

GRUPO DE ESTUDO COMERCIALIZAÇÃO, ECONOMIA E REGULAÇÃO DO MERCADO DE ENERGIA ELÉTRICA - GCR

MAXIMIZAÇÃO DA ARBITRAGEM EM TEMPO REAL DE PLANTAS HÍBRIDAS COM BESS UTILIZANDO *REINFORCEMENT LEARNING*

Heitor Araújo Nunes¹, Eduardo Sodré¹, Rafael de O. Fernandes^{2,3}, André Victor R. N. da Silva⁴, Luiz Gustavo de S. Duda¹, Roberto F. Dias Filho^{1,5}, Ivan Nunes da Silva²

¹Escola Politécnica de Pernambuco (POLI), Universidade de Pernambuco (UPE)

²USP-EESC, ³Equans France, ⁴Aeroespacial, ⁵Clean Horizon

RESUMO

Num cenário de crescimento de fontes renováveis na matriz elétrica brasileira, marcada pela intermitência da geração fotovoltaica e eólica, problemas como cortes de geração (*curtailment*) desafiam o setor elétrico a buscar meios de conciliar a operação do sistema elétrico e a comercialização de energia, de modo a coordenar devidamente cada agente do setor. Uma alternativa para solucionar este impasse é o aprimoramento da utilização do BESS (*Battery Energy Storage System*) no que diz respeito à viabilidade de sua integração com usinas híbridas (fotovoltaica e eólica), visando aproveitar os melhores momentos de geração e de demanda por meio da arbitragem de energia. Assim, este trabalho propõe uma estratégia para maximizar a receita operacional em base horária de uma Usina Híbrida + BESS (UHB), com horizonte de 24 horas à frente, utilizando-se de técnicas de *Reinforcement Learning* (RL). Nele, é apresentada uma proposta preliminar para uma otimização estocástica da operação do BESS considerando as incertezas de geração e do Preço da Liquidação das Diferenças (PLD). Além disso, a fim de tornar a análise mais realista, é considerado o efeito da perda de vida útil da bateria devido aos ciclos de carga/descarga, por meio da curva DoD (*Depth of Discharge*).

PALAVRAS-CHAVE

Usina Híbrida, BESS, Arbitragem de Energia, *Reinforcement Learning*, *Depth of Discharge*, *Epsilon-Greedy*, Lógica Fuzzy.

1.0 INTRODUÇÃO

Usinas fotovoltaicas e parques eólicos estão mudando cada vez mais o cenário elétrico brasileiro, permitindo uma maior diversidade de geração de energia elétrica sustentável. No entanto, a inclusão dessas fontes de energia traz consigo alguns desafios operacionais, dos quais a sua natureza intermitente se destaca por impedir que tais fontes geradoras sejam despacháveis, a menos que estejam acopladas a um sistema de armazenamento de energia [1]. Esses sistemas, conhecidos como BESS (*Battery Energy Storage System*), geralmente são baterias de íon-lítio, devido aos inúmeros benefícios que oferecem, mesmo estando sujeitas à degradação pelo uso e pelo tempo.

A integração do BESS com as plantas híbridas promove uma maior integração das fontes renováveis eólica e solar no sistema elétrico brasileiro, contribuindo para o aumento do percentual de energias limpas na matriz elétrica, garantindo um melhor controle de despacho dessas usinas e evitando cortes de geração (*curtailment*) [2], beneficiando os setores de operação do sistema e econômico. Somado a esses benefícios tem-se que o BESS pode realizar serviços ancilares, aumentando, assim, a confiabilidade do SIN (Sistema Interligado Nacional).

O BESS é uma tecnologia promissora, cuja viabilidade econômica ainda é um desafio, muito embora esteja cada vez mais próxima devido às mudanças da regulação e ao Leilão de Reserva de Capacidade (LRCAP 2025). Ele traz consigo a possibilidade de armazenar energia em momentos de alta geração e baixo consumo, quando o preço da energia está baixo, e liberá-la quando a demanda cresce e o preço horário da energia é mais alto. Isso permite um maior aproveitamento de usinas eólicas e solares, uma vez que ambas podem carregar o BESS em momentos de geração abundante e descarregá-lo quando for requisitado.

