. O NEX-GDDP aplica técnicas de *downscaling* estatístico para corrigir vieses nos dados originais, melhorando a representatividade das projeções climáticas.

Representação da Geração Hidrelétrica

O Sistema Interligado Nacional (SIN) depende intensamente dos recursos hídricos, dado que uma grande parte da geração de eletricidade no Brasil provém de fontes hidrelétricas¹. Essa característica torna essencial que os processos de planejamento da operação e expansão do sistema sejam apoiados por modelos que consigam simular com razoável precisão, as possíveis vazões futuras dos rios e reservatórios. Dada a grande incerteza das afluências, o uso de modelos estocásticos é essencial para se gerar cenários sintéticos de vazões afluentes às hidrelétricas para as condições hidrológicas futuras.

Nesse contexto, o modelo autorregressivo periódico (ARp) é amplamente utilizado, pois ele consegue capturar a memória hidrológica da série temporal de vazões, onde as condições atuais estão diretamente relacionadas às condições passadas, permitindo capturar também a correlação espacial que existe entre os diferentes rios e bacias hidrográficas que alimentam as hidrelétricas que compõem o SIN.

De maneira resumida, um modelo ARp pode ser caracterizado como:

$$\left(\frac{QQ_t - \mu_p}{\sigma_p} \right) = \sum_{m=1}^M \phi_m \left(\frac{QQ_{t-m} - \mu_{p-m}}{\sigma_{p-m}} \right) + \varepsilon_t$$

Onde,

QQ_t é a vazão no estágio t ;

μ_p é a média estimada para a vazão para o mês p correspondente ao estágio t ;

σ_p é o desvio padrão estimado para a vazão para o mês p correspondente ao estágio t ;

M é a ordem do modelo autorregressivo;

ϕ_m é o coeficiente autorregressivo estimado para o atraso m ;

QQ_{t-m} é a vazão em um estágio anterior ($t-m$);

μ_{p-m} é a média estimada para a vazão para o mês $p-m$;

σ_{p-m} é o desvio padrão estimado para a vazão para o mês $p-m$;

$\varepsilon\varepsilon_t$ é o resíduo, que contém a parcela da vazão não explicada pelo modelo;

Embora existam modelos autorregressivos não lineares, mais flexíveis para representar o processo estocástico das condições hidrológicas, os requisitos de convexidade necessários para resolver problemas de programação dinâmica estocástica, típicos do planejamento da operação e expansão, com o algoritmo SDDP (*Stochastic Dual Dynamic Programming*), que será aplicado na simulação operativa do SIN, fazem com que o modelo ARp se destaque como a melhor opção, dado que ele permite manter a linearidade exigida pelo método ao mesmo tempo em que captura características estatísticas essenciais do comportamento das vazões afluentes.

No entanto, no contexto da representação dos impactos das mudanças climáticas, uma das principais limitações do modelo ARp é sua memória curta, o que dificulta a captura de aspectos importantes desse fenômeno, como a ruptura de padrões e tendências ao longo do tempo. Em outras palavras, o ARp é projetado para representar processos estritamente estacionários, sendo menos eficaz na incorporação de dinâmicas de longo prazo associadas às mudanças climáticas.

Uma premissa simples que ajuda a contornar esta limitação é assumir que o processo estocástico modelado é estacionário dentro do horizonte futuro analisado. Isso significa assumir que as distribuições de probabilidade das variáveis climáticas que influenciam as vazões afluentes são estacionárias ao longo do intervalo definido de 2040 a 2070, e dessa forma, este processo pode ser representado por um modelo ARp (para cada usina), cujos parâmetros refletem a resposta média das vazões afluentes às variações de precipitação e temperatura durante esse período.

Considerando que, dentro do escopo do projeto, é necessário ainda avaliar dois cenários distintos de mudança climática, SSP245 e SSP585, seriam estimados modelos ARp diferentes para cada cenário.

A **Figura 1** apresenta uma visão geral do processo, ainda sem detalhar as especificidades de cada subatividade, mas já destacando que o impacto das mudanças climáticas é incorporado por meio da calibração do modelo estocástico ARp com base nas projeções futuras de vazão, calculadas a partir das projeções dos modelos climáticos.




Figura 1: Visão geral do processo, assumindo estacionariedade

A abordagem de assumir uma premissa de estacionariedade do período, embora seja bastante utilizada na literatura, apresenta algumas desvantagens no contexto específico do planejamento da geração do setor elétrico brasileiro. Em especial, a limitação para representação de eventos extremos causados principalmente por uma sequência de anos hidrológicos desfavoráveis.

Devido à grande capacidade de armazenamento do sistema hidrelétrico, as dinâmicas de transições entre períodos de esvaziamento e enchimento dos reservatórios torna-se um aspecto crucial para a otimização eficiente dos recursos. Assim, não basta apenas representar as mudanças na frequência de ocorrência de períodos hidrológicos desfavoráveis; é igualmente importante capturar, em alguma magnitude, a cronologia desses eventos.

Embora os cenários futuros de vazões, derivados das projeções climáticas, possam oferecer informações relevantes sobre a expectativa de mudanças nas taxas de transição entre os anos hidrológicos críticos, essas informações podem ser diluídas ou até completamente perdidas quando todos os eventos são consolidados em uma única distribuição representativa de um período, modelada por um único ARP.

Para superar essa limitação, uma abordagem alternativa é representar, para cada modelo GCM, a dinâmica dos cenários de mudanças climáticas por meio de um encadeamento de múltiplos modelos ARP, em vez de utilizar um único modelo. Essa abordagem permite que as transições projetadas pelos GCMs ao longo do horizonte de análise sejam traduzidas em transições entre diferentes modelos ARP dentro do conjunto.


Assim, o detalhamento a seguir da metodologia será apresentado de forma a incluir a capacidade de representar múltiplos modelos ARP, considerando que a abordagem tradicional de um único modelo ARP, que assume um intervalo estacionário, é um caso particular dessa metodologia (nesse caso, presume-se que o número de modelos encadeados seja igual a 1). O custo-benefício dessa representação ampliada poderá ser avaliado posteriormente nas análises dos cenários de operação do SIN, permitindo identificar a estratégia mais eficaz a ser adotada nas etapas subsequentes do projeto.

A premissa de que cada cenário de mudança climática (SSP245 e SSP585) descreve uma trajetória determinística, permitindo que os modelos ARp sejam encadeados cronologicamente, é pouco realista, considerando o alto nível de incerteza sobre a trajetória real das emissões, de outras forçantes climáticas e a resposta efetiva das variáveis climáticas. Para mitigar este problema, propõe-se a adoção de um modelo probabilístico para a representação das transições entre os diferentes modelos ARp encadeados.


Na Figura 2 é apresentada de maneira ilustrativa esta diferença conceitual. Na parte A, é mostrado como seria uma abordagem de transição puramente cronológica, enquanto na parte B é mostrado a incorporação do aspecto probabilístico das transições.

Figura 2: Conjuntos de modelos ARp

A



B



A estratégia sugerida para a subdivisão desses modelos é utilizar o aumento de temperatura associado a cada cenário como um proxy para formar os diferentes agrupamentos. Essa abordagem não só desvincula o aspecto cronológico, como também permite combinar os distintos cenários (SSP245 e SSP585) em uma única cadeia de modelos.

Na Figura 3 é apresentado um exemplo de aplicação desta estratégia para o modelo ACCESS_CM2², na qual, do lado esquerdo são apresentadas as trajetórias dos dois cenários, enquanto do lado direito são apresentados os grupos resultantes.

² Dix, Martin; Mackallah, Chloe; Bi, Daohua; Bodman, Roger; Marsland, Simon; Rashid, Harun; Woodhouse, Matthew; Druken, Kelsey (2020). CSIRO-ARCCSS ACCESS-CM2 model output prepared for CMIP6 DAMIP.




Figura 3: Clusterização do aumento de temperatura para o modelo ACCESS_CM2

A partir da identificação destes grupos, é possível estimar as probabilidades estacionárias de cada grupo, assim como as probabilidades de transição anual entre estes grupos, resultando na definição de um modelo de Markov que representa a variação dos parâmetros dos parâmetros ARp em função do cluster que caracteriza o aumento médio de temperatura.

Para exemplificação do processo, na Figura 4 é apresentado este modelo de transições para o modelo ACCESS_CM2 (para manter a clareza do diagrama, apenas as transições iniciadas a partir dos estados 2 e 3 foram destacadas na figura).




Figura 4: Grupos e probabilidades dos grupos para o modelo ACCESS_CM2

É importante ressaltar que esta abordagem de representar transições anuais dos parâmetros ARp por modelos de Markov é totalmente aderente a metodologia do SDDP/Optgen, conforme será melhor descrito no Produto 5. Isso permite que o planejamento da operação do SIN seja realizado considerando cenários que apresentam uma maior diversificação e melhor representatividade dos

extremos causados pelas mudanças climáticas.

Uma vez separados quem são os grupos, o próximo passo é efetivamente estimar os parâmetros ARp de cada grupo, com o objetivo de identificar o quanto as variações nas variáveis climáticas (em relação ao período histórico de referência) impactam nas vazões afluentes dentro de cada grupo.

As variáveis climáticas de maior importância para a modelagem da vazão são as precipitações mensais e as temperaturas máximas e mínimas mensais. Elas alimentam modelos hidrológicos (modelo chuva-vazão) que definem funções de transferência capazes de simular a vazão a partir destas variáveis climáticas. Assim, o procedimento fundamental para transferir o impacto das mudanças climáticas das variáveis climáticas para as vazões consiste em aplicar a distorção observada na precipitação e temperatura (em relação ao histórico) aos dados de entrada do modelo hidrológico, e então medir a variação nas vazões simuladas pelo modelo.

Na Figura 5 são apresentadas as distribuições de probabilidade da precipitação anual para cada um dos grupos do modelo de Markov (os mesmos grupos apresentados acima), bem como da precipitação anual do histórico, na visão do modelo GCM avaliado. Observa-se que o impacto na precipitação é diferente para cada um dos grupos.




Figura 5: Distribuição de probabilidade da precipitação para cada um dos grupos

No contexto de projeto, os cenários de vazões serão fornecidos pela Agência Nacional de Águas e Saneamento Básico (ANA), provenientes do estudo Impacto da Mudança Climática nos Recursos Hídricos do Brasil – 2023/2024, mas para manter a metodologia autocontida neste documento, o modelo SMAP³, que é também o modelo hidrológico base aplicado pela ANA, será brevemente apresentado a seguir.

Uma visão esquemática do modelo SMAP é apresentada na Figura 6.

Ele é constituído de dois reservatórios matemáticos: reservatório do solo + reservatório subterrâneo e é formulado por um conjunto de funções de transferência que relaciona estes reservatórios com as variáveis de entrada: precipitação e evapotranspiração, produzindo como

³ Nota técnica ONS 0097/2018-RV3 - APLICAÇÃO DO MODELO SMAP/ONS PARA PREVISÃO DE VAZÕES NO ÂMBITO DO SIN

variáveis de saída: um escoamento superficial mais um escoamento base, que somados constituem a vazão final.




Figura 6: Visão esquemática do modelo hidrológico SMAP (versão mensal)

Os parâmetros que definem o modelo para cada sub-bacia são:

Sat – Capacidade de saturação do solo (mm)

Pes – Parâmetro de escoamento superficial (adimensional)

Crec – Coeficiente de recarga (adimensional)

Kk – Constante de recessão (1/mês)

Ad – Área da bacia (m²)

Tem-se também os seguintes parâmetros extras para auxiliar na compatibilização da distribuição espacial dos postos de medição de chuva e evapotranspiração:

Pcof – Ajuste da chuva média da bacia

Ecof – Ajuste da evapotranspiração média da bacia

As funções de transferência do modelo são:

$$E_s = f_1 \cdot P$$

$$E_r = f_2 \cdot E_p$$

$$R_{ec} = f_3 \cdot R_{solo}$$

$$E_b = f_4 \cdot R_{sub}$$

A vazão estimada a cada mês é:

$$QQ = (E_s + E_b) \cdot A_d /$$

Onde,

2630

$$f_1 = T_u^{Pes}$$

$$f_2 = T_u$$

$$f_3 = Crec \cdot T_u^4$$

$$f_4 = 1 - Kk$$

$$T_u = R_{solo}/Sat$$

A precipitação P é obtida a partir da precipitação média da bacia, sendo ainda ponderada pelo fator P_{cof} , ajustado pelo modelo.

