



UNIVERSIDADE ESTADUAL DE CAMPINAS
Faculdade de Engenharia Mecânica

DANILO LOSANO ALVES DE AZEVEDO

Otimização de um sistema híbrido de Fontes Renováveis de Energia

CAMPINAS
2023

DANILO LOSANO ALVES DE AZEVEDO

Otimização de um sistema híbrido de Fontes Renováveis de Energia

Dissertação apresentada à Faculdade de Engenharia Mecânica da Universidade Estadual de Campinas como parte dos requisitos exigidos para obtenção do título de Mestre em Engenharia Mecânica, na Área de Mecatrônica.

Orientador: Prof. Dr. João Maurício Rosário

ESTE TRABALHO CORRESPONDE À VERSÃO FINAL DA DISSERTAÇÃO DEFENDIDA PELO ALUNO DANILO LOSANO ALVES DE AZEVEDO, E ORIENTADA PELO PROF. DR JOÃO MAURÍCIO ROSÁRIO.

**CAMPINAS
2023**

Ficha catalográfica
Universidade Estadual de Campinas
Biblioteca da Área de Engenharia e Arquitetura
Elizangela Aparecida dos Santos Souza - CRB 8/8098

Azevedo, Danilo Losano Alves de, 1991-
Az25o Otimização de um sistema híbrido de fontes renováveis de energia / Danilo Losano Alves de Azevedo. – Campinas, SP : [s.n.], 2023.

Orientador: João Maurício Rosário.
Dissertação (mestrado) – Universidade Estadual de Campinas, Faculdade de Engenharia Mecânica.

1. Inteligência artificial. 2. Energia renovável. 3. Aprendizado de máquina.
4. Sistemas híbridos. 5. Recursos energéticos - Planejamento. I. Rosário, João Maurício, 1959-. II. Universidade Estadual de Campinas. Faculdade de Engenharia Mecânica. III. Título.

Informações Complementares

Título em outro idioma: Optimization of a hybrid system of renewable energy sources

Palavras-chave em inglês:

Artificial intelligence

Renewable energy

Machine learning

Hybrid systems

Energy resources - Planning

Área de concentração: Mecatrônica

Titulação: Mestre em Engenharia Mecânica

Banca examinadora:

João Maurício Rosário [Orientador]

Ely Carneiro de Paiva

Francisco Carlos Parquet Bizarria

Data de defesa: 05-05-2023

Programa de Pós-Graduação: Engenharia Mecânica

Identificação e informações acadêmicas do(a) aluno(a)

- ORCID do autor: <https://orcid.org/0000-0003-3839-9638>

- Currículo Lattes do autor: <http://lattes.cnpq.br/5590204781314100>

**UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA MECÂNICA**

DISSERTAÇÃO DE MESTRADO ACADÊMICO

Otimização de um sistema híbrido de Fontes Renováveis de Energia

Autor: Danilo Losano Alves de Azevedo

Orientador: Prof. Dr. João Maurício Rosário

A Banca Examinadora composta pelos membros abaixo aprovou esta Dissertação:

**Prof. Dr. João Maurício Rosário, Presidente
FEM / UNICAMP**

**Prof. Dr. Ely Carneiro de Paiva
FEM / UNICAMP**

**Prof. Dr. Francisco Carlos Parquet Bizarria
Universidade de Taubaté (UNITAU)**

A Ata de Defesa com as respectivas assinaturas dos membros encontra-se no SIGA/Sistema de Fluxo de Dissertação/Tese e na Secretaria do Programa da Unidade.

Campinas, 05 de maio de 2023.

Agradecimentos

Este trabalho teve sua conclusão realizada graças ao auxílio de muitas pessoas, de forma direta ou indireta, que se relacionaram comigo durante sua execução.

Primeiramente gostaria de agradecer minha esposa Letícia Rocha Gouveia, por todo suporte, apoio e incentivo na realização deste trabalho e dos demais projetos que temos juntos.

Agradeço a toda minha família por estarem sempre juntos e comemorando nossas conquistas, principalmente pais, sogros, irmã e cunhada.

Agradeço ao meu orientador, desde o período da graduação, prof. Dr. João Mauricio Rosario, que me apoiou e incentivou na realização desse e dos demais projetos acadêmicos, com certeza é uma referência na minha trajetória.

Agradeço aos membros da banca examinadora pelo interesse no projeto e disponibilidade para discutir temas atuais de inovação.

Por fim, agradeço a todos os funcionários e colaboradores da FEM e da UNICAMP que prestaram todo o suporte necessário desde o período da minha graduação até este momento.

Resumo

A evolução tecnológica fez com que a sociedade necessitasse cada vez da energia elétrica para seu desenvolvimento. Porém, o uso abundante de energia por fontes não renováveis se mostrou prejudicial ao planeta e seus habitantes. Dessa forma torna-se essencial a aplicação de meios renováveis para a geração de energia, principalmente visando a otimização dos recursos naturais utilizados. O projeto em questão seleciona três cidades no Brasil, sendo Marechal Deodoro (AL), Ipameri (GO) e Peixe (TO), de tamanhos populacionais diferentes para observar o impacto da otimização da geração híbrida de energia com a aplicação de Inteligência Artificial. Constatou-se que nas três cidades a aplicação do sistema de otimização com aprendizado de máquina e buffer de uma central de baterias apresentou uma redução significativa na geração de gases de efeito estufa com a redução em cerca de 50% do uso da rede básica de energia, além da possibilidade de receitas adicionais na ordem de milhões de reais por ano para cada localidade. Foi observado, ainda, que a planta híbrida ótima varia de localidade para localidade, de acordo com a Irradiação Global Horizontal e Velocidade do Vento para local, buscando-se sempre a otimização para o menor custo com base no preço de energia de cada município.

Palavras Chave: Inteligência Artificial, Geração Híbrida de Energia, Energia Renovável, Aprendizado de Máquina, Aprendizado por Reforço, Mercado Livre de Energia, Otimização.

Abstract

Technological evolution creates an increasing need for power in the development of society. However, the abundant use of energy from non-renewable sources has proved to be harmful to the planet and its inhabitants. In this way, it becomes essential to apply renewable sources of energy, aimed at optimizing the natural resources used. This project selected three Brazilian cities, Marechal Deodoro (AL), Ipameri (GO) and Peixe (TO), with diverse populational numbers to observe the change that hybrid energy generation could impact applying Artificial Intelligence and a Storage Central System as an energy buffer. It was found that in the three cities the application of the optimization system with reinforcement learning showed a significant reduction in the generation of greenhouse gases because of the reduction in ~50% of external power sources. In addition, was possible to reach more than one million reais annually to each city. It was also observed that the optimal hybrid plant varies from location to location, according to the Global Horizontal Irradiation and Wind Speed for each location, always seeking optimization for the lowest cost based on the energy price of each city.

Key Word: Artificial Intelligence, Hybrid Power Generation, Renewable Energy, Machine Learning, Reinforcement Learning, Power Free Market, Optimization.

Lista de Ilustrações

Figura 1 - Interconexão das tecnologias atuais	14
Figura 2 - Complementariedade da Geração de Energia Solar e Eólica no Brasil.....	15
Figura 3 - Crescimento do Uso de Energias Renováveis	16
Figura 4 - Fonte de Geração de Energia Elétrica no Mundo (IEA, 2019) e no Brasil (EPE, 2020) no ano de 2019	18
Figura 5 - Evolução do cenário elétrico nacional e global de 1990 até 2020	19
Figura 6 - Consumo em TJ para o ano de 2020	19
Figura 7 - Participação da Indústria no Consumo Total histórico.....	20
Figura 8 - Custo médio da Energia para fontes renováveis (IRENA, 2021).....	21
Figura 9 - Sistema de Geração de Energia Solar Simplificado	23
Figura 10 - Curva teórica da conversão de vento para energia	26
Figura 11 - Modelos de Turbinas Eólicas - Eixo Horizontal e Vertical.....	26
Figura 12 - Modelo Comercial de Turbina Eólica	27
Figura 13 - Evolução teórica das potências de turbinas com base na altura da torre	29
Figura 14 - Sistema de Armazenamento de Água por Bombeamento	31
Figura 15 - Relação de densidade por armazenamento das baterias	32
Figura 16 - Apresentação de uma Bateria de Fluxo Regenerativo.....	33
Figura 17 - Ilustração de uma Torre Solar	34
Figura 18 - Pilha a base de Hidrogênio	35
Figura 19 - Estrutura do Mercado Brasileiro de Energia	36
Figura 20 - Sistema Interligado Nacional (SIN) horizonte 2024	38
Figura 21 - Comparação entre o ACR e ACL.....	39
Figura 22 - Evolução dos Consumidores no ACL (PORTO, 2022).....	40
Figura 23 - Exemplificação do Uso do PLD	41
Figura 24 - Modelos utilizados para a definição do PLD	41
Figura 25 - PLD nos últimos 10 anos.....	43
Figura 26 - Ciclo de Vida Composto - Análise de Dados e Ciência de Dados (Caceres, 2020)	45
Figura 27 - Métodos de Modelagem (Autor)	47
Figura 28 - Estrutura de Organização - Inteligência Artificial.....	49