Nesse contexto, o presente Informe Técnico busca contribuir de forma prática com a operação de uma Usina Híbrida + BESS (UHB), com o intuito de aproveitar os momentos de maior geração solar e eólica, além de maximizar a receita recebida pelo proprietário da UHB e minimizar sua exposição ao MCP (Mercado de Curto Prazo) através de técnicas de *Reinforcement Learning* (RL). Para tanto, faz-se necessária a realização de modelagens estocásticas das previsões de geração eólica e fotovoltaica e das incertezas do preço do PLD (Preço de Liquidação das Diferenças), bem como da perda de vida útil da bateria por meio da Curva DoD (*Depth of Discharge*), a fim de permitir que o BESS planeje sua tomada de decisões com um dia de antecedência, conforme trabalho de E. Sodré [3].

Este trabalho está dividido da seguinte forma: na Seção 2 é apresentado o desafio da arbitragem de preço e a abordagem matemática do problema, na Seção 3 é apresentado o método de *Reinforcement Learning*, na Seção 4 a metodologia proposta, na Seção 5 os resultados das simulações, e por fim, na Seção 6 a conclusão do trabalho.

2.0 ARBITRAGEM DA PLANTA HÍBRIDA COM BESS

A integração de Planta Híbridas com o BESS tem dois objetivos principais. O primeiro é o aumento da rentabilidade operacional de forma estratégica através da compra e venda de energia em momentos em que o preço da energia está mais baixo e mais alto, respectivamente. A famosa arbitragem de energia. O segundo é a realização de serviços ancilares [4].

Entretanto, ao se realizar a arbitragem de energia, é preciso considerar os efeitos a longo prazo, de modo a traçar um planejamento da operação do BESS de forma mais realista e assertivo. À medida que os ciclos de carga e descarga do BESS são efetuados, a bateria diminui sua capacidade de armazenamento por meio da curva de *Depth of Discharge* (DoD). Assim, quanto mais curtos são os ciclos, mais ciclos poderão ser realizados e vice-versa. Portanto, garantir a otimização em tempo real desses sistemas é primordial para maximizar a receita e a vida útil das baterias e minimizar as falhas que poderiam resultar em custos adicionais ou perda de eficiência [5].

Nesse contexto, é imprescindível realizar modelagens estocásticas que servirão de indicadores para a tomada de decisão do BESS [6]. Um aspecto fundamental dessa abordagem é a utilização de sistemas de gerenciamento de energia em tempo real (EMS), que são capazes de responder rapidamente a mudanças no mercado de energia e compensar erros nas previsões de geração renovável e PLD. Eles se ajustam continuamente para cumprir o melhor desempenho possível sem a necessidade dessas previsões serem perfeitamente precisas.

2.1 Formulação Matemática do Problema de Tomada de Decisão Estocástica

Usinas fotovoltaicas e parques eólicos por si só não configuram como um problema de tomada de decisão, porque, por conta de sua natureza intermitente, o despacho de energia é realizado à medida que a energia é gerada, tendo como único controle apenas o corte de geração, quando necessário. Entretanto, com a inclusão do BESS, um processo de tomada de decisão é criado, uma vez que o BESS atua de forma análoga a uma usina térmica, cujo despacho de energia é totalmente controlado. Assim, é necessário definir o momento que ele deve carregar e descarregar, de modo a executá-lo de forma inteligente, visando maximizar a receita obtida pela arbitragem de energia.

Trata-se, portanto, de um problema estocástico, devido às incertezas envolvidas no processo, tais como: a geração eólica e fotovoltaica e o preço do PLD. Essas variáveis dificultam ou inviabilizam a realização de quaisquer modelagens determinísticas, uma vez que é necessário simular uma quantidade considerável de cenários para se obter dados mais confiáveis e com seus respectivos índices de risco.

A incerteza da geração eólica é dependente da dinâmica dos ventos onde o parque é colocado. No caso da fotovoltaica, a geração tem um perfil mais conhecido, já que é certo que haverá uma geração nula durante a noite e que vai crescendo à medida que o sol nasce até por volta do meio-dia, seguida de uma queda durante à tarde até o pôr-do-sol. O PLD, por sua vez, é conhecido com um dia de antecedência, de acordo com as práticas da Câmara de Comercialização de Energia Elétrica (CCEE), embasadas no Art. 57 do Decreto 5.163 de 30 de julho de 2004, contudo, para horizontes maiores de tempo, o PLD é incerto [7, 8]. Nesta obra, mesmo lidando com um horizonte de 24h, será considerado o PLD desconhecido, a fim de generalizar para múltiplos cenários.