A evapotranspiração potencial Ep é calculada a partir das séries de temperaturas mínimas e máximas da sub-bacia, utilizando o método de Hargreaves e Samani⁴, sendo ainda ponderada pelo fator E_{cof} , ajustado pelo modelo.

Considerando que os clusters de temperatura ($C=1$ até N_c) já foram definidos para os modelos GCM, o procedimento completo para geração de cenários hidrológicos representando o impacto das mudanças climáticas pode ser então consolidado como:

Parte i: Independente do modelo GCM utilizado;

1. Estimação dos modelos ARp a partir dos dados históricos de vazão;

Parte ii: Dependente do modelo GCM utilizado;

2. Para cada cluster C e hidroelétrica;
 - a. A partir da projeção de temperatura do modelo GCM, identificar os anos associados ao cluster C ;
 - b. Estimação dos modelos ARp a partir das projeções de vazões futuras da ANA, considerando apenas os subconjuntos de anos identificados para o cluster C ;
 - c. Caracterização do modelo ARp-C modificado como:

$$\left(\frac{Q_t - \kappa_C \mu_t}{\kappa_C \sigma_t} \right) = \sum_{m=1}^M \phi_m \left(\frac{Q_{t-m} - \kappa_C \mu_{t-m}}{\kappa_C \sigma_{t-m}} \right) + \varepsilon_t$$

Onde κ_C , representa a mudança relativa da média da vazão no cluster C , em relação ao período histórico de referência;

3. Geração de cenários por meio da simulação estocástica da cadeia de Markov e dos processos ARp internos a cada cluster da cadeia;
 - a. Para cada estágio t e cenário s , sorteia o novo estado a partir dos estados conhecidos em $t-1$, cenário s , e das probabilidades de transição entre os clusters (transição de $C(t-1,s)$ para $C(t,s)$);
 - b. Dado o estado sorteado, $C(t,s)$, sorteia as vazões do cenário considerando os parâmetros do modelo ARp- $C(t,s)$

Representação da Geração de Energia Renovável Variável - Eólica e Solar

Os modelos para representação das fontes de energia renovável variável (ERV), constituídas pela geração eólica e solar, são bastante semelhantes entre si em termos dos procedimentos

⁴ Hargreaves, G.H., Samani, S. (1982) Estimating potential evapotranspiration. J. Irrig. Drain. Div., 108~31, 225–230.

necessários para incorporar os impactos das mudanças climáticas em cada tipo de geração.

Uma das principais diferenças dessas fontes em relação à geração hidrelétrica é que, enquanto na hidrelétrica a relação entre geração e precipitação é dinâmica no tempo, isto é, a vazão em um determinado instante não depende apenas da precipitação naquele instante, mas também da precipitação em instantes anteriores, nas fontes ERV a função de transferência que descreve a disponibilidade de geração a partir das variáveis climáticas associadas é estática.

Essa característica simplifica o modelo conceitual necessário para incorporar os impactos das mudanças climáticas, pois permite que a variação na geração seja estimada diretamente a partir da variação mensal esperada nos cenários climáticos. Dessa forma, não é necessário simular a cronologia de um histórico “modificado”, como ocorre no modelo hidrológico, em que a dinâmica temporal das vazões exige a consideração da cronologia dos eventos para estimar a disponibilidade futura de geração. A análise do impacto dentro de cada mês isoladamente é o suficiente para a modelagem proposta.

Para uma melhor organização deste documento, inicialmente serão apresentados os modelos físicos adotados para cada fonte de geração, e então os processos para incorporar os impactos das mudanças climáticas nestes modelos físicos.

É importante destacar que, por decisão do projeto, os cenários sintéticos de operação das fontes renováveis variáveis não serão gerados com base em modelos estatísticos ajustados, que teriam papéis conceitualmente equivalentes aos modelos ARp, para o caso da hidrologia. Em vez disso, os valores serão extraídos diretamente das projeções dos modelos GCM, utilizando uma medida de similaridade. Para cada cenário de operação de vazões afluentes, identifica-se o ano de maior similaridade nos cenários gerados pelo modelo GCM analisado e empregam-se os cenários de geração renovável correspondentes a esse ano. Esse procedimento permitiria capturar a correlação entre a hidrologia e as fontes de geração renovável sem precisar definir um modelo estatístico para as fontes renováveis variáveis.

Devido ao horizonte de planejamento de longo prazo do projeto, uma modelagem detalhada e individualizada das usinas introduziria uma complexidade excessiva, desproporcional às próprias incertezas do projeto. Assim as usinas de fontes renováveis variáveis (VRE) serão representadas por meio de clusters definidos em cada estado. A definição desses clusters foi baseada na base de cenários de longo prazo da PSR, que já realizou o trabalho de clusterização tanto para usinas eólicas quanto solares, facilitando a implementação dessa abordagem no presente estudo.

Para cada tipo de geração, a metodologia de clusterização adotada pela PSR procurou separar cada estado em mais de um cluster representativo, de modo a combinar usinas com características similares em cada cluster.

Por exemplo, na **Figura 7** são apresentados 3 clusters de usinas solares para o estado de Minas Gerais. Cada cluster tem seu próprio conjunto de características, como: tracking, inclinação e perfil de capacidade, para correção de viés.




Figura 7: Clusters de usinas solares - MG

Desta forma, as metodologias descritas a seguir para cada tipo de forma de geração se aplicam aos clusters equivalentes das usinas e não as usinas individuais.

O modelo para estimação da geração eólica a partir da velocidade do vento é baseado no modelo Virtual Wind Farm⁵ - VWF (Staffell and Pfenninger, 2016).

Os passos executados neste modelo, apresentados na Figura 8, são:

- Obter dados de reanálise de velocidade de vento para diferentes alturas (as bases mais utilizadas atualmente apresentam informações a 2, 10, 50 ou 100 m, dependendo do modelo) para pontos de grid da região de interesse;
- Interpolar as velocidades para as coordenadas desejadas, usando regressão LOESS;
- Extrapolar as velocidades de vento para a altura das turbinas de cada usina;
- Converter a velocidade do vento para potência elétrica usando as curvas características de potência de cada turbina (as curvas podem ainda ser suavizadas para representar o agrupamento de várias turbinas em uma usina).

⁵ Staffell, Iain and Pfenninger, Stefan (2016). Using Bias-Corrected Reanalysis to Simulate Current and Future Wind Power Output. Energy 114, pp. 1224-1239. doi: 10.1016/j.energy.2016.08.068.




Figura 8: Visão geral do modelo Virtual Wind Farm5

Embora as bibliografias originais do modelo VWF utilizem a base MERRA-2 para o passo (a), a base ERA-5 consolidou-se como uma fonte mais usual para obtenção de dados horários de velocidade do vento sendo, por isso, adotada neste projeto. Destaca-se que as variáveis obtidas a partir do ERA-5 são as coordenadas u e v dos pontos de grid, e não a velocidade do vento diretamente. Em atendimento ao passo (b), a partir destes valores, pode-se utilizar a regressão LOESS de duas dimensões para extrapolar as coordenadas u , v do vento para as coordenadas das usinas, e então obter-se o valor da velocidade do vento a partir da intensidade do vetor calculado:

$$w = \sqrt{u^2 + v^2}$$

Para o passo (c), embora a metodologia original do *Virtual Wind Farm* sugira a aplicação da "lei logarítmica"⁶ para relacionar a velocidade do vento em diferentes níveis de alturas, por uma questão de maior simplicidade, neste projeto será adotado a lei da potência:

$$w_x = w_r \left(\frac{h_x}{h_r} \right)^\alpha$$

Onde, w_x e w_r representam respectivamente a intensidade da velocidade extrapolada e de referência (original), h_x e h_r suas alturas em relação ao solo. O parâmetro α é o único parâmetro a ser ajustado para cada usina e reflete as características do terreno (principalmente rugosidade).

Embora os clusters de usinas eólicas sejam definidos para uma altura de 100 m, já disponível na base de reanálise, é essencial estimar a função de transformação de altura para cada cluster. Isso se deve ao fato de que, nos cenários de mudanças climáticas, as projeções são feitas para 2 m de

⁶ Bañuelos-Ruedas F, Angeles-Camacho C, Rios-Marcuello S. Methodologies used in the extrapolation of wind speed data at different heights and its impact in the wind energy resource assessment in a region. In: Suvire GO, editor.

altura, exigindo a correção da velocidade do vento.

Após a estimação dos parâmetros, para cada coordenada de usina, a equação pode ser aplicada para estimar a velocidade do vento na altura de interesse. Finalmente, no passo (d), as curvas de potência das turbinas podem ser aplicadas aos ventos estimados de modo a produzir estimativas para a potência das turbinas.

Uma etapa final importante aplicada é a correção de viés da potência final gerada, que tem o objetivo de ajustar o modelo estimado para que a geração final emule os valores reais observados. Esta correção é necessária devido a erros que podem se propagar ao longo de processo de modelagem, como erros na previsão meteorológica da base de reanálise e simplificações da topografia da região.

A granularidade do dado observado conhecido permite que diferentes níveis de perfis de correção de viés possam ser aplicados as diferentes usinas:

- **Perfil único:** um valor de fator de capacidade constante para todas as horas de todos os meses;
- **Perfil mensal:** um valor de fator de capacidade para cada mês;
- **Perfil horário:** um dia típico por mês apresentando um perfil horário (24 horas x 12 meses = 288 valores de fator de capacidade).

A metodologia de correção de viés consiste em um ajuste linear na velocidade do vento, de maneira que:

$$w'_h = \alpha w_h + \beta$$

Onde, w_h é a velocidade do vento original da hora h , w'_h é a velocidade do vento da hora h após a aplicação correção, α e β são os parâmetros do ajuste linear.

Na prática, os parâmetros do ajuste serão calculados de acordo com o perfil de correção disponível (único: um único par de parâmetros para toda a série temporal de vento; mensal: um par de parâmetros por mês do ano; e horário: um par de parâmetro para cada uma das 24h do dia de cada mês);

Na **Figura 9** é apresentada esquematicamente a diferença do processo de conversão do vento em potência sem a correção e com correção de bias.

Como o cálculo analítico dos coeficientes não é trivial, esta estimação é realizada através de um processo iterativo de busca binária.




Figura 9: Conversão de potência com correção de viés

Conforme anteriormente estabelecido, a resposta da geração eólica em função da variação da velocidade do vento é estática e, desta forma, para incorporar o efeito das mudanças climáticas em um cenário de geração eólica, bastaria projetar a distorção esperada para o próprio instante

de tempo no cenário.

Para o cálculo desta distorção, é importante destacar que, para cada modelo GCM, a variação esperada na velocidade média do vento deve ser coerente com a variação esperada na precipitação e temperatura. Para atendimento a este requisito, basta utilizar os mesmos agrupamentos construídos na definição do modelo de precipitação.

Para fins ilustrativos, a Figura 10 apresenta as distribuições de probabilidade da velocidade média do vento para cada um dos clusters anteriormente definidos com base no modelo ACCESS_CM2, evidenciando claramente como a distorção na velocidade do vento em relação à referência histórica varia conforme o grupo de temperatura analisado.