Figura 29 - Fluxo de Desenvolvimento de Modelo de AI.....	49
Figura 30 - Esquema genérico do aprendizado por reforço	51
Figura 31 - Interface com o usuário da Toolbox de Aprendizado por Reforço	53
Figura 32 - Importação de Ambientes para a geração de Agentes.....	54
Figura 33 - Criação de um novo Agente via aplicativo Matlab	55
Figura 34 - Treinamento de Agente via aplicativo Matlab	56
Figura 35 - Exemplo da Otimização via Pesquisa Operacional	57
Figura 36 - Interação dos Agentes do Projeto	62
Figura 37 - Exemplificação da Complementariedade Solar e Eólica.....	63
Figura 38 - Relação de PLD versus Nível dos Reservatórios nos últimos 5 anos	64
Figura 39 - Correlação entre o preço PLD e o Nível dos Reservatórios	65
Figura 40 - Exemplo da aplicação de Inteligência Artificial na Geração de Energia	67
Figura 41 - Modelo proposto por Caceres (2020)	69
Figura 42 - Curvas típicas de carregamento e descarregamento de baterias, para exemplos apenas	73
Figura 43 - Diagrama de Decisão para o sistema de Potência (MORA MONTAÑES, 2020)	74
Figura 44 - Custo da implementação de um sistema Híbrido de Geração (CACERES, 2020)	76
Figura 45 - Diferença entre demanda vs geração de energia (CACERES, 2020).....	77
Figura 46 - Máquina de Estados com a Inteligência Artificial (CACERES, 2020).....	79
Figura 47 - Diagrama de Máquina de Estados (CACERES, 2020)	80
Figura 48 - Arquitetura da Rede Neural da Solução 2 (CACERES, 2020)	81
Figura 49 - Métodos de Previsão (CACERES, 2020).....	82
Figura 50 - Histogramas das 4 soluções propostas - Somatória da Função Recompensa (CACERES, 2020)	83
Figura 51 - Distribuição das probabilidades da função de recompensa (CACERES, 2020) ...	84
Figura 52 - Estrutura Proposta para o Projeto	85
Figura 53 - Fluxo da Estratégia de Implementação do Sistema.....	87
Figura 54 - Divisão dos Municípios no Escopo de estudo	89
Figura 55 - Distribuição das cidades conforme população	89
Figura 56 - Quantidade de Municípios e População Total nas divisões sugeridas	90
Figura 57 - Gráfico de dispersão dos municípios com base no PIB per capita e Valor adicionado da Indústria no total do PIB.....	91

Figura 58 - Potencial de Geração de energia solar - Brasil (PEREIRA et al., 2017).....	92
Figura 59 - Velocidade do Vento a 100 metros de altura (CEPEL, 2013).....	93
Figura 60 - Região com Alto Potencial de Geração de Energia Renovável	95
Figura 61 - Cidades selecionadas para avaliação do projeto (Google Maps, 2023)	96
Figura 62 - Consumo de Energia em Alagoas - AL (CCEE, 2023).....	98
Figura 63 - Consumo de energia no estado de Goiás - GO (CCEE, 2023).....	99
Figura 64 - Consumo histórico de energia para o estado de Tocantins - TO (CCEE, 2023) .	100
Figura 65 - Comportamento diário em 2021 do Sub-mercado Nordeste (ONS, 2023)	101
Figura 66 - Comportamento diário em 2021 do Sub-mercado Sudeste/Centro-Oeste (ONS, 2023).....	101
Figura 67 - Comportamento diário em 2021 do Sub-mercado Norte (ONS, 2023).....	102
Figura 68 - Consumo de Energia por dia de semana no subsistema Nordeste (ONS, 2023) .	102
Figura 69 - Consumo de Energia por dia de semana no subsistema Sudeste / Centro-Oeste (ONS, 2023)	103
Figura 70 - Consumo de Energia por dia de semana no subsistema Norte (ONS, 2023)	103
Figura 71 - Consumo de energia horária para os três subsistemas observados (ONS, 2023)	104
Figura 72 - Definição por aproximação da curva horário municipal	105
Figura 73 - Consumo de Energia Municipal vs Estadual – Alagoas.....	105
Figura 74 - Consumo de Energia Municipal vs Estadual - Goiás	106
Figura 75 - Consumo de energia Municipal vs Estadual - Tocantins	106
Figura 76 - Consumo de Energia Cativo vs Total	107
Figura 77 - Consumo de energia Estado vs Sub-mercado	108
Figura 78 - Consumo de energia horária, aproximado, para cada cidade em estudo.....	109
Figura 79 - Comportamento do PLD médio durante o ano de 2021 (CCEE, 2023)	110
Figura 80 - Preço da Energia Médio em cada mês - Nordeste (CCEE, 2023).....	110
Figura 81 - Preço da Energia Médio em cada mês - Sudeste / Centro-Oeste (CCEE, 2023) .	111
Figura 82 - Preço da Energia Médio em cada mês - Norte (CCEE, 2023)	111
Figura 83 - Preço médio de energia por dia da semana - Nordeste (CCEE, 2023).....	112
Figura 84 - Preço médio de energia por dia da semana - Sudeste / Centro-Oeste (CCEE, 2023)	112
Figura 85 - Preço médio de energia por dia da semana - Norte (CCEE, 2023).....	113

Figura 86 - Preço da energia em um domingo e uma sexta-feira de agosto/2021 (ONS, 2023)	114
Figura 87 - Irradiação Solar Global Horizontal ao longo dos meses do ano	115
Figura 88 - Incidência solar horária média para referência de Alagoas	116
Figura 89 - Incidência solar média horária para referência de Goiás	117
Figura 90 - Incidência solar horária média para referência de Tocantins	117
Figura 91 - Perfil médio horário de velocidade do vento	118
Figura 92 - Variação de velocidade do vento mensal	119
Figura 93 - Consumo horário em um dia de alta demanda de energia	121
Figura 94 - Curva de LCOE para cada percentual de fonte - Marechal Deodoro (AL)	122
Figura 95 - Curva de LCOE para cada percentual de fonte - Ipameri (GO)	123
Figura 96 - Curva de LCOE para cada percentual de fonte - Peixe (TO)	123
Figura 97 - Variação do Consumo de Energia vs Geração Híbrida	127
Figura 98 - Esquemático da implementação da Inteligência Artificial	130
Figura 99 - Ambiente virtual desenvolvimento para a aplicação do Aprendizado por Reforço	132
Figura 100 - Bloco referente aos dados levantados para Estudo	133
Figura 101 - Bloco de modelagem do Ambiente de interação com o Agente	136
Figura 102 - Subsistema da Central de Baterias no Ambiente simulado	137
Figura 103 - Subsistema de Balanço Energética do Ambiente simulado	137
Figura 104 - Subsistema de Transação de Energia no Mercado para o Ambiente Simulado	138
Figura 105 - Bloco de Sinais para o Aprendizado por Reforço	139
Figura 106 - Bloco para o Agente do Aprendizado por Reforço	141
Figura 107 - Avaliação das despesas em um ano para cada município sem a IA	142
Figura 108 - Receita acumulada com o uso de baterias	143
Figura 109 - Carga acumulada na Central de Baterias em 2021	144
Figura 110 - Carregamento da Central de Baterias Otimizado	145
Figura 111 - Receita acumulada durante o ano de 2021 com compra de energia remanescente	145