2.2 Importância da Perda de Vida Útil do BESS

O BESS, como qualquer outro componente real, está sujeito ao desgaste provocado pelo tempo e pelo uso. Levar em consideração a perda de vida útil na otimização da operação de um BESS é primordial para garantir resultados mais realistas e mais assertivos, além de permitir análises por outros ângulos. No âmbito da arbitragem de energia, ao desconsiderar a perda de vida útil do BESS e considerá-lo como ideal, a análise fica restrita ao retorno financeiro que a UHB proporciona num determinado intervalo de tempo, assim, técnicas promissoras podem ser descartadas porque obtiveram resultados instantâneos inferiores.

Neste artigo, por meio do Índice BESS (I-BESS), descrito na Seção 5, poderá ser visto que o uso de certas técnicas pode otimizar o despacho de energia do BESS, de modo que este proporcione bons retornos e que poupem a vida útil da bateria. Assim, revelando que considerar a operação do BESS sem perda de vida útil é uma visão extremamente limitada sobre o problema de arbitragem de energia de uma UHB.

3.0 REINFORCEMENT LEARNING

Com o advento da tecnologia, as tomadas de decisões passaram a ser complexas e a exigir uma rapidez cada vez maior, de modo que se tornou necessário buscar técnicas mais rápidas e eficientes para resolver os problemas que apareciam. Neste contexto, o *Reinforcement Learning* surge, no âmbito do *Machine Learning*, com o objetivo de otimizar a tomada de decisões, analisando alguns cenários possíveis, realizando suas escolhas e esperando seus retornos para, enfim, selecionar a que obteve melhor êxito. Assim, o RL consiste num agente, que é o responsável pelas escolhas feitas; nas ações, que são as decisões tomadas; num ambiente, que é o meio no qual o agente interage executando seus comandos; e na recompensa, que servirá de métrica para decidir se as ações realizadas foram boas ou não [9].

A fim de executar suas ações, o *Reinforcement Learning* se baseia em alguns princípios. O primeiro deles é o aprendizado por tentativa e erro (*trial-and-error*), no qual a máquina tomará decisões num mesmo ambiente e verá qual recompensa retornará; isso é crucial quando se lida com cenários desconhecidos, além de ser simples sua implementação computacional. O segundo é o da recompensa tardia (*delayed reward*), pois uma decisão afeta não apenas a escolha presente, mas também as futuras, o que torna o processo de aprendizado mais complexo e realista. O último princípio é o dilema da exploração-exploração (*exploration-exploitation dilemma*); nele o agente decide se ele deseja explorar (refinar uma ação promissora, a fim de tentar maximizar os seus retornos) ou explorar (tomar ações diferentes que podem ser melhores que a atual, evitando mínimos ou máximos locais) [9, 10].

Os algoritmos de *Reinforcement Learning* podem ser classificados em três grandes famílias, a depender do modo como resolvem seus problemas. A primeira são os algoritmos baseados em política (*Policy-Based Algorithms*), no qual a otimização é obtida a partir de uma política pré-determinada, como é o caso do REINFORCE, o que permite achar um máximo ou mínimo local. A segunda são os algoritmos baseados em valor (*Value-Based Algorithms*), cuja otimização é feita através de uma função que analisa a ação e o estado, a fim de determinar a política a ser empregada, como é o caso do *Epsilon-Greedy* e do *Deep Q-Networks* (DQN). A terceira são os algoritmos baseados em modelo (*Model-Based Algorithms*) que buscam estudar a dinâmica do ambiente, prevendo ações possíveis e suas respectivas consequências sem, necessariamente, agir de imediato, como é o exemplo do *Monte Carlo Tree Search* (MCTS). Existem ainda algoritmos que mesclam características de famílias distintas, de modo a aproveitar o melhor de cada uma delas, como é o caso da *Proximal Policy Optimization* (PPO) [11].

Algoritmos gananciosos (*greedy*) são simples de implementar, pois eles não analisam todas as possibilidades possíveis, prezando pelo aprendizado por tentativa e erro. Entretanto, eles estão sujeitos a ficar presos em máximos ou mínimos locais, de modo que soluções melhores não sejam exploradas. Para contornar esse efeito, o *Epsilon-Greedy* surge propondo uma ponderação entre a chance de explorar uma determinada solução ou explorar novas alternativas. Ao agir dessa forma, corre-se o risco de explorar soluções que sejam piores do que a alternativa atual, em contrapartida, também permite que novas soluções ainda melhores sejam encontradas [10, 11].