Figura 10: Distribuição de probabilidade da velocidade do vento para cada um dos grupos

Considerando que os mesmos clusters de temperatura ($C=1$ até N_c) já definidos para os modelos GCM, o procedimento completo para incorporar as mudanças climáticas na representação da geração eólica pode ser consolidado como:

Parte i: Independente do modelo GCM utilizado;

1. Estimação dos modelos das usinas a partir dos passos já apresentados acima:
 - a. Obter dados de reanálise de velocidade de vento para diferentes alturas;
 - b. Interpolar as velocidades para as coordenadas desejadas;
 - c. Extrapolar as velocidades de vento para a altura das turbinas de cada usina;
 - d. Converter a velocidade do vento para potência elétrica usando as curvas características de potência de cada turbina;
 - e. Corrigir viés da geração, quando aplicável;
2. Simulação da geração eólica a partir dos modelos das usinas, obtendo o perfil para cada mês (produzindo $media(E_{sim,mes})$)

Parte ii: Dependente do modelo GCM utilizado;

3. Para cada cluster C e usina eólica;
 - d. Estimação da velocidade do vento do modelo GCM para a altura de interesse, utilizando a equação estimada para a usina;

- e. Cálculo da variação da distribuição da velocidade do vento médio dentro do cluster *C* em relação ao experimento 'histórico' do modelo GCM;
- f. Simulação da potência gerada média a partir da velocidade do vento modificada em cada mês; (produzindo $media(E_{mod,mes})$);
- g. Cálculo do fator de variação da geração simulada no mês a partir de $\kappa_{C,E} = \frac{media(E_{mod,mes})}{media(E_{sim,mes})}$
- h. Na geração final, o valor simulado é multiplicado pelo fator de variação, de maneira a preservar o coeficiente de variação original (relação entre a média mensal e o desvio padrão mensal).

Já o modelo para estimação da geração solar é baseado no modelo Global Solar Energy Estimation - GSEE⁷ (Pfenninger, Stefan & Staffell, Iain. (2016)).

Os passos executados neste modelo, apresentados na Figura 11, são:

- a) Obter dados de reanálise de radiação solar global e temperatura para pontos de grade da região de interesse;
- b) Interpolar as radiações e temperatura para as coordenadas desejadas;
- c) Estimar a separação das irradiâncias em direta e difusa a partir da aplicação do modelo BRL⁸;
- d) Estimar a projeção das radiações sobre o painel fotovoltaico equivalente do cluster;
- e) Calcular a potência elétrica a partir das radiações, temperatura e da especificação da eficiência do painel fotovoltaico.




Figura 11: Visão geral do modelo Global Solar Energy Estimation⁷

Os passos (a) e (b) são bastante similares aos já descritos para a obtenção e interpolação espacial

⁷ Pfenninger, Stefan & Staffell, Iain. (2016). Long-term patterns of European PV output using 30 years of validated hourly reanalysis and satellite data. Energy. 114. 1251–1265. 10.1016/j.energy.2016.08.060.

⁸ Ridley, B., J. Boland, and P. Lauret, 2010: Modelling of diffuse solar fraction with multiple predictors. Renew. Energy, 35, 478–483, doi:10.1016/j.renene.2009.07.018

da velocidade do vento.

Para o passo (c), deve ser aplicado um modelo de estimação de fração difusa, cujo objetivo é separar as componentes direta e difusa que compõe a radiação global. Existem diferentes métodos na literatura, sendo o método proposto em [8] Ridley et al. (2010) um dos mais utilizados. Ele propõe uma função logística para representar a relação entre a fração difusa e o índice de claridade:

$$F_d = \frac{a}{1 + \exp(b \cdot (K_t - c))}$$

Onde,

F_d é a fração difusa, que vai definir a razão entre a radiação difusa e a radiação global;

K_t é o índice de claridade, calculado pela razão entre a radiação solar global e a radiação solar teórica para céu claro no mesmo local e tempo (pode ser obtido também da base ERA-5);

a , b e c são parâmetros ajustados empiricamente.

A partir da estimação da fração difusa, pode-se separar as componentes a partir de:

$$I_{dif} = F_d \cdot GHI$$

$$I_{dir} = GHI - I_{dif}$$

Onde,

GHI é a radiação global;

I_{dir} é a radiação direta;

I_{dif} é a radiação difusa

Para o passo (d), é necessário obter o ângulo de incidência do plano. Este ângulo vai depender das características específicas de cada painel e de maneira geral vai ser dado por:

$$\alpha = \arccos(\sin(h) \cdot \cos(t) + \cos(h) \cdot \sin(t) + \cos(a_p - a_s))$$

Onde,

h é altitude do sol;

a_p é o ângulo *azimuth* do painel;

a_s é o ângulo *azimuth* do sol;

t é o ângulo *tilt* do painel;

A partir deste ângulo, a projeção das radiações diretas e difusas no painel ($I_{dir,P}$ e $I_{dif,P}$) podem ser calculadas como:

$$I_{dir,P} = \frac{I_{dir} \cdot \cos(\alpha)}{\cos\left(\frac{\pi}{2} - a_s\right)}$$

$$I_{dif,P} = I_{dif} \cdot \frac{1 + \cos(t)}{2} + A \cdot GHI \cdot \frac{1 - \cos(t)}{2}$$

Onde, A é uma constante que reflete o albedo da superfície.

Para o passo (e), a potência do painel é calculada a partir da radiação projetada no plano, usando

um modelo de eficiência. Em Huld et al (2010)[9] são definidos múltiplos modelos, que são comumente usados para este tipo de aplicação. No contexto dos clusters agregados adotados neste projeto, foram adotados os parâmetros típicos do painel do tipo c-SI apresentado.

Assim como para a geração eólica, para incorporar o efeito das mudanças climáticas em um cenário de geração solar se utiliza os mesmos agrupamentos construídos na definição do modelo de precipitação.

A Figura 12 apresenta as distribuições de probabilidade da radiação solar global para cada um dos clusters anteriormente definidos com base no modelo ACCESS_CM2.




Figura 12: Distribuição de probabilidade da radiação solar global de cada grupo

Considerando mais uma vez os mesmos clusters de temperatura ($C=1$ até N_c) já definidos para os modelos GCM, o procedimento completo para incorporar as mudanças climáticas na representação da geração solar pode ser consolidado como:

Parte i: Independente do modelo GCM utilizado;

1. Estimação dos modelos das usinas a partir dos passos já apresentados acima:
 - a. Obter dados de reanálise de radiação solar global e temperatura para pontos de grid da região de interesse;
 - b. Interpolar as radiações e temperatura para as coordenadas desejadas;
 - c. Estimar a separação das irradiâncias em direta e difusa a partir da aplicação do modelo BRL;
 - d. Estimar a projeção das radiações sobre o painel fotovoltaico;
 - e. Calcular a potência elétrica a partir das radiações, temperatura e da especificação da eficiência do módulo fotovoltaico.;
 - f. Corrigir viés da geração, quando aplicável;
2. Simulação da geração solar a partir dos modelos dos clusters das usinas, obtendo o perfil

⁹ Huld T, Gottschalg R, Beyer HG, Topic M. Mapping the performance of PV modules, effects of module type and data averaging. Sol Energy 2010;84(2):324e38.

para cada mês (produzindo $media(E_{sim,mes})$)

Parte ii: Dependente do modelo GCM utilizado;

3. Para cada cluster C e usina solar;

- g. Estimação da radiação solar global e temperatura do modelo GCM para a coordenada de interesse;
- h. Cálculo da variação das distribuições da radiação solar global e temperatura dentro do cluster C em relação ao experimento 'histórico' do modelo GCM;
- i. Aplicação da variação nos dados históricos horário de GHI e temperatura do mês;
- j. Estimação das componentes I_{dir} e I_{dir} assumindo os mesmos F_d originais;
- k. Simulação da potência gerada média a partir das componentes e temperatura modificadas; (produzindo $media(E_{mod,mes})$);
- l. Cálculo do fator de variação da geração simulada no mês a partir de $\kappa_{C,S} = \frac{media(E_{mod,mes})}{media(E_{sim,mes})}$
- m. Na geração final, o valor simulado é multiplicado pelo fator de variação, de maneira a preservar o coeficiente de variação original (relação entre a média mensal e o desvio padrão mensal).

5. Avaliação da Performance dos Modelos GCM

Esta seção apresenta a avaliação da performance dos modelos GCM, de maneira a definir aqueles que melhor representam as características climáticas do Brasil e definir quais modelos devem ser utilizados para o processo de projeção das séries temporais futuras de hidrologia, fontes renováveis variáveis e demandas.

Na primeira parte é apresentada a metodologia aplicada e na segunda parte é apresentada a análise estatística aplicada.

Os mapas completos para todos os modelos GCM e variáveis climáticas, utilizados como insumo para a parte de análise, estão contidos no Anexo I deste relatório.

Metodologia

Para definir os modelos GCM a serem utilizados no estudo, partiu-se do conjunto de modelos empregados no estudo "Impacto da Mudança Climática nos Recursos Hídricos do Brasil – 2023/2024", conduzido pela Agência Nacional de Águas e Saneamento Básico (ANA), aplicando-se ainda um filtro adicional com base em uma revisão bibliográfica.

Na Figura 13 são apresentados os modelos CMIP6 analisados nas referências (linha inferior da tabela) que abordaram separadamente ou em conjunto as variáveis base. A pontuação foi atribuída conforme o desempenho, de acordo com a análise de cada estudo (1 para cada estudo que indicou que, de modo geral, a variável daquele modelo teve bom desempenho). Modelos que não foram bem avaliados foram deixados vazios (em branco) na tabela. A última coluna mostra, em ordem decrescente, a soma dos pontos dos respectivos modelos de acordo com os estudos analisados. Adicionalmente, na parte inferior da tabela, são apresentadas as somas parciais para cada variável climática analisada.

Para a constituição desta tabela, foram considerados apenas os modelos efetivamente empregados no projeto executado pela ANA, excluindo-se, assim, outros modelos que, embora avaliados no levantamento bibliográfico, não foram aplicados pela agência. Dessa forma, a partir da lista fornecida pela ANA, foram identificados 26 modelos que serão mantidos para a análise quantitativa de desempenho, enquanto 6 modelos foram descartados (sinalizados no retângulo vermelho). No entanto, ressalta-se que durante a execução desta fase do estudo, os cenários dos modelos GFDL-CM4 GR1 e GFDL-CM4 GR2 não estavam disponíveis nos principais servidores de distribuição de dados do CMIP6 e por isso foram inicialmente desconsiderados. Desta maneira, serão avaliados 24 modelos no total.

[illegible]

Figura 13: Modelos climáticos da base NEX GDDP utilizados no Estudo ANA

As métricas utilizadas serão as mesmas apresentadas por DIAS e REBOITA (2021), ou seja: (i) a diferença (*bias*) entre a simulação histórica do modelo CMIP6 e a base histórica de referência (ERA5); (ii) o coeficiente de correlação (*r*), e (iii) o índice de Willmott (*d*).

$$r = \frac{\sum_{i=1}^n (M_i - \mu_M)(R_i - \mu_R)}{\sum_{i=1}^n (M_i - \mu_M)^2 + \sum_{i=1}^n (R_i - \mu_R)^2} ; \quad d = 1 - \frac{\sum_{i=1}^n (M_i - R_i)^2}{\sum_{i=1}^n (|M_i - \mu_M| + |R_i - \mu_R|)^2}$$

Onde:

M_j : cada média trimestral (ou anual) da variável do modelo CMIP6 avaliado no domínio espacial

considerado para célula i ;

μ_R e μ_M : média da variável de análise para reanálise e modelo, respectivamente

R_i : cada média trimestral (ou anual) da variável da base de reanálise ERA5 no domínio espacial considerado para célula i ;

n : número de pontos (células) da variável em análise.

Os modelos e reanálises serão convertidos para uma mesma grade (aprox. 50 km x 50 km)km) já que algumas métricas estatísticas são sensíveis à resolução espacial.

A média trimestral será feita sobre DJF, MAM, JJA, SON, tal como em DIAS e REBOITA (2021).