SUMÁRIO

1	INTRODUÇÃO	13
2	REVISÃO BIBLIOGRÁFICA	16
2.1	O MERCADO DE ENERGIA NO BRASIL	17
2.1.1	ENERGIA RENOVÁVEL	20
2.1.2	SISTEMA DE ARMAZENAMENTO DE ENERGIA	30
2.1.3	MERCADO DE ENERGIA NO BRASIL	36
2.2	ANÁLISE DE DADOS E INTELIGÊNCIA ARTIFICIAL	44
2.2.1	ANÁLISE DE DADOS E BIG DATA.....	44
2.2.2	INTELIGÊNCIA ARTIFICIAL	47
2.2.3	SOFTWARES AUXILIARES PARA INTELIGÊNCIA ARTIFICIAL.....	52
2.3	PESQUISA OPERACIONAL E APLICAÇÃO NA INDÚSTRIA DE ENERGIA.....	57
3	INTELIGENCIA ARTIFICIAL E ANÁLISE DE DADOS	61
3.1	ESCOPO DO PROJETO.....	62
3.2	TRABALHOS DE REFERÊNCIAS	68
3.3	MODELAGEM PROPOSTA.....	85
3.3.1	ESTRATÉGIAS PROPOSTAS.....	85
3.3.2	CENÁRIOS DE IMPLEMENTAÇÃO	87
3.4	COMENTÁRIOS E CONCLUSÕES DO CAPÍTULO	93
4	UTILIZAÇÃO DE TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL PARA A GERAÇÃO HÍBRIDA DE ENERGIA	94
4.1	SELEÇÃO DE CENÁRIOS.....	95
4.2	AVALIAÇÃO DE DADOS DISPONÍVEIS ATRAVÉS DE HISTÓRICOS.....	97
4.2.1	CONSUMO DE ENERGIA	97
4.2.2	PRECIFICAÇÃO DE ENERGIA.....	109
4.2.3	ÍNDICES DOS FATORES NATURAIS.....	114
4.3	ESTUDO DA IMPLEMENTAÇÃO.....	120
4.3.1	DIMENSIONAMENTO DO SISTEMA DE ENERGIA	121
4.3.2	DIMENSIONAMENTO DO SISTEMA DE BATERIAS	127
4.3.3	APLICAÇÃO DA INTELIGÊNCIA ARTIFICIAL E CONTROLE.....	129
5	VALIDAÇÃO COM A UTILIZAÇÃO DE MATLAB/SIMULINK	132
6	CONCLUSÕES.....	147
	REFERÊNCIAS	151

1 INTRODUÇÃO

A geração de energia na sociedade tornou-se elemento essencial e de suporte para as novas tecnologias que estão surgindo ano após ano. Cada vez mais as cidades conectadas, ou *Smart City*, são fatores mais presentes no cotidiano das pessoas.

Nos últimos anos diversos meios tecnológicos surgiram, impulsionados ainda mais pela pandemia da COVID 19, com o objetivo de facilitar a vida das pessoas, além de aproximá-las cada vez mais, mesmo estando longe. Exemplos dessas tecnologias são:

- **5G** – quinta geração das redes de telecomunicação, sendo tecnologia base para o desenvolvimento de veículos e cidades inteligentes;
- **Block Chain** - meio de validação online para qualquer tipo de documento, facilitando tramites burocráticos e reduzindo o tempo gasto com verificação de contratos;
- **Veículos Autônomos** – ou ainda veículos inteligentes, são frotas capazes de se locomover sozinhas pela cidade, não havendo necessidade de pilotos;
- **Indústria 4.0** – aplicação de redes inteligentes conectadas com os meios de produção, aumentando eficiência e qualidade de trabalho;
- **Smart Grids** – redes de energia inteligentes, conectadas para suprir as demandas de energia de cada localidade.

Todas essas tecnologias têm um ponto em comum, a utilização da rede elétrica como suporte, conforme apresentado pela *Figura 1*.

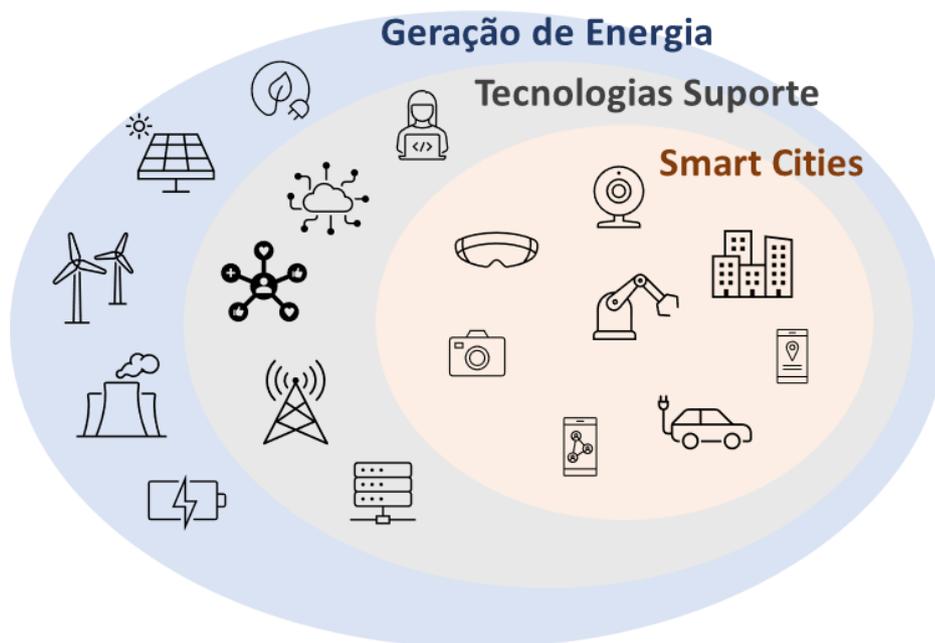


Figura 1 - Interconexão das tecnologias atuais

Com isso, torna-se essencial o uso e otimização da geração de energia elétrica. Adicionalmente, e ainda mais importante, são os recursos utilizados para a geração de energia. Atualmente no mundo mais de 37% da matriz elétrica mundial é composta de meios não renováveis (EPE, 2022) como o Carvão e Petróleo, sendo um dos principais agentes causadores dos gases de efeito estufa que estão cada vez mais implicando em riscos para a sobrevivência humana.

Visando essa preocupação, é importante gerar energia por fontes renováveis, e aproveitar esse potencial presente na maioria dos países, e principalmente no Brasil. As energias renováveis mais desenvolvidas são a Eólica, com base nos ventos, e a Solar, com base na irradiação solar, então serão utilizadas essas duas para o estudo, pois como um adicional, elas apresentam uma complementariedade importante para a geração de energia, conforme apresentado em *Figura 2*.

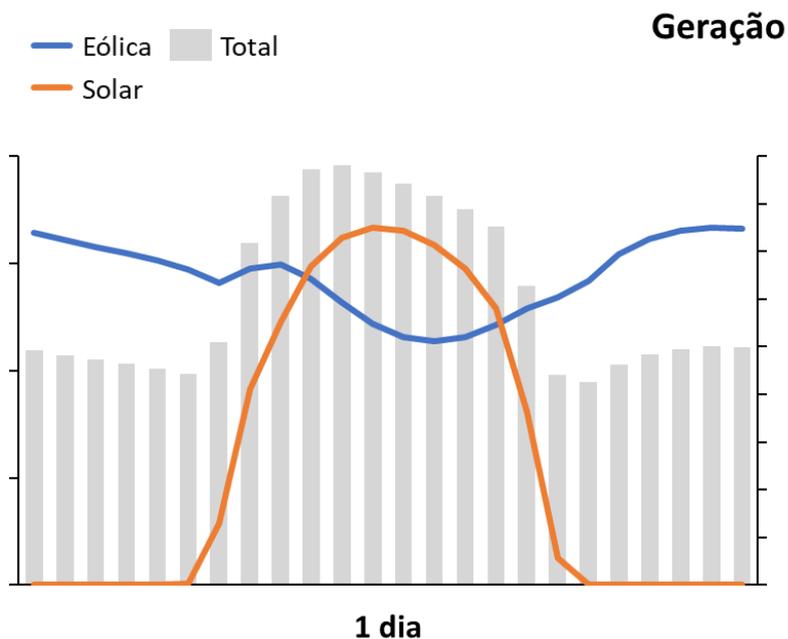


Figura 2 - Complementariedade da Geração de Energia Solar e Eólica no Brasil

Por fim, o objetivo desse trabalho é buscar meios de otimização da geração híbrida de energia, focando em fontes renováveis e na viabilidade financeira do projeto. Para isso buscou-se a implementação de um simulador utilizando os softwares computacionais *Matlab* e *Simulink* para avaliar os impactos desse novo modelo de geração de energia com a adição de inteligência artificial para otimizar a conexão com as redes e autonomia das cidades.

2 REVISÃO BIBLIOGRÁFICA

A evolução tecnológica no meio industrial, como as técnicas de Indústria 4.0, fazem com que o uso de energia se torne um fator relevante na análise de insumos fabris. Tal fato ocorre devido ao aumento do uso de tecnologias que necessitam de energia para seu correto funcionamento, aumentando significativamente o uso desse insumo. Em paralelo a sociedade apresenta uma evolução natural de conhecimentos e descobertas, observando a importância de preservar e otimizar os recursos naturais, influenciando no aumento do uso de energias advindas de fontes renováveis, como solar e eólica, conforme apresentado na Figura 3.