O *Epsilon-Greedy* pode ser implementado de duas maneiras: com ϵ fixo ou variável. Na primeira situação, a chance de exploração (ϵ) é mantida constante de modo que o algoritmo sempre tenha a mesma probabilidade de refinar uma solução ou desbravar outra promissora. No segundo caso, a variação pode acontecer das mais variadas formas. A mais usual é considerar que, no início do algoritmo, é preciso explorar mais para conhecer o ambiente. À medida que ele é conhecido, busca-se aumentar a exploração, a fim de otimizar o retorno [10]. Entretanto, em cenários mais complexos, o ϵ não necessariamente segue uma regra de queda constante, ele pode variar de acordo com a lógica apresentado para determinado problema. Neste artigo, é apresentada na Seção 4 uma lógica *fuzzy* para variar a relação exploração-exploração entre as decisões que o BESS pode tomar.

4.0 METODOLOGIA PROPOSTA

O complexo híbrido em questão segue o exemplo de N. G. Rocha et al. [12], sendo composto por um parque eólico e uma planta fotovoltaica de 15 MW_{inst} cada, adicionando-se um sistema de armazenamento de 5 MW / 20 MWh. Adicionalmente, será considerado no problema de otimização a degradação da vida útil do BESS, que conta com 3000 ciclos de carga e descarga de 20 MWh, conforme a curva DoD (*Depth of Discharge*). A eficiência do BESS utilizada neste trabalho será de 97%, tanto para carga quanto para descarga. Nesta obra não será utilizada a técnica convencional da Programação Dinâmica Dual Estocástica (PDDE) utilizada em [12].

Para atingir a otimização desejada, foram modeladas em Python as incertezas envolvidas, ou seja, as gerações eólica e fotovoltaica e o PLD de modo a simular seus comportamentos 24 horas à frente, sem considerar correlação entre elas. A geração eólica foi modelada por meio de uma função de densidade de probabilidade Gaussiana cuja média é 7 MW e desvio padrão 2 MW, sendo limitada aos 15 MW de potência instalada.

Já a geração fotovoltaica foi modelada da seguinte forma: foi considerada uma Gaussiana para cada hora simulada. Cada uma das 12 Gaussinas, construídas para cada hora das 06h00 às 18h00, tem sua própria média e desvio padrão. Os valores médios para cada uma das 12 horas consideradas foram extraídos de um complexo fotovoltaico localizado em Pernambuco, o Conjunto Tacaratu (10 MW_{inst}), para os dias do mês de janeiro de 2025 [13], conforme código Python abaixo. O desvio padrão para cada uma das 12 horas foi o mesmo e igual a 0,3 MW.

$valores_medios_ger_fotovoltaica = [0.27, 1.34, 2.47, 3.07, 3.35, 3.66, 3.71, 3.83, 3.36, 2.44, 1.33, 0.22] * 1.5$

O PLD, por sua vez, foi modelado conforme a distribuição lognormal de média R\$ 200,00/MWh e desvio padrão R\$100,00/MWh, sendo limitado pelo PLD mínimo e máximo, que em 2025 é R\$58,60/MWh e R\$ 1.542,23/MWh respectivamente [14].

Com relação ao BESS, ele foi modelado de modo a receber três ações, são elas: carregar, descarregar e fazer nada. Se a opção escolhida for a mesma da iteração anterior, haverá uma exploração, no qual será potencializado os retornos previstos para aquela ação, sejam bons ou ruins. Entretanto, se a decisão for diferente da iteração anterior, é realizada a exploração, que tem como objetivo desbravar novos cenários que podem dar retornos melhores. A fim de obter a receita da operação do BESS, foram aplicados três métodos de otimização: dois envolvendo a técnica de *Reinforcement Learning Epsilon-Greedy* e outro sem usá-lo. No primeiro caso usando RL, foi considerado que a tomada de decisão tem 70% de chance de exploração e 30% de exploração (15% para cada ação). Já na segunda, a probabilidade de cada ação ser executada depende de uma lógica fuzzy que combina a carga atual do BESS com o valor do PLD em cada hora analisada, conforme Fig. 1 (a) e (b). Por fim, a que não usa RL estabelece que o BESS carrega das 10h às 14h e descarrega das 17h às 21h o montante de 5 MWh a cada hora.