Além das métricas individuais, será feita uma ponderação voltada para a criação de métrica de performance agregada de interesse específico ao setor elétrico, aderente aos objetivos desse projeto. Nesse caso, a performance de cada variável será ponderada pela potência efetiva de cada fonte, individualmente, em cada região de interesse, mas considerando a energia correspondente esperada para o final do horizonte (quando a demanda for o dobro da atual). A partir de dados históricos públicos disponibilizados pelo ONS calcula-se as médias da potência efetiva de cada fonte de geração em MWm (MW médios) e utilizar este valor como fator de ponderação para as análises agregadas.

Mais especificamente:

- temperatura - carga elétrica líquida (bruta – geração distribuída)
- precipitação – potência hidrelétrica calculada a partir da ENA (energia natural afluenta)
- velocidade do vento - potência eólica (em relação aos parques eólicos offshore, os dados originais CMIP6 serão usados, por que não existem dados NEX GDDP para offshore)
- irradiação solar - potência solar PV

a. O procedimento nesse caso é o seguinte. Seja:

- i índice da variável sendo avaliada
- jj índice do polígono sendo avaliado
- W_i conjunto de células variável i dentro de cada polígono j
- $p_{i,jj}$ performance da variável i no conjunto W_i ao comparar a variável do modelo com a variável da reanálise, no polígono j . Por exemplo, p_i pode ser a correlação dos valores das células no modelo e do conjunto de dados de reanálise ERA.
- $c_{i,jj}$ Fator de ponderação considerado: potência efetiva no final do horizonte por tipo de recurso (1 = demanda, 2 = energia hidrelétrica, 3 = energia eólica, 4 = energia solar FV)

b. A medida de performance agregada do modelo será $\sum_i p_{i,jj} \cdot c_{i,jj}$.

c. Repita este procedimento para todos os modelos. Classifique-os da melhor performance para a pior, para o corte dos modelos de pior performance.

Além da análise quantitativa, será adicionalmente feita uma análise qualitativa dos modelos a partir da análise visual. As etapas deste processo são:

- a. Geração de mapas para Brasil de climatologia e viés (resultado do modelo do CMIP6 –referência da reanálise ERA5, ou seja, $viés = \mu_M - \mu_R$) por trimestre e média anual. Serão, portanto matrizes de 5 colunas (trimestres e ano) e 4 linhas (variáveis).
- b. Descarte de modelos com inadequados para variáveis de interesse em domínios de interesse.
- c. Preparação de um anexo com os mapas.

Análise da Temperatura

A Figura 14 apresenta a climatologia da temperatura, baseada na base ERA-5, distribuída espacialmente ao longo do território brasileiro para os períodos DJF, MAM, JJA, SON, além da média anual.




Figura 14: Climatologia - Temperatura

A tabela contendo os índices para todos modelos considerando todos os períodos é apresentada na Figura 15.

Modelo	DJF		MAM		JJA		SON	
	willmott	R	willmott	R	willmott	R	willmott	R
ACCESS_CM2	0.54	0.56	0.76	0.75	0.96	0.94	0.85	0.90
ACCESS_ESM1_5	0.45	0.68	0.77	0.87	0.94	0.94	0.70	0.89
BCC_CSM2_MR	0.52	0.45	0.75	0.72	0.93	0.94	0.80	0.86
CANESM5	0.34	0.44	0.68	0.66	0.91	0.88	0.56	0.82
CMCC_ESM2	0.66	0.63	0.80	0.84	0.90	0.91	0.77	0.88
CMCC_CM2_SR5	0.65	0.66	0.75	0.82	0.90	0.92	0.71	0.87
EC_EARTH3_VEG_LR	0.79	0.64	0.74	0.57	0.98	0.96	0.83	0.87
EC_EARTH3	0.73	0.64	0.74	0.61	0.96	0.96	0.73	0.87
FGOALS_G3	0.53	0.75	0.78	0.89	0.93	0.96	0.77	0.93
GFDL_ESM4	0.80	0.67	0.86	0.76	0.96	0.95	0.77	0.87
HADGEM3_GC31_LL	0.68	0.68	0.83	0.77	0.97	0.95	0.89	0.92
HADGEM3_GC31_MM	0.67	0.79	0.89	0.89	0.98	0.97	0.86	0.94
INM_CM4_8	0.57	0.35	0.83	0.82	0.90	0.93	0.86	0.78
INM_CM5_0	0.54	0.30	0.83	0.83	0.92	0.93	0.90	0.85
IPSL_CM6A_LR	0.71	0.69	0.84	0.85	0.97	0.96	0.85	0.92
KACE_1_0_G	0.38	0.44	0.58	0.78	0.85	0.97	0.66	0.90
MIROC6	0.68	0.64	0.89	0.83	0.92	0.88	0.74	0.82
MPI_ESM1_2_HR	0.76	0.68	0.86	0.81	0.93	0.93	0.92	0.89
MPI_ESM1_2_LR	0.65	0.58	0.76	0.73	0.83	0.86	0.88	0.84
MRI_ESM2_0	0.84	0.85	0.96	0.93	0.95	0.94	0.90	0.89
NESM3	0.64	0.44	0.74	0.59	0.84	0.85	0.90	0.86
NORESM2_MM	0.73	0.68	0.87	0.83	0.95	0.91	0.83	0.87
TAIESM1	0.75	0.56	0.90	0.82	0.95	0.91	0.86	0.82
UKESM1_0_LL	0.67	0.67	0.79	0.73	0.94	0.91	0.83	0.89

Figura 15: Tabela de índices de desempenho para temperatura

Observa-se que o período DJF é o que apresenta maior variabilidade nas performances dos diferentes modelos. A comparação entre os períodos DJF e JJA revela que os modelos têm um desempenho superior na captura das temperaturas durante os meses mais frios em relação aos

mais quentes. No período JJA, todos os modelos apresentam índices acima de 0.8, enquanto, no período DJF, apenas o modelo MRI_ESM2.0 alcança um índice ligeiramente superior a 0.8, com alguns modelos registrando índices até mesmo abaixo de 0.6.

Na Figura 16 são apresentados os índices de Willmott obtidos para a temperatura de forma ordenada, do melhor para o pior modelo, considerando todo território brasileiro, para os períodos DJF e JJA.




Figura 16: Índice de Willmott para temperatura

Para facilitar a compreensão de como os índices de desempenho refletem o viés dos modelos, as Figura 17 e Figura 18 apresentam a distribuição espacial do viés para o melhor e o pior modelo (usando DJF como referência).

O viés do modelo MRI_ESM2.0, considerado o de melhor desempenho, é distribuído de maneira relativamente uniforme ao longo de todo o território, com valores predominantemente próximos ao centro da escala de viés. Uma exceção ocorre no período SON, quando um viés ligeiramente mais elevado é observado, concentrado principalmente na região Nordeste.

O viés do modelo CANESM5, identificado como o de pior desempenho, apresenta uma distribuição altamente desigual ao longo do território, com as maiores divergências localizadas na região Norte, onde o modelo superestima significativamente a temperatura média nos períodos DJF e SON. Mesmo nos períodos MMA e JJA, em que o modelo subestima as temperaturas na maior parte das regiões Nordeste, Sudeste e Sul, a região Norte continua apresentando uma tendência de superestimação.




Figura 17: Viés da temperatura do modelo MRI_ESM2.0




Figura 18: Viés da temperatura do modelo CANESM5

A Figura 19 apresenta a comparação do viés anual entre os dois modelos.

Nota-se que o desempenho do modelo MRI_ESM2.0 é ainda mais destacado quando analisado em uma escala anual consolidada. Por outro lado, torna-se evidente que o principal desafio do modelo CANESM5 está na representação da região Norte, onde se observam as maiores discrepâncias.




Figura 19: Comparação do viés da temperatura anual (esquerda: MRI_ESM2.0 e direita: CANESM5)

Conforme anteriormente citado, no contexto do SIN, a principal influência esperada da variação da temperatura é o impacto no aumento da demanda elétrica, embora existam outros efeitos secundários, como a mudança na evapotranspiração das bacias hidrográficas e a queda da eficiência nos painéis solares.

Desta maneira, de modo a se ponderar a influência de cada região no cálculo dos índices de desempenho dos modelos globais para a temperatura, é utilizado como fator a distribuição percentual do consumo elétrico de cada estado do país, extraídos do Painel de Monitoramento do Consumo de Eletricidade no Brasil.

A distribuição para o período DJF de 2024 é apresentada na Figura 20.




Figura 20: Distribuição do consumo de energia elétrica por estado (DJF-2024)

A ordenação dos modelos ao se aplicar a ponderação no índice de desempenho Willmott é apresentada na Figura 21.

Embora o modelo MRI_ESM2.0 não ocupe mais a liderança no ranking, ele continua entre os primeiros colocados, permanecendo próximo dos três líderes: GFDL_ESM4, EC_EARTH3 e HADGEM3_GC31_MM. Este último, aliás, apresentou um dos avanços mais significativos no ranking após a aplicação do fator de ponderação, tendo inicialmente ocupado uma posição mais central na classificação.





Figura 21: Índice de Willmott ponderado para temperatura

A Figura 22 apresenta a comparação do viés anual entre os dois modelos ao se considerar o fator de ponderação. Nota-se que o desempenho do modelo KACE_1.0.G apresenta um viés predominantemente positivo, que embora seja mais forte no Norte, é mais penalizado pelas parcelas no Sudeste e no Sul, enquanto que o modelo GFDL_ESM4 apresenta boa parte da região do Sudeste e do Sul com viés próximo de zero.



**Figura 22: Comparação do viés da temperatura anual
(esquerda: GFDL_ESM4 e direita: KACE_1.0.G)**

Análise da Precipitação

A Figura 23 apresenta a climatologia para a precipitação, também tendo como fonte a base ERA-5, para os períodos DJF, MAM, JJA, SON, bem como para a média anual.




Figura 23: Climatologia - Precipitação

A tabela contendo os índices para todos modelos considerando todos os períodos é apresentada na Figura 24.

Modelo	DJF		MAM		JJA		SON	
	willmott	R	willmott	R	willmott	R	willmott	R
ACCESS_CM2	0.45	0.17	0.469	0.149	0.968	0.951	0.864	0.806
ACCESS_ESM1_5	0.683	0.501	0.894	0.809	0.97	0.95	0.848	0.781
BCC_CSM2_MR	0.505	0.21	0.526	0.186	0.729	0.812	0.849	0.735
CANESM5	0.352	-0.015	0.661	0.541	0.838	0.895	0.724	0.685
CMCC_ESM2	0.556	0.296	0.625	0.384	0.878	0.855	0.774	0.72
CMCC_CM2_SR5	0.497	0.182	0.501	0.199	0.848	0.838	0.738	0.755
EC_EARTH3_VEG_LR	0.72	0.523	0.475	0.133	0.969	0.945	0.87	0.828
EC_EARTH3	0.7	0.494	0.557	0.274	0.973	0.949	0.858	0.795
FGOALS_G3	0.526	0.277	0.644	0.552	0.638	0.67	0.709	0.626
GFDL_ESM4	0.682	0.521	0.749	0.574	0.876	0.869	0.751	0.832
HADGEM3_GC31_LL	0.572	0.347	0.637	0.411	0.969	0.953	0.91	0.861
HADGEM3_GC31_MM	0.787	0.655	0.902	0.856	0.984	0.973	0.904	0.852
INM_CM4_8	0.632	0.419	0.804	0.687	0.884	0.786	0.772	0.6
INM_CM5_0	0.683	0.475	0.821	0.704	0.883	0.786	0.807	0.678
IPSL_CM6A_LR	0.305	-0.196	0.571	0.306	0.909	0.834	0.896	0.853
KACE_1_0_G	0.538	0.257	0.696	0.578	0.928	0.889	0.908	0.863
MIROC6	0.649	0.491	0.88	0.784	0.907	0.888	0.892	0.858
MPI_ESM1_2_HR	0.719	0.534	0.779	0.619	0.886	0.902	0.909	0.854
MPI_ESM1_2_LR	0.606	0.378	0.691	0.545	0.727	0.847	0.918	0.852
MRI_ESM2_0	0.796	0.757	0.944	0.915	0.906	0.875	0.903	0.89
NESM3	0.359	-0.006	0.427	0.101	0.893	0.918	0.809	0.812
NORES2_MM	0.766	0.629	0.928	0.864	0.848	0.813	0.878	0.88
TAIESM1	0.673	0.468	0.835	0.712	0.876	0.872	0.793	0.802
UKESM1_0_LL	0.64	0.466	0.663	0.486	0.962	0.944	0.896	0.831

Figura 24: Tabela de índices de desempenho para precipitação

Assim como observado para a temperatura, os modelos apresentam melhor desempenho nos períodos JJA e SON em comparação ao período DJF. No entanto, diferentemente do comportamento observado para a temperatura, alguns modelos também enfrentam dificuldades em representar adequadamente o período MAM. Como DJF corresponde ao período de maior

precipitação no país de forma geral, e MAM ainda concentra chuvas em algumas regiões, pode-se inferir que os modelos tendem a apresentar maior dificuldade em capturar com precisão os períodos úmidos das diferentes áreas. Outro ponto a ser observado é que mesmo para o período DJF a performance dos modelos já é predominantemente inferior quando comparada com os resultados da temperatura. Por exemplo, o modelo IPSL_CM6A_LR, que apresentava desempenho considerado bom para a temperatura, apresenta desempenho insatisfatório para a precipitação.