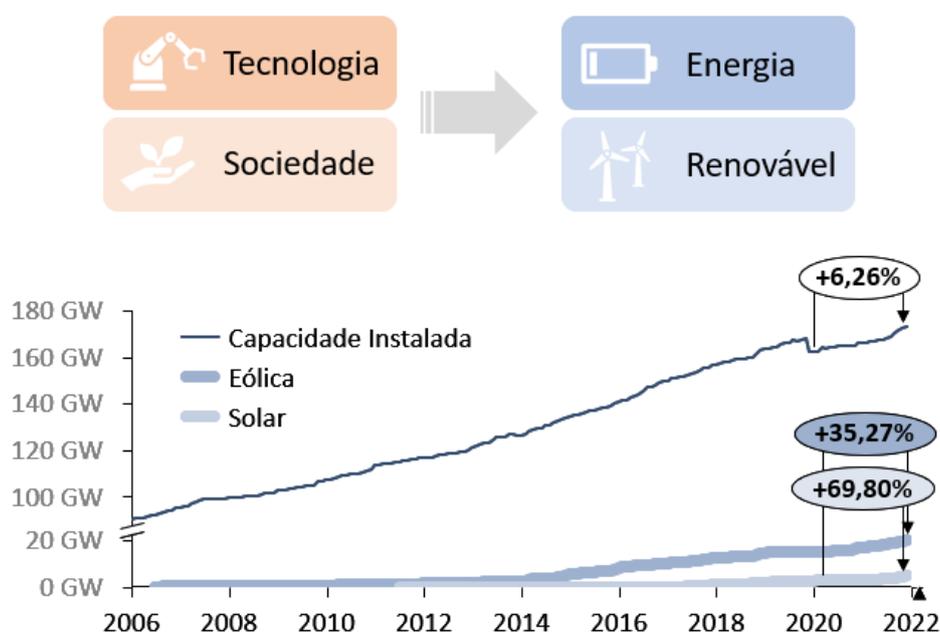


Figura 3 - Crescimento do Uso de Energias Renováveis

Porém as usinas renováveis são dependentes de fatores ambientes, como chuvas, ventos e irradiação solar. Assim esse sistema deve ser suportado por baterias que auxiliam em momentos de baixa geração ou mesmo de excesso, sendo superior a demanda.

Para a implementação de sistemas totalmente renováveis na geração de energia, é necessária a inclusão de tecnologias inteligentes para otimizar o uso dos recursos e, conseqüentemente, utilizar uma quantidade menor, sendo assim ainda mais sustentável.

Para isso, a análise de dados, aliada da inteligência artificial, pode auxiliar na previsão dos fatores ambientais e geração de energia o que, implementando junto com técnicas de pesquisa operacional, conseguem otimizar a geração de energia.

Assim, esse capítulo busca explicitar as técnicas e fatores de cada um desses agentes do sistema analisado, sendo dividido em:

- **Energia e Mercado de Energia no Brasil**

Avalia o cenário energético e sua evolução, apresentando a especificidade do cenário energético brasileiro e do mercado de energia implementado, além de abranger os fatores para cálculo de preços.

- **Análise de Dados e Inteligência Artificial**

Apresenta o funcionamento da análise de dados e suas principais ferramentas. Abrange técnicas de inteligência artificial, principalmente sobre aprendizado de máquina, muito utilizado atualmente e que será uma das bases para o projeto em questão.

- **Pesquisa Operacional**

Indica o processo de realização da pesquisa operacional, sistema utilizado para a otimização de problemas complexos, com diversos agentes e variáveis, diretas e indiretas. Sendo uma metodologia aplicada ao projeto proposto.

2.1 O MERCADO DE ENERGIA NO BRASIL

A energia elétrica é um recurso cada vez mais importante para o desenvolvimento da humanidade, a evolução exponencial tecnológica e conexões exigidas, como Indústria 4.0, automóveis autônomos, cidades inteligentes etc., aumentam a demanda e necessidade de fornecimento de energia. Com isso, surge também a necessidade de fontes renováveis a fim de obter um desenvolvimento sustentável para o planeta.

Desde o século 19 o mundo tem evoluído e se desenvolvido muito em sistemas energéticos, como exemplo têm-se sistemas muito bem constituídos, como o Leste dos Estados Unidos, servindo 228 milhões de pessoas, e outros que apresentam desenvolvimento acelerado, como o Chinês que instalou cerca de 85 GW em quatro anos, apresentando aumento de cerca de 50% (MAUAD; FERREIRA; TRINDADE, 2017).

Em 2019 a produção mundial de energia era focada, principalmente, em fontes não renováveis como o Carvão e Gás Natural, juntas representando cerca de 60% da produção mundial de energia elétrica (IEA, 2019). No Brasil, a maior fonte produtora de energia é a hidrelétrica, devido ao enorme potencial hídrico presente no país, representando em 2019 cerca de 63% do total de energia elétrica produzida (EPE, 2020). A Figura 4 apresenta essa relação e diferença entre as matrizes energéticas mundiais e nacional.

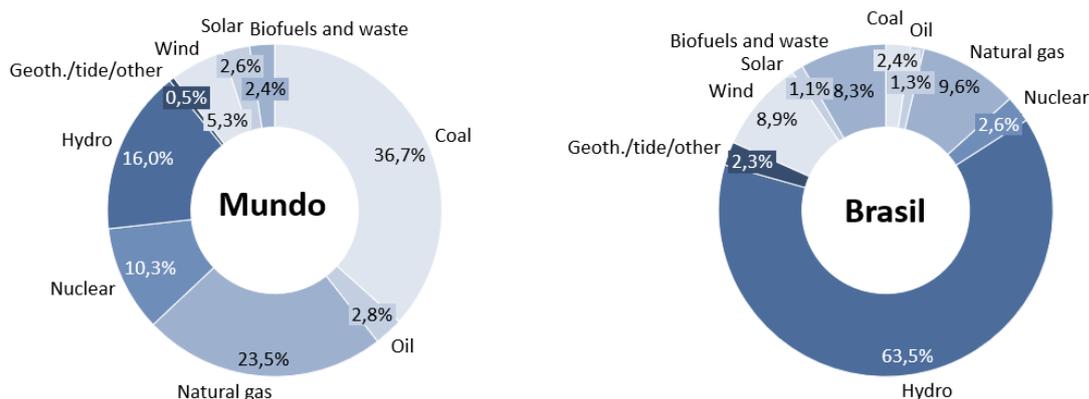


Figura 4 - Fonte de Geração de Energia Elétrica no Mundo (IEA, 2019) e no Brasil (EPE, 2020) no ano de 2019

Em 30 anos, de 1990 até 2020, o Brasil apresentou um aumento de ~180% da sua capacidade de geração de energia, chegando em valores de 620 mil GWh no total, sendo que fonte hidráulica passou da representação de 93% da matriz para 63%, dessa forma o aumento foi realizado em outras fontes, principalmente renováveis. No mundo, esse aumento foi menos significativo, cerca de 125%, chegando a valores de ~27 milhões de GWh (IEA, 2022). A Figura 5 apresenta de forma mais visual tais informações.

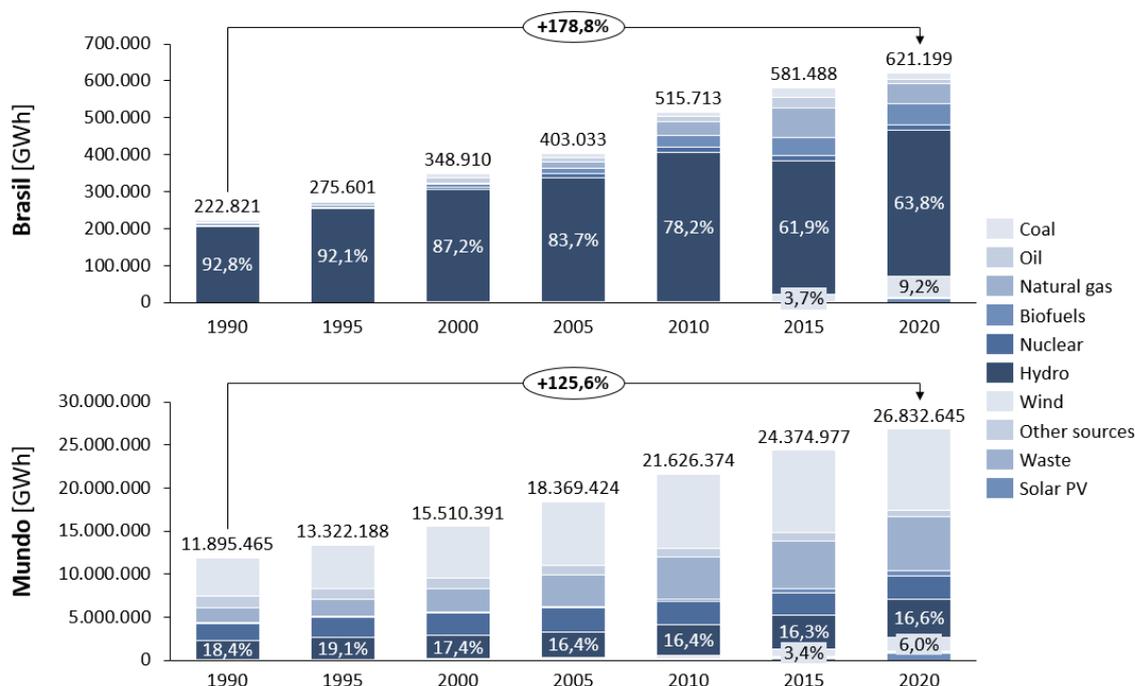


Figura 5 - Evolução do cenário elétrico nacional e global de 1990 até 2020

O consumo de energia é mais significativo no meio industrial, mas nos últimos anos, com os avanços tecnológicos, esses números tendem a se equilibrar, atualmente o consumo industrial representa 44% do consumo mundial e 39% do nacional (IEA, 2022), conforme apresentado na Figura 6 para o ano de 2020.