Fig. 1 – (a) Lógica fuzzy aplicada ao PLD; (b) Lógica fuzzy aplicada à carga atual do BESS.

Durante o treinamento, as técnicas de *Reinforcement Learning* interagem com o modelo do sistema (“ambiente”), ajustando suas políticas de decisão para maximizar as recompensas acumuladas. A adoção do *Reinforcement Learning* representa uma abordagem inovadora e eficiente em relação às técnicas tradicionais. Isso permite a adaptação dinâmica, a otimização contínua e promove a eficiência energética, a sustentabilidade dessas plantas híbridas e a transição global para fontes de energia mais limpas e eficientes.

4.1 Modelagem Utilizada para Perda de Vida Útil do BESS

Sendo o BESS de 20 MWh / 5 MW e com garantia do fabricante para 3000 ciclos, a modelagem da perda de vida útil utilizada neste trabalho foi considerar que o BESS pode descarregar o total de $20 \text{ MWh} * 3000 = 60000 \text{ MWh}$ até a perda de sua vida útil total. Ou seja, caso cada ciclo carga/descarga seja de 1 MWh, então o operador do BESS pode realizar 60000 ciclos dessa espécie, conforme Fig. 2.

A simulação da perda de vida útil do BESS foi modelada através de uma função que garante que o produto entre o número de ciclos e a energia despachada sejam sempre iguais a 60.000 MWh, independentemente da amplitude da descarga. Assim, a cada megawatt-hora despachado pelo BESS, a vida útil dele é reduzida até zerar. Como o horizonte de tempo usado na simulação foi de apenas 24h, não há riscos da vida útil do BESS se esgotar.




Fig. 2 – Vida Útil.

5.0 RESULTADOS

Após realizar as simulações dos 5.000 cenários, foi constatado, conforme a Tabela 1, que num horizonte de 24h (curto prazo), a operação fixa forneceu maior retorno financeiro frente às que utilizaram o *Reinforcement Learning* e ainda um menor desvio padrão. Dentre as opções envolvendo RL, a lógica *fuzzy* implementada proporcionou resultados com menor variância, mesmo embora gerando uma receita menor. Além disso, os valores de VaR (95%) e o CVaR apresentaram comportamento semelhante aos da receita. Por não se tratar de uma análise de viabilidade, não foi verificada a operação sem o BESS.

Tabela 1 - Análise financeira de curto prazo da UHB.

Técnica	Receita Média Diária (R\$)	Desvio Padrão (%)	VaR (R\$)	CVaR (R\$)
Operação Fixa	47.047,87	11,78%	38.406,42	36.622,71
<i>Epsilon-Greedy</i>	45.661,34	14,70%	35.255,74	33.297,38
<i>Epsilon-Greedy Fuzzy</i>	43.452,83	13,15%	34.539,89	32.722,83

Conforme a Fig. 3, é possível constatar também que o comportamento da receita dos cenários simulados é semelhante a uma distribuição assimétrica à direita, no qual percebe-se que a probabilidade de arrecadar receitas maiores que a média diminui mais acentuadamente do que para valores abaixo dela. Em contrapartida, nos 250 piores casos (5%), é evidenciado que o CVaR se encontra próximo do VaR, o que permite inferir que, mesmo nas piores situações, o prejuízo não é tão pior quanto o VaR.




Fig. 3 - Receita média diária da UHB nos 5000 cenários usando Epsilon-Greedy Fuzzy.

Por outro lado, as técnicas de RL demonstraram mais eficiência que a operação fixa, pois elas foram capazes de proporcionar um despacho de energia do BESS mais inteligente, de modo que as receitas de um dia são menores que a operação fixa, mas a vida útil do BESS é poupada. Com o objetivo de mensurar o quão bem aproveitado foi o despacho do sistema de baterias, foi criado o Índice BESS (I-BESS) que corresponde à receita média arrecadada pela UHB nas 24 horas simuladas, para cada megawatt-hora descarregado do BESS. Quanto maior o I-BESS, melhor foi o aproveitamento do despacho realizado. Ou seja, uma técnica pode apresentar uma receita média menor, mas, em compensação, o BESS terá sua vida útil poupada e poderá operar por mais tempo.