Na Figura 25 são apresentados os índices de Willmott obtidos para a precipitação para os períodos DJF e JJA, enquanto na

Figura 26 são apresentados os índices para o período MAM.




Figura 25: Índice de Willmott para precipitação




Figura 26: Índice de Willmott para precipitação - MAM

Na Figura 27 é apresentado o viés do melhor modelo, MRI_ESM2.0, enquanto na Figura 28 é apresentado o viés do pior modelo, IPSL_CM64_LR, usando o desempenho de DJF como referência.

No período DJF, o modelo MRI_ESM2.0 apresenta predominantemente viés de sobrestimação na maior parte do país, com exceção da região Sul e das áreas mais ao norte da região Norte, onde o viés é de subestimação. Já nos períodos MAM e SON, o modelo exibe um comportamento mais equilibrado, com proporções semelhantes de viés de sobrestimação e subestimação.

Importante destacar que, em nenhum dos períodos analisados, os valores de viés são significativamente altos.

O modelo IPSL_CM64_LR apresenta um viés de sobrestimação bastante expressivo na precipitação da região Nordeste, além de uma subestimação significativa na região Norte, especialmente nos períodos DJF e MAM. Essas discrepâncias contribuem de forma substancial para o desempenho insatisfatório do modelo no ranking geral.

Em contrapartida, nos períodos secos (JJA e SON), o modelo demonstra um desempenho positivo, exibindo viés reduzido em todas as regiões analisadas, o que faz com que ele esteja até mais bem posicionado no ranking do que o modelo MRI_ESM2.0, ao se considerar apenas estes períodos.




Figura 27: Viés da precipitação do modelo MRI_ESM2.0




Figura 28: Viés da precipitação do modelo IPSL_CM64_LR

Para ponderar os modelos, de modo a se obter índices de desempenho que refletem melhor a importância de cada região para a geração hidrelétrica, foi utilizada a energia afluenta, em

MWmed média, de cada bacia. Estes dados foram obtidos dos dados abertos do ONS¹¹.

Na **Figura 27** são apresentadas as bacias hidrográficas que compõe o SIN.



Figura 29: Mapa das bacias hidrográficas

A distribuição por bacia é apresentada na Figura 30.

A ordenação dos modelos ao se aplicar a ponderação no índice de desempenho Willmott é apresentada na Figura 31.




Figura 30: Distribuição da energia afluyente média por bacia




Figura 31: Índice de Willmott ponderado para precipitação

Para esta medida ponderada, observa-se que não existe uma grande variação no desempenho dos modelos, estando a primeira metade do ranking praticamente toda dentro da faixa 0.5-0.6. A região Nordeste, representada principalmente pela bacia do SÃO FRANCISCO nesta análise, é um dos principais fatores que influencia na redução geral do desempenho dos modelos. Conforme será visto a seguir, os modelos apresentam viés de sobrestimação considerável para a precipitação desta bacia.

Na Figura 32 é apresentado o viés do modelo INM_CM4.8, que possui a melhor performance no ranking ponderado. Observa-se o quanto o erro para o Nordeste é bem mais acentuado do que para as demais

regiões.




Figura 32: Viés da precipitação do modelo INM_CM4.8

Na Figura 33 é apresentada a distribuição de probabilidade do viés da precipitação do período DJF para as 6 bacias de maior importância, combinando-se todos os modelos globais de circulação. Destaca-se que estas 6 bacias correspondem acumuladamente a mais de 75% do total da energia afluyente do SIN.




Figura 33: Distribuição de probabilidade do viés da precipitação para as bacias - DJF

Observa-se uma tendência predominante de viés positivo, indicando uma sobrestimação da precipitação na maioria dos casos. A bacia do Amazonas destaca-se como a única com uma distribuição simétrica, refletindo um equilíbrio entre modelos que subestimam e superestimam a

precipitação. Já a bacia do Uruguai apresenta uma distribuição próxima à simetria, embora com uma leve inclinação para a sobrestimação. Nenhuma das bacias analisadas apresenta tendência de subestimação predominante.

Destaca-se, em particular, a bacia do São Francisco, onde a assimetria é extremamente acentuada, evidenciando um viés de sobrestimação quase unânime entre os modelos avaliados.

Embora a bacia do Paraná não apresente uma assimetria tão grande quanto a do São Francisco, ela também deve ser destacada devido à sua importância para o SIN.

Na Figura 34 é apresentada a distribuição de probabilidade agora para o período JJA. A figura foi dividida em dois grupos dado a diferença de escala da distribuição de Tocantins e São Francisco em relação as demais.




Figura 34: Distribuição de probabilidade do viés da precipitação para as bacias - JJA

No período JJA, observa-se uma maior simetria no viés dos modelos climáticos. Das seis bacias analisadas, apenas as bacias do Uruguai e do Iguaçu apresentam uma assimetria mais acentuada, com predominância de subestimação da precipitação. As bacias do Paraná e do Amazonas também exibem uma tendência de subestimação, embora em menor intensidade.

Análise da Velocidade do Vento a 10m de altura

A Figura 35 apresenta a climatologia da velocidade média do vento espacialmente ao longo do território brasileiro para os períodos DJF, MAM, JJA, SON, bem como para a média anual, também tendo como fonte a base ERA-5.




Figura 35: Climatologia – Velocidade do vento

A tabela contendo os índices para todos modelos considerando todos os períodos é apresentada na Figura 36.

Modelo	DJF		MAM		JJA		SON	
	willmott	R	willmott	R	willmott	R	willmott	R
ACCESS_CM2	0.87	0.785	0.807	0.707	0.848	0.808	0.923	0.878
ACCESS_ESM1_5	0.919	0.868	0.889	0.846	0.872	0.828	0.928	0.889
BCC_CSM2_MR	0.799	0.772	0.776	0.787	0.838	0.842	0.861	0.859
CMCC_ESM2	0.858	0.742	0.854	0.738	0.889	0.823	0.916	0.843
CMCC_CM2_SR5	0.857	0.741	0.845	0.722	0.896	0.825	0.913	0.839
EC_EARTH3_VEG_LR	0.77	0.723	0.712	0.629	0.818	0.856	0.835	0.866
EC_EARTH3	0.741	0.67	0.696	0.594	0.825	0.87	0.818	0.831
FGOALS_G3	0.751	0.809	0.743	0.802	0.844	0.814	0.842	0.858
GFDL_ESM4	0.812	0.672	0.81	0.671	0.85	0.773	0.905	0.826
HADGEM3_GC31_LL	0.889	0.797	0.84	0.719	0.916	0.861	0.949	0.906
HADGEM3_GC31_MM	0.941	0.897	0.938	0.883	0.947	0.909	0.96	0.932
INM_CM4_8	0.701	0.626	0.633	0.632	0.605	0.587	0.736	0.744
INM_CM5_0	0.701	0.665	0.621	0.633	0.594	0.555	0.732	0.739
IPSL_CM6A_LR	0.713	0.8	0.68	0.737	0.779	0.777	0.865	0.868
KACE_1_0_G	0.852	0.756	0.873	0.772	0.915	0.842	0.927	0.889
MIROC6	0.694	0.717	0.683	0.785	0.746	0.85	0.786	0.813
MPI_ESM1_2_HR	0.825	0.837	0.818	0.837	0.86	0.877	0.917	0.903
MPI_ESM1_2_LR	0.744	0.671	0.727	0.657	0.733	0.729	0.831	0.792
MRI_ESM2_0	0.837	0.786	0.821	0.797	0.852	0.802	0.924	0.861
NORESM2_MM	0.854	0.835	0.864	0.852	0.887	0.885	0.884	0.892
TAIESM1	0.857	0.793	0.844	0.796	0.852	0.832	0.906	0.863
UKESM1_0_LL	0.85	0.732	0.732	0.547	0.835	0.756	0.908	0.833

Figura 36: Tabela de índices de desempenho para a velocidade do vento

Na Figura 37 são apresentados os índices de Willmott obtidos para a velocidade do vento, considerando todo território brasileiro, para os períodos DJF e JJA, ordenando os modelos de acordo com a performance.

Um aspecto marcante desta análise é que a variável vento é consistentemente bem representada por todos os modelos avaliados, sem que nenhum deles apresente desempenho insatisfatório em qualquer período. A maioria dos modelos atinge índices de desempenho superiores a 0.8, enquanto os demais se encontram na faixa entre 0.7 e 0.8, demonstrando uma boa aderência geral.

Ressalta-se, no entanto, que dois modelos, NESM3 e CANESM5, não puderam ser incluídos na análise, pois não disponibilizam cenários de velocidade do vento, ou, ao menos, esses cenários não estavam acessíveis para download.




Figura 37: Índice de Willmott para velocidade do vento

Para facilitar a compreensão de como os índices de desempenho refletem o viés dos modelos, a Figura 38 e a Figura 39 apresentam a distribuição espacial do viés para o melhor e o pior modelo (usando DJF e JJA como referência).

O modelo HADGEM3_GC31_MM apresenta viés bem reduzido ao longo de todo território sendo que apenas na região offshore se observa uma diferença absoluta superior a 2 m/s.

A região Sul é a única que apresenta um viés consistentemente de subestimação ao longo dos 4 trimestres.

O modelo INM_CM5.0 tende a superestimar o valor da velocidade do vento ao longo de todo território nacional, a menos da região do Nordeste, onde se vê uma tendência maior de subestimação. Observa-se que esta característica se estende para o offshore.




Figura 38: Viés da velocidade do vento do modelo HADGEM3_GC31_MM




Figura 39: Viés da velocidade do vento do modelo INM_CM5.0

Para ponderar os modelos, de modo a se obter índices de desempenho que refletem melhor a importância de cada região para a geração eólica, foi utilizada a potência efetiva relativa de cada estado em relação a potência total. Estes dados foram obtidos dos dados abertos do ONS¹². A distribuição por estado é apresentada na Figura 40.




Figura 40: Distribuição da potência efetiva da geração eólica por estado

A ordenação dos modelos ao se aplicar a ponderação no índice de desempenho Willmott é apresentada na Figura 41.




Figura 41: Índice de Willmott ponderado para velocidade do vento

O modelo HADGEM3_GC31_MM, que já apresentava a melhor performance na análise não ponderada, continua sendo o primeiro do ranking nesta análise ponderada. O gráfico de viés anual, apresentado no lado esquerdo da Figura 42, ressalta a sua boa compatibilidade para representar todo o território do Brasil, bem como o desvio pequeno nas regiões de maior importância, como o Nordeste e o Sul.