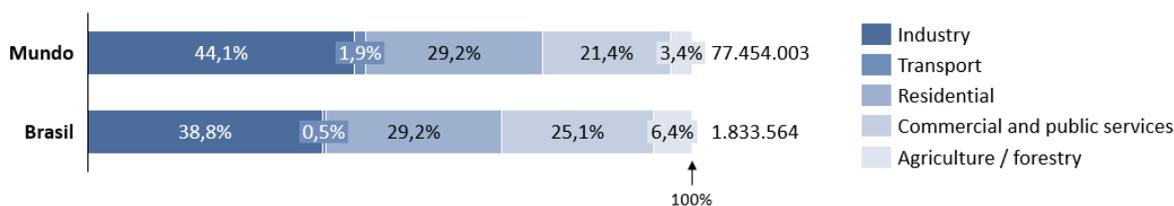


Figura 6 - Consumo em TJ para o ano de 2020

Na Figura 7 é possível observar como a indústria perde participação no setor energético, devido principalmente ao aumento de tecnologias nas casas e comerciais e a eficiência energética buscado como redução de custos. É importante observar, também, que o ano de 2020

no âmbito global sofreu um aumento, contrariando a tendência percebida, devido à entrada das indústrias novas, principalmente chinesas, no cálculo industrial global.

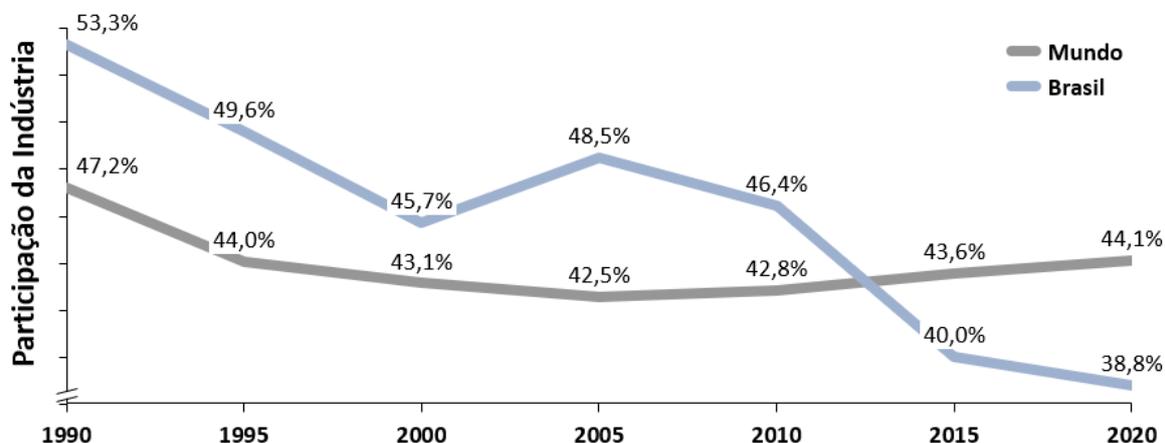


Figura 7 - Participação da Indústria no Consumo Total histórico

2.1.1 ENERGIA RENOVÁVEL

Desde o Protocolo de Kyoto em 1997 até os dias atuais, o mundo se mostra mais preocupado com o desenvolvimento sustentável, afinal diversas evidências estão apresentando o incremento de problemas ambientais e fatores climáticos diretamente ligados às emissões de gases de efeito estufa (WWF, 2022).

Como apresentado em Muad et al. (2017), os principais fatores que desafiam a implementação de energia renovável são os seguintes:

- **Disponibilidade de Recursos:** As fontes de energia renováveis dependem da disponibilidade de seus recursos naturais para a geração de energia, como disponibilidade de ventos, irradiação solar constante, corrente de água, etc.
- **Fatores econômicos e tecnológicos:** As tecnologias para a implementação de energias renováveis ainda são muito escassa e estão em total desenvolvimento. Com isso, seus custos ainda são muito elevados, mas tendem a reduzir ao longo do tempo, conforme apresentado na Figura 8, com o histórico do preço médio da implementação de tais fontes de energia (IRENE, 2021).

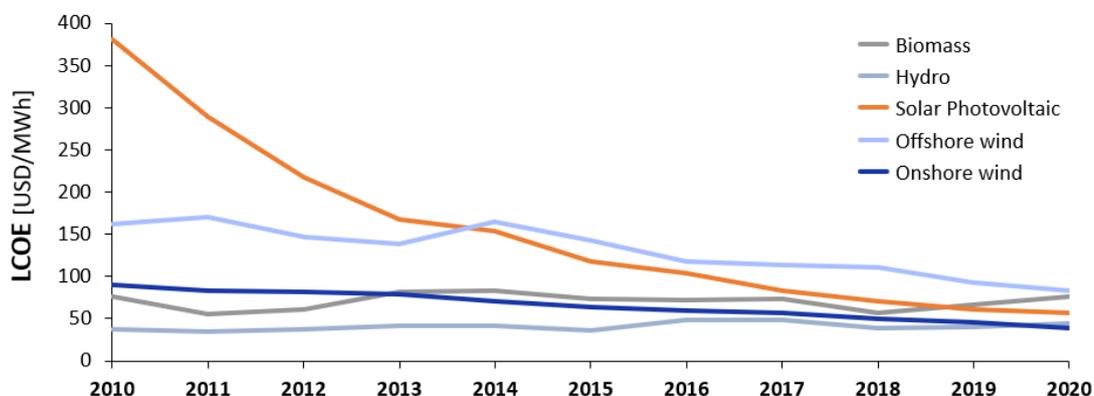


Figura 8 - Custo médio da Energia para fontes renováveis (IRENA, 2021)

O custo da energia, do acrônimo **LCOE**, que é uma expressão em inglês de *Levelized Cost of Energy* (Custo médio nivelado de energia), consegue comparar investimentos que apresentam custos e durações diferentes. Ele define que o custo mínimo que deve ser pago por um consumidor para que o investimento feito gere um retorno aceitável para o investidor (MAUAD; FERREIRA; TRINDADE, 2017). A fórmula para o cálculo é dada por (1):

$$LCOE = \frac{\text{Custo Total}}{\text{Energia Gerada Total}} \quad (1)$$

Em que:

- **LCOE** = Custo da energia, dado em R\$/MWh;
 - **Custo Total** = Soma dos valores presentes de todo fluxo de custos para manutenção, operação e investimentos iniciais do projeto, à uma taxa de retorno definida;
 - **Energia Gerada Total** = Soma de toda energia gerada na vida útil do projeto, trazidos à valor presente pela mesma taxa de desconto utilizada para o Custo Total.
- **Fatores socioambientais:** Embora as fontes de energia renováveis são consideravelmente melhores para o meio ambiente do que as fontes de combustíveis

fósseis, elas ainda geram uma certa quantidade de gases de efeito estufa, principalmente durante sua produção e manutenção, sendo que, atualmente que mais gera é a solar, devido a complexidade no desenvolvimento das placas.

Além disso, existem problemas ambientais da implementação de grandes usinas renováveis, que podem causar desmatamentos, retirada de habitat de alguns animais, etc. Do lado social, é necessária uma adaptação das pessoas quanto às novas tecnologias, como alteração de estética de residências, paisagens naturais, etc.

Por fim, existe a falta de mão-de-obra qualificada para a implementação dessas tecnologias, tanto que diversos insumos devem ser importados, causando ainda uma piora econômica pela conversão da moeda.