Deste modo, conforme a Tabela 2, fica evidente que o *Epsilon-Greedy* aparece como a alternativa que apresentou o despacho mais racional do BESS, seguido pelo *Epsilon-Greedy Fuzzy*. Em contrapartida, o desvio padrão aponta que a alternativa com maior I-BESS é também a mais arriscada. A operação fixa aparece como a opção mais conservadora e a *Epsilon-Greedy Fuzzy* como uma alternativa intermediária.

Tabela 2 – I-BESS.

Técnica	Índice BESS (R\$ _{UHB} /MWh _{BESS})	Desvio Padrão (%)
<i>Epsilon-Greedy</i>	4.487,97	14,70%
<i>Epsilon-Greedy Fuzzy</i>	3.085,49	13,15%
Operação Fixa	2.315,98	11,78%

Na Fig. 4, é possível constatar que nenhuma das técnicas apresentou domínio sobre a outra, evidenciando que as três são válidas para serem aplicadas nesse contexto, ficando a critério do proprietário da UHB a escolha da técnica a ser usada. Além disso, é perceptível que os riscos das técnicas de *Reinforcement Learning* são compensados pelo retorno que proporcionam.




Fig. 4 – Gráfico Risco X Retorno.

6.0 CONCLUSÕES

No decorrer dessa obra, buscou-se maximizar a receita de uma UHB utilizando as técnicas emergentes de *Reinforcement Learning*. Para isso, foi feita uma simulação estocástica horária com horizonte de 24h com 5000 cenários. Foi verificado que a solução do problema era não somente considerar a receita média diária obtida com a simulação estocástica, mas analisar a operação, por meio da perda de vida útil da bateria. Tendo ficado comprovado que a perda de rentabilidade mostrada pelas técnicas de RL era compensada pelo menor desgaste do BESS.

Por meio da proposta dos autores de criação do índice I-BESS, foi observado também que nenhuma das três técnicas utilizadas demonstraram domínio sobre outra, o que evidencia que todas elas são válidas para serem aplicadas nesse contexto, ficando a critério do proprietário da UHB a escolha da técnica a ser implementada. De modo geral, o *Epsilon-Greedy* foi a opção que deu o maior I-BESS, mas também a mais arriscada; a operação fixa foi a de menor I-BESS, porém foi a mais conservadora; já a *Epsilon-Greedy Fuzzy* se mostrou como uma alternativa intermediária que ponderou a relação entre o I-BESS e o aumento do risco.

Esse artigo traz como contribuições originais: a integração do RL, de forma preliminar, ao contexto de usinas híbridas com BESS, considerando a perda de vida útil da bateria e a criação do Índice BESS (I-BESS), responsável por mensurar o uso inteligente da bateria e permitir que sejam obtidas conclusões numa simulação de 24h.

Os autores acreditam que muito há a ser pesquisado sobre este tema e é sugerido como trabalhos futuros: realizar um refinamento no *Epsilon-Greedy Fuzzy*; melhorar a modelagem da perda de vida útil do BESS; fazer uma análise separada do efeito do BESS na UHB; e implementar o *Deep Reinforcement Learning*, comparando com as demais técnicas.

7.0 BIBLIOGRAFIA

- [1] C. L. Nge, I. U. Ranaweera, O.-M. Midtgård, and L. Norum, “A real-time energy management system for smart grid integrated photovoltaic generation with battery storage”, *Renewable Energy*, vol. 130, pp. 774–785, Jun. 2018, doi: 10.1016/j.renene.2018.06.073.
- [2] C. Yagi and K. Takeuchi, “Electricity storage or transmission? Comparing social welfare between electricity arbitrages”, *Energy Economics*, p. 107969, Oct. 2024, doi: 10.1016/j.eneco.2024.107969.