Na mesma figura, à direita, é apresentado o viés do modelo MPI_ESM1.2LR, que apresentou o pior desempenho na análise ponderada. Ressalta-se que na análise não ponderada este modelo ocupava

uma posição intermediária no ranking, com um índice de concordância ligeiramente acima de 0.8. Essa discrepância significativa se deve ao fato de que a principal limitação do modelo recai sobre a região Nordeste, que é bastante importante para o contexto de representação do vento, e onde ele subestima consideravelmente as velocidades do vento, como destacado na figura. Além disso, observa-se um viés de subestimação mais pronunciado na região Sul, que também é uma área de alta relevância para a geração eólica.




Figura 42: Comparação do viés da velocidade do vento anual (esquerda: HADGEM3_GC31_MM e direita: MPI_ESM1.2LR)

Análise da Radiação Solar

Inicialmente ressalta-se que para esta análise foi utilizada a variável *Surface Downwelling Shortwave Radiation*, que, para fins de simplificação, será referida como radiação solar ao longo da análise, também tendo como fonte a base ERA-5.

A Figura 43 apresenta a climatologia distribuída espacialmente ao longo do território brasileiro para os períodos DJF, MAM, JJA, SON, bem como para a média anual da radiação solar.




Figura 43: Climatologia – Radiação Solar

A tabela contendo os índices para todos modelos considerando todos os períodos é apresentada na Figura 44.

Modelo	DJF		MAM		JJA		SON	
	willmott	R	willmott	R	willmott	R	willmott	R
ACCESS_CM2	0.547	0.286	0.372	-0.109	0.877	0.912	0.733	0.761
ACCESS_ESM1_5	0.506	0.403	0.461	0.466	0.753	0.875	0.563	0.67
BCC_CSM2_MR	0.554	0.416	0.362	0.048	0.701	0.836	0.609	0.673
CANESM5	0.471	0.064	0.46	0.202	0.763	0.902	0.566	0.714
CMCC_ESM2	0.755	0.609	0.482	0.154	0.866	0.91	0.865	0.787
CMCC_CM2_SR5	0.684	0.495	0.365	-0.033	0.847	0.914	0.853	0.807
EC_EARTH3_VEG_LR	0.811	0.722	0.268	-0.182	0.905	0.958	0.89	0.905
EC_EARTH3	0.77	0.696	0.4	-0.009	0.903	0.966	0.866	0.896
FGOALS_G3	0.729	0.61	0.664	0.7	0.8	0.917	0.79	0.817
GFDL_ESM4	0.855	0.741	0.661	0.528	0.795	0.952	0.831	0.897
HADGEM3_GC31_LL	0.629	0.559	0.388	-0.032	0.856	0.945	0.696	0.815
HADGEM3_GC31_MM	0.599	0.771	0.479	0.404	0.832	0.908	0.634	0.794
INM_CM4_8	0.693	0.817	0.565	0.593	0.707	0.901	0.636	0.767
INM_CM5_0	0.784	0.891	0.591	0.665	0.714	0.891	0.666	0.781
IPSL_CM6A_LR	0.879	0.837	0.46	0.111	0.757	0.776	0.543	0.65
KACE_1_0_G	0.552	0.442	0.396	0.076	0.779	0.802	0.65	0.747
MIROC6	0.788	0.658	0.842	0.733	0.823	0.883	0.899	0.863
MPI_ESM1_2_HR	0.656	0.462	0.524	0.258	0.894	0.916	0.854	0.853
MPI_ESM1_2_LR	0.568	0.3	0.426	0.01	0.915	0.899	0.857	0.774
MRI_ESM2_0	0.816	0.869	0.602	0.862	0.777	0.939	0.642	0.916
NESM3	0.492	0.129	0.268	-0.284	0.878	0.863	0.75	0.751
NORESMM2_MM	0.931	0.914	0.784	0.899	0.822	0.919	0.824	0.909
TAIESM1	0.819	0.719	0.74	0.571	0.856	0.897	0.847	0.783
UKESM1_0_LL	0.655	0.65	0.422	0.044	0.851	0.915	0.68	0.796

Figura 44: Tabela de índices de desempenho para radiação solar

Ao contrário das demais variáveis climáticas, para as quais o período DJF é sempre o mais crítico de ser representado, para a radiação solar os modelos apresentam dificuldade também de reproduzir o período MAM, para o qual se observam muitos modelos como desempenho abaixo do satisfatório.

São observados tanto padrões nos quais o modelo tem bom desempenho para DJF, mas que não representa bem o MAM, como o modelo EC_EARTH3_VEG_LR, como padrões no qual o modelo não representa bem nenhum dos dois períodos, como o CANESM5 e NESM3.

Na Figura 45 são apresentados os índices de Willmott obtidos para a radiação solar, considerando todo território brasileiro, para os períodos DJF e JJA.




Figura 45: Índice de Willmott para radiação solar

Como o período MAM apresenta uma variação de desempenho crítica, na Figura 46 é apresentada a ordenação dos modelos para este período.

Destaca-se que existem modelos, EC_EARTH3_VEG_LR e NESM3 com índice de correspondência bem próximo da faixa de 0.2, que é o pior indicador observado até agora.




Figura 46: Índice de Willmott para radiação solar (MAM)

Os vieses dos melhores e piores modelos para DJF e MAM são apresentados na **Figura 47** - melhor modelo para DJF, **Figura 48** – pior modelo para DJF,


Figura 49 – melhor modelo para MAM, e Figura 50 – pior modelo para MAM.

O modelo NESM4, classificado como o de pior desempenho para o período MAM, apresenta uma característica distinta: a coexistência de regiões com elevada superestimação e subestimação. Essa característica não se restringe ao período MAM, mas também é observada no período DJF.

Adicionalmente, na **Figura 51** é apresentado também o modelo EC_EARTH3_VEG_LR, devido a sua particularidade de apresentar bom desempenho para todos os trimestres a menos do período MAM.

Na análise visual do viés deste modelo, observa-se que esta característica está bastante associada a uma área de superestimação bastante concentrada na região Norte neste período MAM, e que não se repete para os demais períodos.

Figura 47: Viés da radiação solar do modelo NORESM2_MM






Figura 48: Viés da radiação solar do modelo CANESM5




Figura 49: Viés da radiação solar do modelo MIROC6




Figura 50: Viés da radiação solar do modelo NESM3




Figura 51: Viés da radiação solar do modelo EC_EARTH3_VEG_LR

Para ponderar os modelos, de modo a se obter índices de desempenho que refletem melhor a importância de cada região para a geração solar, foi utilizada a potência efetiva relativa de cada estado em relação a potência total. Estes dados foram obtidos dos dados abertos do ONS¹³.

A distribuição por estado é apresentada na Figura 52.

A ordenação dos modelos ao se aplicar a ponderação no índice de desempenho Willmott é apresentada na Figura 53.




Figura 52: Distribuição da potência efetiva da geração solar por estado




Figura 53: Índice de Willmott ponderado para radiação solar

O modelo HADGEM3_GC31_MM, originalmente posicionado na segunda metade do ranking, destaca-se como o melhor modelo na análise ponderada. Essa diferença significativa ocorre porque a área de pior desempenho do modelo está concentrada em uma área concentrada na região do Norte, sem influência na geração solar. Por outro lado, nas demais regiões, o modelo apresenta um viés relativamente pequeno, conforme ilustrado na parte esquerda da Figura 54.

Na mesma figura, à direita, é exibido o viés do modelo NESM3, que obteve o pior desempenho na análise ponderada, assim como já havia se destacado negativamente na análise geral. Embora o modelo

apresente uma discrepância significativa na região Norte, o principal problema reside na subestimação acentuada observada em áreas estratégicas para a geração solar no Nordeste e no Sudeste.




Figura 54: Comparação do viés da radiação solar anual (esquerda: HADGEM3_GC31_MM e direita: NESM3)

Análise Combinada

Por fim, foi realizada a análise combinada considerando o impacto simultâneo em todas as fontes de geração via fatores de ponderação, conforme o critério estabelecido.

Uma premissa fundamental para a definição desses fatores é que a distribuição espacial de cada tipo de fonte de geração não deverá sofrer grandes variações até o ano final do horizonte de planejamento. Assim, a ponderação entre diferentes tipos de fontes pode ser realizada com base apenas na relação entre os valores finais agregados de cada tipo, sem a necessidade de considerar os valores individuais de cada unidade geradora. Esses fatores são então aplicados aos índices intermediários, que já foram ponderados pela importância das fontes individuais.

Desta forma, foi utilizado como fator de ponderação a participação percentual projetada de cada tipo de fonte de energia para o ano de 2050, conforme ilustrado na Figura 55.




Figura 55: Fator de participação dos tipos de fonte de geração de energia (2050)

O ranking de melhores modelos considerando os fatores de ponderação especificados é apresentado na Figura 56.

Observa-se que os modelos CANESM5 e NESM3, que ocupam 2 das últimas 3 posições, são penalizados na ponderação final por não disponibilizar dados de vento.




Figura 56: Índice de Willmott composto

Os modelos com melhor desempenho, apresentando índice de concordância acima de 0.6 ou muito próximo disso, são, respectivamente: HADGEM_GC31_MM, GFDL_ESM4, EC_EARTH3, NORES2_MM, MRI_ESM2_0, TAIESM1, UKESM1.0.LL, EC_EARTH3_VEG_LR, ACCESS_CM2, HADGEM_GC31_LL e CMCC_ESM2.

Abaixo desta faixa, mas ainda acima de 0.5, tem-se: CMCC_CM2_SR5, IPSL_CM64_LR, INM_CM4.8, INM_CM5.0, BCC_CSM2_HR, MPI_ESM1.2_HR, FGOALS_G3, KACE_1.0.G, ACCESS_ESM1.5 e MIROC6.

Por fim, na região de menor compatibilidade, tem-se: CANESM5, MPI_ESM1.2_LR e NESM3.

Desta maneira, sugere-se que duas hipóteses sejam consideradas para a escolha dos modelos.

Na primeira hipótese, os cenários seriam gerados considerando apenas o conjunto mais restrito dos 10 melhores modelos: HADGEM_GC31_MM, GFDL_ESM4, EC_EARTH3, NORES2_MM, MRI_ESM2_0, TAIESM1, UKESM1.0.LL, EC_EARTH3_VEG_LR, ACCESS_CM2 e HADGEM_GC31_LL.

E na segunda hipótese, seriam gerados utilizando-se o conjunto ampliado de 21 modelos, que apenas descarta os 3 de menor compatibilidade, resultando em: HADGEM_GC31_MM, GFDL_ESM4, EC_EARTH3, NORES2_MM, MRI_ESM2_0, TAIESM1, UKESM1.0.LL, EC_EARTH3_VEG_LR, ACCESS_CM2, HADGEM_GC31_LL, CMCC_ESM2, CMCC_CM2_SR5, IPSL_CM64_LR, INM_CM4.8, INM_CM5.0, BCC_CSM2_HR, MPI_ESM1.2_HR, FGOALS_G3, KACE_1.0.G, ACCESS_ESM1.5 e MIROC6.

Para as análises preliminares dos cenários, foi adotado o conjunto estendido de 21 modelos.

6. Apresentação e Análise Estatística das Séries Geradas

Os métodos apresentados na seção 3 foram aplicados aos três tipos de fontes de geração para elaborar as séries de disponibilidade de energia considerando os impactos das mudanças climáticas. Nesta seção, serão destacados alguns dos resultados obtidos, ilustrando o tipo de informações gerado por esse processo.

Conforme descrito na seção de metodologia, o planejamento da operação é um problema estocástico que exige uma grande quantidade de cenários para representar adequadamente a incerteza associada aos recursos. No entanto, os cenários gerados pelos diferentes modelos GCM não devem ser combinados de forma a compor diretamente a nuvem de incerteza no modelo de operação. Assim, é necessário que os cenários utilizados na operação sejam gerados individualmente para cada modelo GCM, por meio de modelos estatísticos ajustados que reflitam o impacto das mudanças climáticas específicas de cada GCM. Para diferenciar esses dois conceitos de cenários — os provenientes de cada modelo GCM e aqueles gerados por modelos estatísticos baseados nos GCM — denominaremos os cenários gerados pelos modelos estatísticos ajustados como **cenários sintéticos de operação**.