- **Fatores políticos:** Para superar os pontos citados anteriormente, são necessárias políticas públicas para investir em tais energias e incentivar o setor privado nesse sentido. No Brasil, algumas iniciativas já foram realizadas, como:
 - **Lei nº5.655/1971:** Utilização da Reserva Global de Reversão para a produção de energia a partir de fontes renováveis;
 - **Lei nº9.427/1996:** Descontos na taxa de transmissão e simplificação dos procedimentos para autorização de usinas;
 - **Lei nº9.478/1997:** Inclui as fontes renováveis nos objetivos da política energética nacional;
 - **Lei nº10.438/2002:** Institui o Programa de Incentivo às Fontes Alternativas de Energia Elétrica (ProInfra) e a Conta de Desenvolvimento Energético (CDE), em que busca melhorar a competitividade de fontes renováveis que participam do sistema interligado nacional de energia.

- **Integração entre tecnologias novas e antigas:** As novas tecnologias, quando entram no sistema interligado de energia, podem causar interferências e instabilidades. A adaptação dessas novas tecnologias com as antigas visa a obtenção de confiabilidade na geração, evitar oscilações e sobrecargas do sistema, além da falta de energia.

Este trabalho terá foco em dois tipos principais de energia renovável, sendo a Eólica e a Solar, que serão brevemente apresentadas a seguir.

A **energia solar fotovoltaica** é a única fonte renovável que tem a capacidade de fornecer energia para atender toda a demanda global (MAUAD; FERREIRA; TRINDADE, 2017).

Conforme apresentado em Mauad et al. (2017) um sistema de energia fotovoltaico é composto por três blocos principais, sendo:

- **Bloco gerador:** Esse primeiro corresponde aos painéis fotovoltaicos, cabeios e estruturas de suporte;
- **Bloco de condicionamento de potência:** Este consiste no ajuste da potência, contendo inversores, conversores, controladores de carga, etc.;
- **Bloco de armazenamento** (quando necessário): Composto pelas baterias ou outras formas de armazenamento.

De forma resumida, o sistema pode ser implementado conforme a Figura 9.

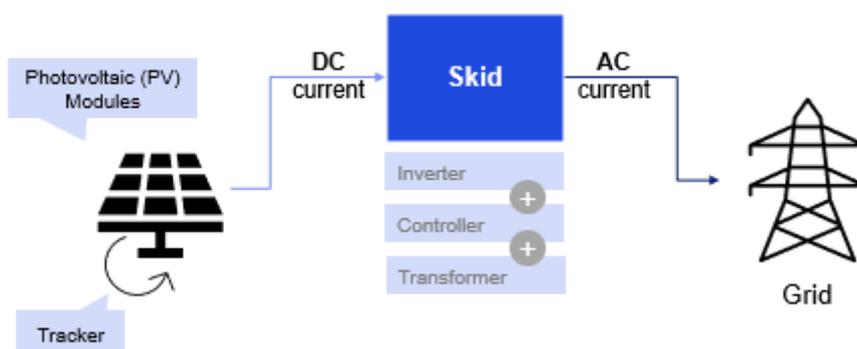


Figura 9 - Sistema de Geração de Energia Solar Simplificado

Os principais componentes são apresentados a seguir: (MAUAD; FERREIRA; TRINDADE, 2017)

- **Módulo Fotovoltaico**

O módulo consiste em um conjunto de células fotovoltaicas, em série ou paralelo, com o objetivo de gerar uma determinada tensão e corrente elétrica. A irradiação solar incide nas células, fazendo com que os fótons energizem os elétrons que passam nas diversas camadas da placa, fazendo com que uma corrente elétrica, e consequentemente tensão elétrica, seja gerada.

- **Inversores**

O sistema elétrico industrial e residencial é composto por corrente alternada (AC), e a energia gerada pelo efeito fotovoltaico é do tipo contínuo (CC). Dessa forma, o inversor realiza a conversão DC para AC, além de realizar a medição da energia gerada pelo sistema.

- **Controladores de Carga**

Os controladores de carga estão presentes sempre que o sistema possui a parte de armazenamento de energia. O intuito dele é realizar a comunicação entre módulo e bateria para que não haja sobrecarga no sistema.

A irradiação captada pelas placas solares podem ser:

- **Irradiação Difusa:** Advindas do efeito de difusão dos raios solares que cruzam a atmosfera;
- **Irradiação Direta:** Trajetória em linha reta dos raios incidentes solares.

É muito importante organizar os módulos de forma que a inclinação esteja baseada na altura solar específica, fazendo com que os raios diretos atinjam a placa perpendicularmente. E as fileiras devem estar alinhadas de forma a causar a menor interferência possível umas nas outras, como o sombreamento. Algumas usinas mais modernas utilizam o sistema de *trackers*, em que as placas realizam uma rotação em um ou dois graus de liberdade para obter a melhor inclinação em cada horário do dia.

A geração de energia solar comercial, toma como base a potência de pico da planta, que é convertida em potência AC para então ser multiplicada pelo fator de capacidade da geração solar, dado por (2):

$$E_{fv} = P_{Wac} \times NFC \times Horas_{dia} \quad (2)$$

Em que:

- E_{fv} = energia gerada em MWh
- P_{Wac} = potência AC (obtida após a conversão da potência pico) em MW

- **NFC** = fator de capacidade em %, indica a eficiência de conversão da potência em energia
- **Horas_{dia}** = 24 horas

A energia fotovoltaica pode apresentar ainda alguns problemas físicos que reduzem sua eficiência, como falhas de solda e metalização, trilhas de caracol, bolhas, delaminação, fissuras e rachaduras, necessitando de manutenção constante (MESQUITA, 2020). Além disso, existem desvantagens intrínsecas da aplicação de tal sistema, dentre elas a intermitência, baixo armazenamento de energia e impactos visuais (PORTAL SOLAR, 2023).

A **Energia Eólica**, é obtida a partir dos ventos e, apesar de apresentar capacidade menor que a solar, possui maiores incentivos e participa majoritariamente do sistema interligado nacional.

A utilização do vento como fonte de energia data de milhares de anos atrás, desde as grandes navegações que utilizavam o vento como força motriz, até moinhos encontrados na China antiga que datam de aproximadamente 2000 ano a.c. (MAUAD; FERREIRA; TRINDADE, 2017).

O princípio básico da geração de energia pelo vento é transformar a energia cinética que movimenta o ar, para energia mecânica, como a rotação das pás, para finalmente energia elétrica. Porém, a energia disponível no vento é capturada apenas em partes pela turbina, conforme apresentado na Figura 10. (IPCC, 2011)

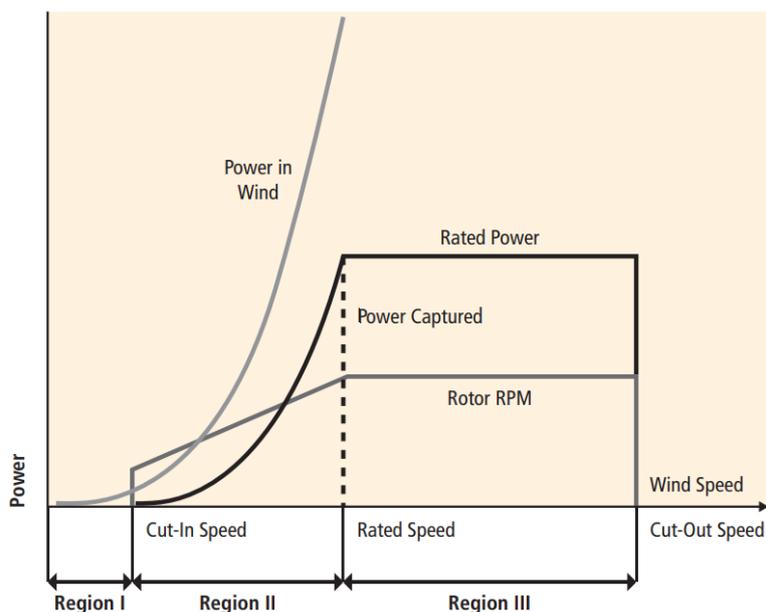


Figura 10 - Curva teórica da conversão de vento para energia

Pode-se observar que os geradores possuem um corte de velocidade inicial, devido à entrada no sistema, entrando na região II, então a potência gerada aumenta conforme aumenta a velocidade do vento. Atingindo uma velocidade chamada de *rated speed*, a turbina não gera mais energia para preservar o limite do rotor, entrando em uma região estável de geração, região III. Por fim, atingindo uma velocidade superior a de corte, o sistema para de gerar com o objetivo de preservar sua estrutura. (IPCC, 2011).