- [3] E. Sodré, A. Muller, D. Ferreira, R. Silveira. “Análise de Risco em Comercialização de Energia de Usina Virtual no Mercado Brasileiro”. *XXVI SNPTEE - Seminário Nacional de Produção e Transmissão de Energia Elétrica*, 15 a 18 de maio de 2022 – Rio de Janeiro - RJ.
- [4] F. Hafiz, I. Harjunkoski, M. Eissa, E. Vallarino, S. Picerno, “Automated Market Bidding for Battery Energy Storage Systems”, *CIGRÉ - Conseil International des Grands Réseaux Électriques*, 25 a 30 de agosto de 2024 – Paris, França.
- [5] S. H. Kim and Y.-J. Shin, “Optimize the operating range for improving the cycle life of battery energy storage systems under uncertainty by managing the depth of discharge,” *Journal of Energy Storage*, vol. 73, p. 109144, Oct. 2023, doi: 10.1016/j.est.2023.109144.
- [6] K. Abdulla *et al.*, “Optimal operation of energy storage systems considering forecasts and battery degradation,” *IEEE Transactions on Smart Grid*, vol. 9, no. 3, pp. 2086–2096, Sep. 2016, doi: 10.1109/tsg.2016.2606490.
- [7] CCEE. “PLD” Câmara de Comercialização de Energia Elétrica (CCEE). Accessed: Mar. 25, 2025. [Online]. Available: <https://www.ccee.org.br/web/guest/dados-e-analises/dados-pld>.
- [8] Brazil. Casa Civil. (2004, Jul. 30) *Decreto nº 5.163, Regulamenta a comercialização de energia elétrica, o processo de outorga de concessões e de autorizações de geração de energia elétrica, e dá outras providências*. Accessed: Mar. 25, 2025. [Online]. Available: https://www.planalto.gov.br/ccivil_03/_Ato2004-2006/2004/Decreto/D5163.htm.
- [9] P. Winder, *Reinforcement Learning: Industrial Applications of Intelligent Agents*, 1st ed., Massachusetts: O’Reilly, 2020.
- [10] R. S. Sutton, A. G. Barto, *Reinforcement Learning: An Introduction*, 2nd ed., Massachusetts: The MIT Press, 2018.
- [11] L. Graesser, W. L. Keng, *Foundations of Deep Reinforcement Learning: Theory and Practice in Python*, 1st ed., Massachusetts: Pearson Education, Inc., 2020.
- [12] N. G. Rocha, J. M. Vilela, G. M. B. de Moraes, J. D. Garcia, “Metodologia para Operação em Tempo Real de Plantas Híbridas com Sistemas de Armazenamento Baseada em Programação Dinâmica Dual Estocástica”, *XXVII SNPTEE - Seminário Nacional de Produção e Transmissão de Energia Elétrica*, 26 a 29 de novembro de 2023 – CICB, Brasília-DF.
- [13] ONS. “Geração de Energia”, Operador Nacional do Sistema Elétrico (ONS). Accessed: Apr. 14, 2025. [Online]. Available: https://www.ons.org.br/Paginas/resultados-da-operacao/historico-da-operacao/geracao_energia.aspx
- [14] Brazil. ANEEL. (2024, Dez. 16) *Despacho nº 3.625, Fixa os valores das Tarifas de Energia de Otimização – TEO, de Energia de Otimização da Usina Hidrelétrica de Itaipu – TEOItaipu e de Serviços Ancilares – TSA, bem como define os limites do Preço de Liquidação de Diferenças – PLD, com validade entre 1º de janeiro de 2025 e 31 de dezembro de 2025, para todos os submercados, conforme descrito*. Accessed: Mar. 26, 2025. [Online]. Available: <https://biblioteca.aneel.gov.br/acervo/detalhe/245677?i=15>.

DADOS BIOGRÁFICOS

Heitor Araújo Nunes



Graduado em Engenharia Elétrica-Eletrotécnica pela Universidade de Pernambuco (UPE) em 2024. Esteve envolvido em vários projetos de monitoria acadêmica na respectiva instituição e estagiou no Laboratório da Escola Politécnica de Pernambuco (POLI). Atualmente cursa o mestrado de Engenharia de Sistemas na Universidade de Pernambuco (UPE), no qual tem se dedicado à pesquisa na área de planejamentos de sistemas elétricos, utilizando inteligência artificial e modelagens matemáticas. Também são áreas de interesse: auditoria energética, tarifação de energia, eficiência energética e operação de sistemas elétricos.