Conforme anteriormente já destacado, por decisão do projeto, os cenários de operação das fontes renováveis variáveis não serão gerados com base em modelos estatísticos ajustados. Como consequência, apenas para a geração hidrelétrica será necessária uma avaliação adicional dos cenários sintéticos de operação.

Ao longo das análises, para comparação dos perfis históricos das variáveis com os cenários gerados, será adotado um padrão em que a linha vermelha sólida representará a média da série gerada calculada a partir de todos os modelos climáticos. As áreas sombreadas em vermelho indicarão as distribuições projetadas: a região delimitada pelos quantis de 0.025 e 0.975 define o intervalo de 95% de probabilidade, enquanto a área entre os quantis de 0.1 e 0.9 corresponde ao intervalo de 80% de probabilidade.

O objetivo da inserção destas duas áreas sombreadas é prover uma percepção qualitativa sobre o grau de dispersão entre os modelos mais extremos e os demais. Quanto menor a diferença entre as áreas, maior é a concordância entre os modelos mais extremos e os demais. Por outro lado, quanto maior a diferença entre as áreas, maior a divergência entre modelos extremos e os demais.

Séries de Geração Hidrelétrica

Para uma primeira visão com um maior detalhe a nível de usina individual, na Figura 57 são apresentadas as vazões médias mensais projetadas para as trajetórias SSP245 e SSP585 a partir do ensemble de modelos GCM para 4 usinas hidrelétricas, comparando-se com o perfil médio dos dados históricos observados (período de referência definido: 1980-2014).

Cada usina escolhida está associada a um subsistema do SIN. O Sudeste é representado pela usina ITAIPU, o Nordeste é representado pela usina Sobradinho, o Norte é representado pela usina Tucuruí e por fim o Sul é representado pela usina Campos Novos.

Para cada usina, apresenta-se o ensemble para o cenário SSP245 e SSP585.

Embora esses gráficos representem usinas individuais, eles refletem os padrões observados nos subsistemas do SIN. De modo geral, percebe-se uma tendência de redução das vazões médias em relação ao histórico nos sistemas Sudeste, Norte e Nordeste, enquanto o sistema Sul apresenta uma tendência oposta, com aumento das vazões médias.

Contudo, destaca-se que o sistema Sudeste exibe uma maior heterogeneidade em comparação com o Nordeste e o Norte, havendo usinas para as quais a redução das vazões médias não é tão pronunciada. A Figura 58, por exemplo, apresenta os cenários para as usinas Santo Antônio e Três Marias, localizadas no sistema Sudeste, onde a diferença entre o perfil histórico e a média do ensemble é significativamente menor e, a média do ensemble chega a ser inferior ao histórico para os meses mais úmidos.

Observa-se uma grande variabilidade na resposta dos modelos climáticos para todas as usinas, com diferenças significativas entre os modelos que indicam efeitos opostos, seja de aumento ou de redução das vazões. No caso de Sobradinho e Tucuruí, apesar dessa elevada variabilidade, a média histórica se posiciona acima até mesmo do quantil superior utilizado para representar a distribuição dos cenários, reforçando ainda mais a percepção de uma redução expressiva nas vazões para esses sistemas.




Figura 57: Projeção de vazões para o ensemble de modelos




Figura 58: Projeção de vazões para o ensemble de modelos (adicional)

Conforme descrito na seção de metodologia, foi proposta uma abordagem para representar os modelos estocásticos de vazões, baseada em uma cadeia de modelos ARp integrados por meio de um modelo de Markov, cujos estados discretos correspondem a diferentes níveis de aumento de temperatura. Dessa forma, para cada nível esperado de aumento de temperatura, é atribuído um conjunto distinto de parâmetros ARp a cada usina hidrelétrica e modelo GCM. Essa proposta contrasta diretamente com a abordagem de adotar a premissa de estacionariedade, na qual um único modelo ARp é estimado para todo o período analisado.

Para assegurar a consistência dos estados discretos entre todos os modelos GCM, foi criada uma única amostra abrangente (conjunto T_{Δ}), composta por todos os possíveis valores de variação da temperatura média anual em relação à média do período histórico de referência. Essa amostra unificada considerou as projeções de todos os modelos GCM e as duas trajetórias de emissões, SSP245 e SSP585.

Após testes preliminares, optou-se por representar o modelo utilizando três clusters, com os níveis discretos de aumento de temperatura definidos pela divisão da distribuição de probabilidade empírica do conjunto T_{Δ} . Essa divisão foi realizada com base no cálculo de dois quantis: $q_1 = 0.333$; $q_2 = 0.666$, que equivalem as temperaturas: 1.59°C e 2.27°C

- Cluster 1 – Composto pelos anos em que a variação de temperatura em relação ao período de referência é inferior a 1.59°C ;
- Cluster 2 – Composto pelos anos em que a variação de temperatura em relação ao período de referência está entre 1.59°C e 2.27°C ;
- Cluster 3 – Composto pelos anos em que a variação de temperatura em relação ao período de referência é superior a 2.27°C


A partir desta definição, os modelos estocásticos ARp foram estimados para todas as usinas hidrelétricas e para todos os modelos GCM, com as estimativas realizadas de forma independente para cada modelo GCM. Essa estimativa foi realizada considerando duas abordagens: a premissa de um único modelo estacionário válido para todo o período de estudo e a abordagem de múltiplos modelos integrados por uma cadeia de Markov.

A **Figura 59** ilustra as distribuições de probabilidade das vazões médias anuais simuladas a partir desses modelos para o mesmo conjunto de hidrelétricas exemplificado anteriormente. São apresentados os resultados para dois modelos GCM distintos, escolhidos entre os primeiros no ranking de classificação.

Os resultados estão expressos em valores percentuais em relação à MLT. A linha tracejada representa a distribuição obtida sob a premissa de um único modelo estacionário, enquanto as áreas coloridas representam as distribuições geradas para cada modelo ARp individualmente. A área azul corresponde aos cenários gerados com o modelo ARp do cluster 1 (parâmetros calculados com base nos anos classificados nesse cluster), a área verde aos cenários gerados com o modelo ARp do cluster 2, e a área vermelha aos cenários gerados com o modelo ARp do cluster 3.

Embora seja esperado que os resultados variem significativamente conforme o modelo GCM avaliado, os exemplos apresentados revelam uma clara diferença de padrões entre as vazões simuladas para cada cluster. Essa distinção ocorre mesmo que os clusters tenham sido definidos com base no aumento da temperatura e não diretamente nas vazões, que iria forçar diferença nos padrões pelo próprio critério de definição dos clusters. Para as usinas analisadas, observa-se que as condições mais críticas estão consistentemente associadas ao cluster 3, que representa o maior aumento na temperatura. Isso é evidente tanto para as usinas onde o impacto mais severo está relacionado ao aumento de períodos de seca, como ITAIPU, SOBRADINHO e TUCURUÍ, quanto para CAMPOS NOVOS, onde o efeito projetado é o de grande aumento da precipitação.

Vale ressaltar que as distribuições individuais foram geradas de forma independente, assumindo a hipótese de que os clusters são equiprováveis. Na prática, no entanto, essa condição não é real, e espera-se que, ao gerar os cenários de forma independente, mas considerando as probabilidades reais (estimadas) de cada cluster, a distribuição final se aproxime da distribuição obtida sem a representação dos grupos, indicada pela linha tracejada.






Figura 59: Distribuição de Probabilidade das Vazões Anuais Simuladas por Grupos

Um dos argumentos mais importantes pelo uso de cadeia de Markov é a hipótese da melhoria da representação da dinâmica interanual das vazões, dado a dificuldade do modelo ARp de representar dinâmicas mais longas, conforme estabelecido na seção metodológica.

Desta maneira, foi proposto um teste para avaliar a capacidade dos modelos ARp em gerar cenários de secas mais longas, comparando-se os resultados dos modelos estimados com as duas abordagens.

O teste prático consistiu em gerar 1200 cenários¹⁰ de 3 anos¹¹, tanto pelo modelo ARp único, quanto pela cadeia de Markov, computar as distribuições de probabilidade das vazões médias nestes 3 anos acumulados, e comparar a representatividade dos cenários mais críticos nas caldas

¹⁰ 1200 é o número de cenários normalmente utilizados pela PSR na avaliação do PMO.

¹¹ Foram gerados ainda 5 anos de período de inicialização, para que os cenários se originem de condições aleatórias, independentes da condição inicial.

das distribuições (região abaixo do quantil 0.05).

A comparação foi realizada por meio do teste KS (Kolmogorov-Smirnov), que avaliou a hipótese nula de que a distribuição acumulada das amostras geradas pelo modelo de Markov não estar significativamente acima da das amostras geradas pelo modelo ARp único.

Mais especificamente:

H₀: (hipótese nula): A distribuição acumulada (CDF) das séries geradas com Markov é menor ou igual à gerada sem Markov;

H₁ (hipótese alternativa): A distribuição acumulada (CDF) das séries geradas com Markov é maior que a gerada sem Markov;

A estatística do teste KS mede a maior diferença unilateral entre as distribuições acumuladas empíricas das duas amostras. Quanto maior a estatística, maior a evidência contra a hipótese nula.

O **p-value** indica a probabilidade de observarmos um valor da estatística KS tão extremo quanto o calculado (ou mais), assumindo que a hipótese nula é verdadeira.

- **Se $p\text{-value} \leq \alpha$ (nível de significância, adotado 0.05):** Rejeitamos a hipótese nula, indicando que as séries geradas com a representação de Markov tendem a gerar valores menores que as séries geradas com o modelo sem Markov.

- **Se $p\text{-value} > \alpha$:** Não rejeitamos a hipótese nula, indicando que não há evidências suficientes para afirmar que as séries geradas com a representação de Markov tendem a gerar valores menores que as séries geradas sem o modelo de Markov.

O teste foi feito individualmente por usina, mas considerando-se a combinação de todos os modelos GCMs e todas as usinas.

Para facilitar a interpretação dos resultados, a **Figura 58** apresenta quatro casos pontuais. A linha azul representa a distribuição de probabilidade dos cenários mais secos sem a representação com Markov, enquanto a linha vermelha corresponde à distribuição de probabilidade dos cenários mais secos com a representação com Markov. Como referência adicional, foi incluída uma linha pontilhada laranja, que indica o período de 3 anos mais seco do histórico observado. É importante ressaltar que este valor serve apenas como referência, pois o objetivo principal desta avaliação não é verificar se os modelos estocásticos conseguem reproduzir a sequência mais crítica do histórico, uma vez que isso depende das características específicas de cada modelo GCM.

Os dois gráficos superiores (SOBRADINHO – EC-Earth3 e ITAPEBI – GFDL-ESM4) ilustram casos em que o teste estatístico indicou que o modelo com Markov apresenta uma melhor capacidade de representar cenários críticos em comparação ao modelo sem Markov (**$p\text{-value} \leq 0.05$**). Já os dois gráficos inferiores (STO ANTONIO – EC-Earth3 e ITAIPU – GFDL-ESM4) representam situações em que o teste estatístico revelou que não há evidências para concluir que o modelo com Markov seja capaz de produzir cenários mais críticos que o modelo sem Markov (**$p\text{-value} > 0.05$**).

Destaca-se que, nos dois casos superiores, a pior sequência do histórico se aproxima da moda da distribuição dos cenários críticos gerados pelo modelo com Markov. Em contrapartida, para ITAIPU, ambas as representações atribuem uma probabilidade relativamente baixa à ocorrência da pior sequência histórica.




Figura 60: Exemplificação Visual dos Resultados do Teste Realizado

Ao consolidar os resultados de todas as usinas e modelos GCM, verificou-se que, em aproximadamente 63% dos casos, o modelo sem Markov foi suficiente para capturar os cenários mais secos. Por outro lado, em cerca de 37% dos casos, o modelo com Markov conseguiu gerar cenários mais críticos do que aqueles produzidos pelo modelo sem Markov.