No passar do tempo, diversos modelos de turbinas foram pensados e testados, tanto de eixo vertical como de eixo horizontal, conforme a Figura 11. (IPCC, 2011)

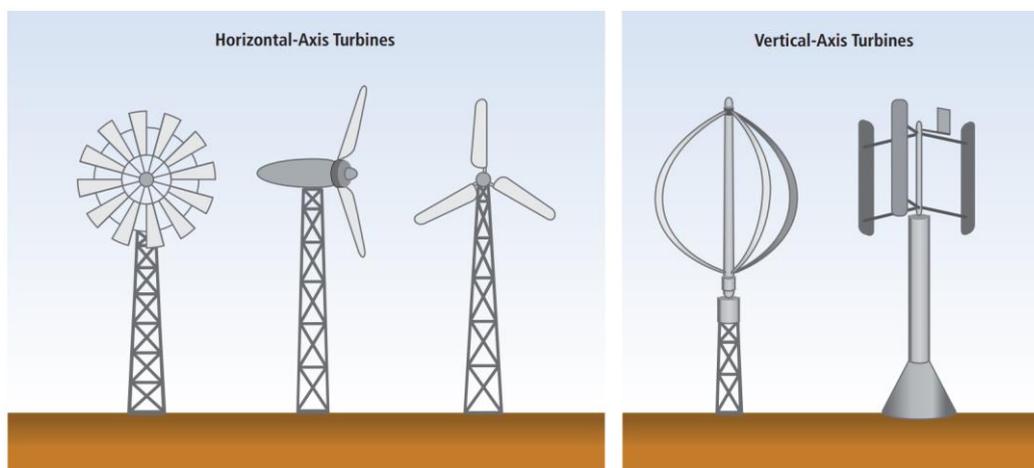


Figura 11 - Modelos de Turbinas Eólicas - Eixo Horizontal e Vertical

As turbinas que atualmente dominam o mercado são as de eixo horizontal e três pás, isso ocorre devido à redução no ruído gerado e menor atrito aerodinâmico. As turbinas são compostas por um complexo conjunto de equipamentos, em que observa-se, além das partes estruturais e de geração, uma forte presença de controladores, para obter as melhores conversões de vento em energia elétrica. A Figura 12 apresenta a estrutura atual de uma turbina comercial (IPCC, 2011).

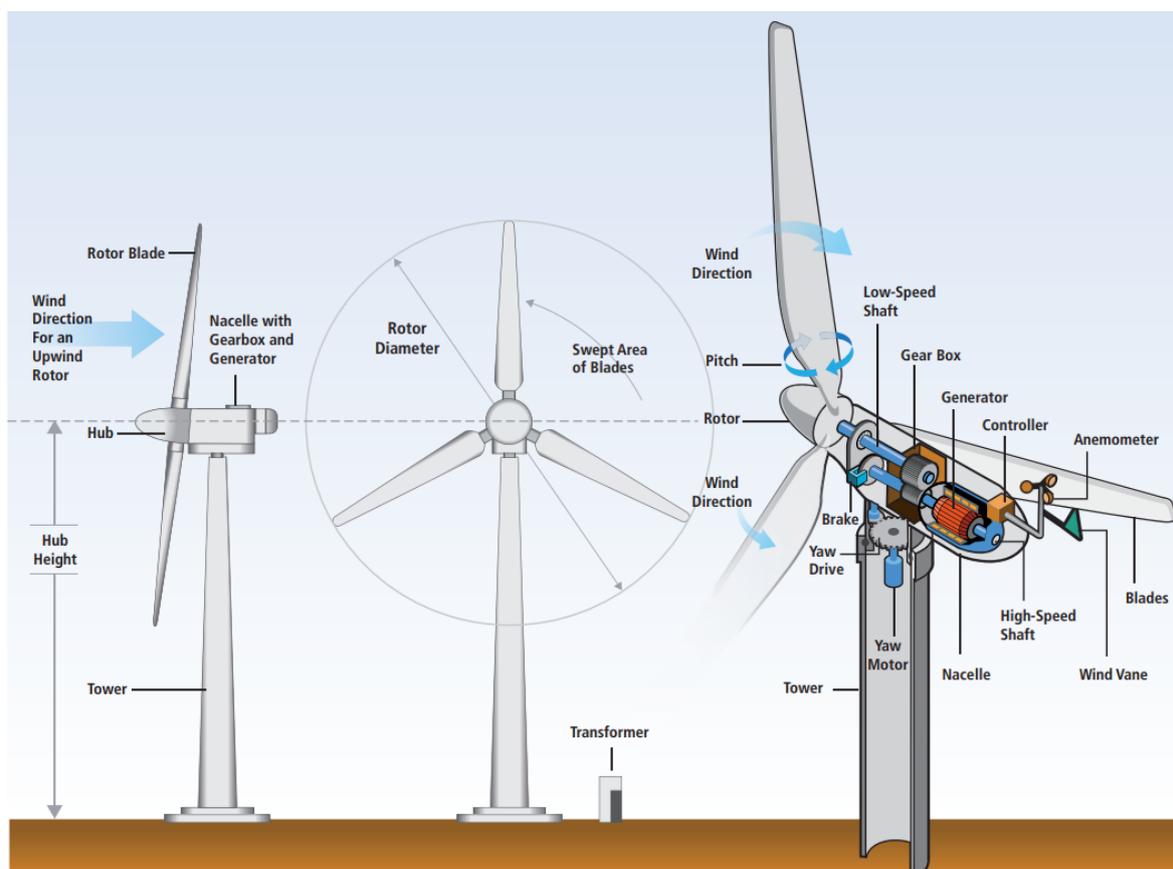


Figura 12 - Modelo Comercial de Turbina Eólica

Mauad et al. (2017) apresenta maiores detalhes dos componentes presentes em uma Turbina Eólica, ainda com base na Figura 14, pode-se observar os principais:

- **Sistema de geração**

Composto pelo gerador e caixa de redução, são responsáveis por transformar a energia mecânica da rotação das pás, em energia elétrica pelo efeito eletromagnético

- **Sistema de Controle**

Composto pelos motores e sensores que avaliam a direção e velocidade do vento para otimizar o posicionamento das pás. Nesse conjunto inclui-se também o controlador de carga e sistema de freios, responsável pela segurança do sistema de geração quando a velocidade do vento é muito alta.

- **Transformador**

O transformador é composto por um inversor e um retificador, com o objetivo de elevar a tensão para igual com a rede em que a energia está sendo escoada.

- **Estrutura de Suporte**

O suporte para o rotor e nacelle é realizado por uma torre que pode variar de 80 a 100 metros de altura, dependendo do ponto ótimo de velocidade do vento e capacidade da turbina. Ela é de extrema importância para a segurança de todo o sistema e representa cerca de 25% do custo de uma turbina.

Atualmente as turbinas atingiram um ponto ótimo de eficiência aerodinâmica, atingindo o valor de 0,50 de performance em meados do ano 2000, sendo que nos anos de 1980 o valor máximo de performance era de 0,44. O máximo teórico, dado pelo coeficiente de Lanchester-Betz em 0,593. Dessa forma, a produção desse tipo de turbina pode ser realizada em massa, e o ganho de potência decorre da possibilidade do incremento da altura da torre, apresentando significativa diferença nos últimos anos e prospectos futuros, conforme apresentado na Figura 13 (IPCC, 2011).

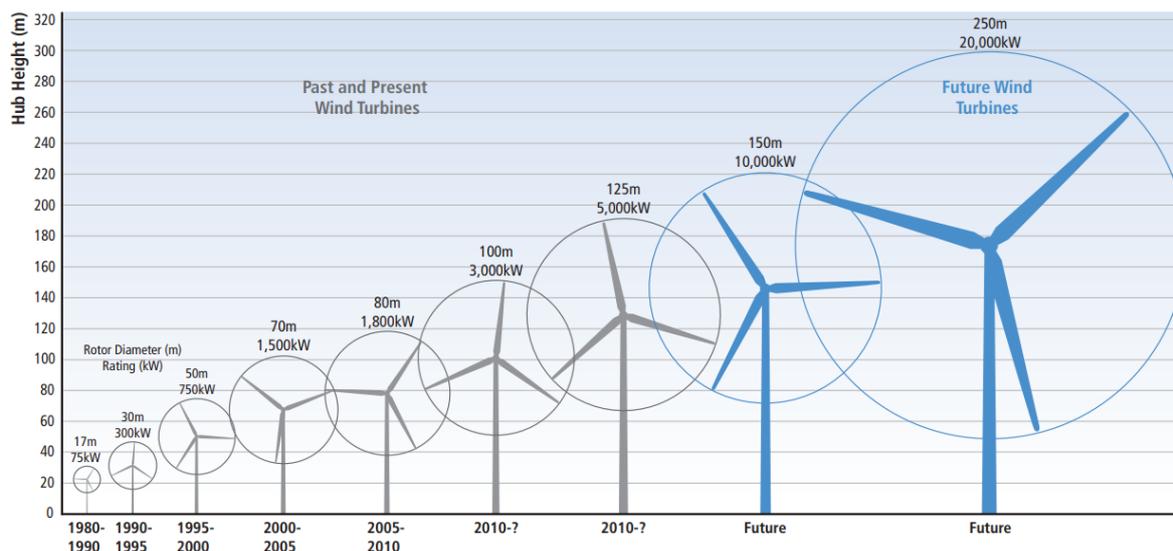


Figura 13 - Evolução teórica das potências de turbinas com base na altura da torre

Mesmo sendo uma tecnologia avançada e bem desenvolvida, ainda existem pontos de inovação para a energia eólica. Exemplos podem ser observados, como:

- **Otimização do controle** com uso de novas tecnologias, como a internet das coisas (ALI; ASHIM; PALLAV, 2022);
- **Turbinas sem pás**, em que a geração é realizada com base na vibração que o vento causa em uma haste vertical o que permite a geração de energia com menor interferência no ambiente (Elsayed; Farghaly, 2022);
- **Usinas Offshore**, que são uma vantagem devido à restrições técnicas ou ambientais da geração de energia onshore, além da possibilidade de atender regiões que não possuem potencial eólico em lugares fora os costeiros (IPCC, 2011).