Eduardo de Aguiar Sodré

Tem experiência na área de Geração, Transmissão e Distribuição de Energia Elétrica. Trabalha na Eletrobrás Chesf e na Neoenergia Pernambuco, tendo executado trabalhos de engenharia na área de energias renováveis, regulação da geração e hidrogênio. Realizou também vários trabalhos nas áreas de planejamento da expansão da transmissão e expansão da geração. É professor da POLI - UPE desde 2008. Possui Doutorado em Engenharia Elétrica pela Universidade Federal de Campina Grande em 2006 (CAPES 7) e Mestrado em Engenharia Elétrica pela Universidade Federal de Santa Catarina em 1996 (CAPES 6). Site pessoal: eduardo-sodre.eng.br. Site profissional: arnepy.com.

Rafael de Oliveira Fernandes

Graduado em Engenharia Elétrica pela Universidade Federal de Itajubá (UNIFEI) em 2001 e recebeu o título de Mestre em Estabilidade Transitória com PMU pela Unicamp em 2019. É Gerente Técnico na Equans na França, trabalhando com projetos de geração renovável. Membro Individual do Cigré-B5 e Membro Correspondente do WGB5.65, WGC2.18 e WGB5.74 do Cigré. Atua como Coordenador Brasileiro no Cobei / IEC-CE03.TC95-MT04 (Funções de Proteção e Guias de Aplicação).

André Victor Rodrigues Nascimento da Silva

CEO e Diretor Executivo e de Engenharia da Aeroespacial. Mestre em Engenharia Elétrica pela UFPE (2024), cujo tema é uma metodologia probabilística de quantificação do *curtailment* em usinas renováveis. MBA em Comercialização de Energia Elétrica pela UNINASSAU (2022) e Graduação em Engenharia Elétrica pela UFPE (2014). Lidera, coordena e desenvolve estudos elétricos e energéticos, tendo atuado em mais de 240 GW de projetos eólicos, fotovoltaicos, hídricos, híbridos e BESS. Lidera o desenvolvimento de soluções para o setor elétrico como estudos de quantificação de *constrained-off* futuro, estudos viabilidade e dimensionamento de usinas de geração renovável, BESS, H2V e NH3V, a plataforma de gestão de ativos de geração Wiidas e a plataforma de previsão de geração e *constrained-off Predictor*.

Luiz Gustavo de Sousa Duda

Formado em Eletrotécnica pelo CEFET-PE e em Engenharia Eletrotécnica pela Escola Politécnica da Universidade de Pernambuco. Possui 29 anos de experiência profissional, sendo oito em manutenção de equipamentos, um em manutenção de redes elétricas e vinte em operação do sistema eletroenergético. Desenvolveu diversas ferramentas de treinamento e de apoio à operação do sistema eletroenergético, incluindo a primeira versão do GERDIN, apresentada no 10º SENOP (2021), que serviu de base para o atual sistema GERDIN/SINapse do ONS. Atualmente, atua como Engenheiro de Operação no ONS.

Roberto Feliciano Dias Filho

Professor adjunto de Engenharia Elétrica na UPE, atuante nas áreas de recursos energéticos distribuídos, sistemas de armazenamento, H2V, proteção e automação de sistemas elétricos. Possui experiência em modelagem e simulação computacional para estudos de regime permanente, dinâmico, transitórios eletromagnéticos, curto-circuito, coordenação e seletividade de proteção. Também é engenheiro eletricista na Clean Horizon, com experiência em análise técnica de sistemas de armazenamento e integração com fontes renováveis em sistemas elétricos, além de projeto e análise de sistemas de proteção e controle de redes e microrredes com Recursos Energéticos Distribuídos.

Ivan Nunes Silva

É bolsista Produtividade em Pesquisa pelo CNPq desde o ano 2000. Possui Mestrado em Engenharia Elétrica pela Universidade Estadual de Campinas (1995) e doutorado em Engenharia Elétrica pela Universidade Estadual de Campinas (1997). Atualmente é Professor Titular (MS-6) do Departamento de Engenharia Elétrica e de Computação da Universidade de São Paulo (USP / Campus de São Carlos). É assessor científico da FAPESP, CNPq, CAPES, FAPEMIG, FACEPE, FAPESPA e Fundação Araucária (Governo do Paraná). Possui 7 patentes depositadas junto ao INPI. É fundador e coordenador do Laboratório de Automação Inteligente de Processos e Sistemas (LAIPS) da USP. Suas áreas de pesquisas incluem temas relacionados à automação inteligente de processos envolvendo sistemas elétricos de potência, controle inteligente de máquinas e equipamentos elétricos, projeto de arquiteturas de sistemas inteligentes, identificação e otimização de sistemas.