Observa-se que o impacto da representação por meio do modelo de Markov pode aumentar significativamente em análises mais específicas. Por exemplo, ao restringir a análise ao subconjunto de modelos climáticos que projetam as maiores variações de temperatura, onde os três clusters possuem maior representatividade, o percentual de casos em que o modelo de Markov é indispensável para a geração dos cenários mais críticos aumenta para 48%.

Assim, recomenda-se que a avaliação do benefício do uso da representação com Markov seja também realizada no contexto da operação do sistema, ou seja, no escopo do Produto 5. Essa abordagem permitirá verificar se a maior diversidade de cenários críticos gerados por essa representação contribui, de fato, para operações mais robustas do sistema no contexto da representação das mudanças climáticas.


Séries de Geração Eólica

Na **Figura 61** são apresentadas as projeções dos fatores de capacidade futuros para usinas eólicas localizadas nos 4 estados com maiores níveis de participação percentual deste tipo de geração. Observa-se que, de maneira geral, não há um deslocamento significativo da média do ensemble em relação à média histórica. As mudanças são mais evidentes para as eólicas nos estados do RN e BA, enquanto para os estados do CE e RS, o deslocamento é mais sutil.

No entanto, a variabilidade entre os modelos é bastante acentuada, apresentando uma divisão relativamente equilibrada entre os que indicam aumento e os que indicam redução no fator de capacidade das usinas. Entre os estados avaliados, o RS se destaca como aquele com a maior dispersão, especialmente nos últimos meses do ano.

Ao comparar os cenários climáticos SSP245 e SSP585, observa-se uma leve diferença nas respostas dos modelos, sendo o principal efeito o aumento dos quantis superiores no cenário SSP585. A consolidação dos cenários por sistema do SIN é apresentada na **Figura 62**.

A projeção da potência média disponível por mês tomou como referência a potência de cada usina ao final de 2024, conforme especificado no Programa Mensal de Operação Energética (PMO) de setembro de 2024.







Figura 61: Projeção de fator de capacidade das eólicas para o ensemble de modelos






Figura 62: Projeção da potência média por sistema para o ensemble de modelos

Séries de Geração Solar

Na Figura 63 são apresentadas as projeções dos fatores de capacidade futuros, para usinas solares localizadas nos 4 estados com maiores níveis de participação percentual deste tipo de geração.

Comparando com os resultados obtidos para as demais fontes analisadas, a geração solar demonstra uma variabilidade menor. Tanto nos resultados individuais quanto no agregado por sistema, as duas faixas de quantis permanecem bastante próximas. Essa característica é consistente para ambas as trajetórias de emissões, SSP245 e SSP585, sem diferenças significativas nas dispersões do ensemble dessas trajetórias.

Além disso, não se observa um deslocamento relevante da média do ensemble em relação à média histórica. Entre os resultados individuais analisados, apenas a solar de MG apresenta um deslocamento mais acentuado, e mesmo assim, restrito aos últimos três meses do ano. Esse efeito também é refletido no resultado do sistema Sudeste, embora com menor intensidade.

Assim como para a geração eólica, a projeção da potência média disponível por mês tomou como referência a potência de cada usina ao final de 2024, conforme especificado no Programa Mensal de Operação Energética (PMO) de setembro de 2024.




Figura 63: Projeção de fator de capacidade das solares para o ensemble de modelos




Figura 64: Projeção da potência média por sistema para o ensemble de modelos

7. Impacto das Mudanças Climáticas sobre Bioeletricidade

A bioeletricidade, especialmente aquela gerada a partir do bagaço de cana-de-açúcar, desempenha um papel importante na matriz elétrica brasileira. Segundo a União da Indústria de Cana-de-Açúcar e Bioenergia (Unica) [12] as usinas de cana-de-açúcar forneceram 21 TWh de eletricidade ao SIN em 2023.

Em 2024, o Operador Nacional do Sistema Elétrico (ONS) reportou uma geração total de 642,9 TWh no Sistema Interligado Nacional (SIN), dos quais 68,6 TWh foram provenientes de usinas térmicas. Dentre essas, 23,3 TWh foram gerados a partir de biomassa, representando 3,6% do total de energia elétrica produzida no país. Este valor reflete a relevância dessa fonte para complementar a geração de energia no Brasil, em especial nos períodos de baixa produção hídrica.

No entanto, não se espera uma expansão significativa da bioeletricidade na matriz elétrica brasileira nos próximos anos. A maior competitividade de outras fontes renováveis, como solar e eólica, com custos de geração decrescentes, tende a limitar o crescimento da participação da biomassa no sistema elétrico. Além disso, o bagaço de cana-de-açúcar, principal insumo para a geração de bioeletricidade, enfrenta crescente concorrência de usos alternativos. Entre esses usos estão a produção de etanol de segunda geração, o biochar — que aumenta a produtividade agrícola e contribui para a captura de carbono —, além de outras aplicações que geram créditos de carbono e benefícios ambientais adicionais.

Dada essa conjuntura, a hipótese adotada neste estudo considera a manutenção da capacidade atual de geração de bioeletricidade. Essa capacidade não será ajustada diretamente por modelagem vinculada a cenários climáticos, como ocorre com as fontes hidrelétrica, solar e eólica. Em vez disso, o estudo se baseará em referências da literatura especializada para realizar análises indiretas sobre o desempenho e as perspectivas dessa fonte. Assim, busca-se compreender e contextualizar o papel atual e futuro da bioeletricidade no contexto energético brasileiro.

O impacto das mudanças climáticas na bioeletricidade do Brasil pode ser avaliado a partir da referência [13]. Nessa dissertação, um modelo denominado CAT - *Crop Assessment Tool* - desenvolvido pelo Laboratório Nacional de Biorrenováveis foi utilizado de forma a relacionar a produtividade de canaviais com relação às variáveis climáticas. A metodologia empregada no CAT é de zoneamento agroecológico da Organização das Nações Unidas para Alimentação e Agricultura (FAO) [14].

O CAT baseia-se em dados climáticos e fatores fisiológicos da cultura agrícola para estimar a produtividade potencial, sendo a máxima produtividade alcançada por uma cultura sem restrição hídrica, nutricional e fitossanitária. A produtividade atingível considera o déficit hídrico, ou seja, a água como fator limitante e suas conseqüentes implicações para a planta.

O valor da produtividade da cana-de-açúcar do tipo “soca” é calculado pela média ponderada, considerando que 30% da colheita é realizada no início de safra, 40% no meio e 30% no final,

¹² UNICA. Bioeletricidade em números. [s.l.: s.n.]. Disponível em: . Acesso em: 2 mar. 2024.

¹³ Petrielli, Gabriel Palma: *Avaliação georreferenciada dos impactos das mudanças climáticas na produção de cana-de açúcar no Brasil*, dissertação de MSc da Faculdade de Engenharia Mecânica, Programa de Pós-Graduação em Planejamento de Sistemas Energéticos - UNICAMP, 2024.

¹⁴ DOORENBOS, J.; KASSAM, A. FAO Irrigation and Drainage Paper 33 - Yield Response to Water. 1979.

considerada a distribuição mais representativa após consulta com especialistas. Devido à renovação do canavial, foi considerado que 20% da produtividade provém de cana de-açúcar recém-plantada e 80% provém de rebrotas (tipo “soca”).

Considerando os resultados climáticos espacializados recortados para as áreas de cultivo de cana de açúcar no Brasil e atuais, foram avaliadas as variações esperadas de variáveis climáticas como precipitação e temperatura para, com o uso do CAT, estimar os impactos sobre a produtividade futura dos canaviais com relação à produtividade histórica. O trabalho não considera aspectos de adaptação, como a seleção de cepas mais adaptadas às novas condições climáticas ou uso mais disseminado de irrigação para compensar eventuais déficits hídricos. Sendo assim, os resultados precisam ser avaliados com alguma cautela.

O trabalho utilizou dados climáticos regionalizados pelo INPE tanto para modelos CMIP5 (cenários RCP 4.5, RCP 8.5) como CMIP6 (SSP126 e SSP585), respectivamente do 5º e 6º relatórios de avaliação do IPCC para horizonte até o final do século. A figura a seguir ilustra os valores médios mensais da variação da precipitação para o cenário do CMIP6 SSP585 para o período 2060-2099 com relação à precipitação histórica.




Figura 65: Diferença na precipitação média mensal

Observa-se que, para os modelos estudados, a maior parte da região de interesse para o cultivo da cana terá uma redução da precipitação, com consequente impacto na produtividade. Os resultados indicam impactos na produção de cana-de-açúcar, principalmente para os cenários de maior concentração de carbono, como o SSP585. Nesse caso, uma parte da área avaliada terá queda de produtividade superior a 15 toneladas por hectare. As projeções dos modelos do CMIP5 apresentaram maior queda na produtividade em relação às do CMIP6, associados à redução mais contundente da precipitação em boa parte da região estudada. Os valores abaixo indicam a variação para os modelos CMIP6.




Figura 66: Diferença na produtividade média para diferentes horizontes e cenários SSP par CMIP6

Apesar do possível impacto positivo das mudanças climáticas na produtividade em algumas regiões isoladas, a maior parte da região estudada apresentou queda na produtividade. O estudo também avaliou os impactos para possíveis áreas de expansão de canaviais no Brasil, com resultados semelhantes.

Considerando a redução de produtividade da ordem de 10%, os impactos das mudanças climáticas diminuiriam em até 2 TWh a bioeletricidade produzida e fornecida ao SIN.

Naturalmente tal redução avalia somente a perspectiva de queda de produtividade para a produção atual. Como já dito, esse número pode ser reduzido se houver maior desenvolvimento de usos concorrentes para o bagaço da cana de açúcar, como a produção de etanol de segunda geração ou produção de biocombustíveis avançados por processos que utilizem essa biomassa.

Considerando: (i) a menor representatividade da bioeletricidade na matriz, que deve se reduzir ainda mais ao longo do tempo, pelo avanço de outras fontes, como solar e eólica; (ii) o impacto climático compatível com esse estudo seria o do horizonte até 2059 porque uma demanda igual ao dobro daquela de 2023 deverá ocorrer nessa janela de tempo, mesmo considerando para uma taxa de crescimento moderada; (iii) os resultados climáticos mais recentes do CMIP6; (iv) o ritmo de emissões está mais ligado ao cenário de maior concentração de CO₂ na atmosfera (SSP5), conclui-se que:

A perda de produtividade da cana no Brasil terá baixo impacto sobre o setor elétrico, razão pela qual não será detalhada como as demais fontes renováveis nesse estudo.

8.Referências

1. EPE, BEN Interativo - 2024. Acessado em <https://dashboard.epe.gov.br/apps/ben/>
2. Earth System Grid Federation. <https://doi.org/10.22033/ESGF/CMIP6.14361>
3. Wind farm technical regulations, potential estimation and siting assessment. Rijeka, Croatia: InTech; 2011. <http://dx.doi.org/10.5772/20669>.
4. Mapping the performance of PV modules, effects of module type and data averaging. Sol Energy 2010;84(2):324e38. URL, <http://www.sciencedirect.com/science/article/pii/S0038092X0900293X>.
5. Painel de Monitoramento do Consumo de Energia Elétrica – EPE. Acessado em: <https://www.epe.gov.br/pt/publicacoes-dados-abertos/dados-abertos>
6. Dados abertos ONS. <https://dados.ons.org.br/organization/ons>.
7. *Avaliação georreferenciada dos impactos das mudanças climáticas na produção de cana-de açúcar no Brasil*, dissertação de MSc da Faculdade de Engenharia Mecânica, Programa de Pós-Graduação em Planejamento de Sistemas Energéticos - UNICAMP, 2024, disponível em www.repositorio.unicamp.br/acervo/detalhe/1403346

Projeto: Sistemas de Energia do Futuro III

Estudo: Impactos das Mudanças Climáticas no Planejamento da Geração de Energia Elétrica

Cliente: GIZ

Documento: Produto 2