Por fim, vale indicar que as usinas eólicas, como toda e qualquer construção humana, apresenta impactos ambientais e desvantagens, dentre eles pode-se citar os problemas visuais em localidades turísticas, limitação de passagem em terrenos, ruídos e obstáculos para aves. Muitas ações estão sendo colocadas em prática para evitar tais problemas, além de estudos de cada impacto. (CARVALHO et al., 2016)

2.1.2 SISTEMA DE ARMAZENAMENTO DE ENERGIA

O armazenamento de energia é uma demanda cada vez mais em alta. Isso ocorre devido a alguns fatores que devem ser levados em conta (HUGGINS, 2016):

- Fonte primária de energia é finita: Os combustíveis fósseis, que são atualmente a maior fonte de energia global, é finita e causa sérios problemas ambientais. Com isso, uma necessidade de uso de outras fontes é necessária;
- Fontes renováveis são dependentes de fatores naturais: os principais insumos para as fontes renováveis de energia são naturais (vento, irradiação solar, chuva, etc.), com isso a geração não pode ser realizada sob demanda, e sim quando disponível.
- A demanda de energia é variável: A demanda de energia altera conforme o horário do dia e mês do ano, com isso é inviável o uso instantâneo da energia gerada, precisando alinhar o potencial energético com o consumo.

Nesse trabalho o foco será nas possibilidades de armazenamento de energia elétrica, que é uma parte do problema global de armazenamento de energia, que inclui, além da elétrica, energia para transporte, por exemplo.

Dentre os métodos de armazenamento de energia elétrica, pode-se detalhar alguns importantes de serem observados, sendo (MIRANDA, 2011):

- **Bombeamento de Água**

Uma das principais fontes de geração de energia no Brasil é a hidrelétrica, onde o reservatório pré-turbinas funciona como uma fonte de armazenamento de energia, que será utilizada para a geração posterior.

O sistema de bombeamento utiliza o descolamento da curva de geração com a curva de energia do sistema, fazendo com que a energia sobressalente seja utilizada para bombear a água a jusante para o sistema a montante, garantindo reserva de energia para o momento de maior demanda. Atualmente esse sistema funciona com uma eficiência média de 65% a 70%, apresentando assim certa perda de energia no processo. A Figura 14 apresenta o esquema desse tipo de armazenamento, com a utilização da energia de uma usina eólica, como exemplo.

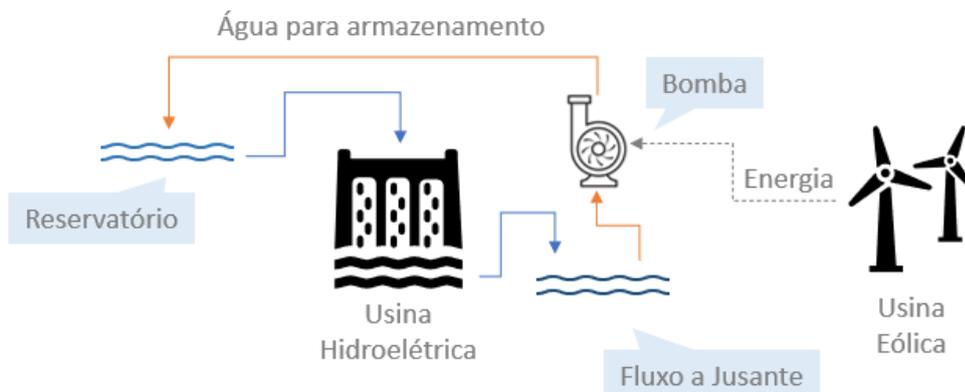


Figura 14 - Sistema de Armazenamento de Água por Bombeamento

- **Ar comprimido**

Utilizado em sistema de geração de energia por gás. Auxilia na diminuição do consumo de gás em cerca de 40%, para ciclo combinado, e 60% em centrais tradicionais (MIRANDA, 2011). O princípio é similar ao visto anteriormente, com a compressão do gás utilizando energia sobressalente da rede, em momentos de baixo consumo. É possível produzir três vezes mais energia com a mesma quantidade de gás.

A ideia é utilizar a compressão do gás utilizando sua propriedade elástica, e posterior expansão em turbinas para a geração de energia. O ar pode ser guardado em cavernas subterrâneas como cavernas de sal e depósitos de petróleo vazios. É possível observar a capacidade de armazenamento do ar pela equação de um gás ideal (HUGGINS, 2016):

$$PV = nRT$$

Em que P é a pressão do gás, V o volume, n é o número de mols, R é a constante do gás, dada por $8,314 \text{ Jmol}^{-1}\text{K}^{-1}$ e T é a temperatura do gás.

- **Volante de Inércia**

Os volantes de inércia datam da idade do bronze, e consiste em uma massa com peso muito maior que o seu sistema, fixada em um eixo, em que a energia elétrica é convertida em energia cinética.

O ideal é que o sistema contenha um grande coeficiente de inércia. Quanto menor o atrito entre paredes e bases, menor é a perda do sistema e maior é o tempo de armazenamento de energia que ele terá.

Atualmente existem volantes de inércia inseridos em sistemas à vácuo, em que o volante fica suportado por dois ímãs magnéticos, reduzindo significativamente o atrito com as paredes. (MIRANDA, 2011).

Porém, seu uso mais comum é a redução das variações de frequência da rede, do que para o armazenamento de energia à longo prazo.

- **Químico (Baterias)**

O Armazenamento por baterias é a utilização de um acumulador químico, que utiliza princípios químicos para armazenar e liberar energia, transformando a energia elétrica em química e vice-versa.

As baterias apresentam grande benefício quando comparado os demais meios, devido à alta densidade de armazenamento de energia, como apresentado na Figura 15 (MIRANDA, 2011).

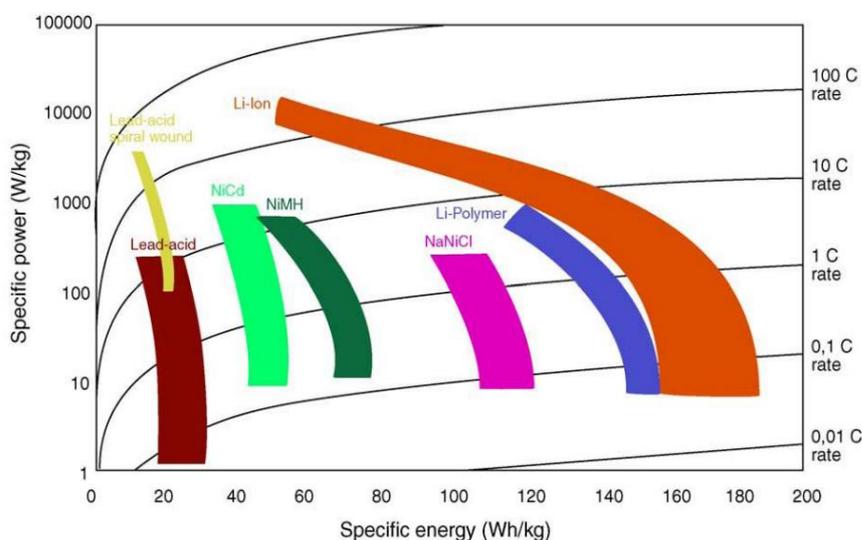


Figura 15 - Relação de densidade por armazenamento das baterias

Uma desvantagem das baterias é o curto ciclo de vida, dependendo do tipo pode chegar a apenas algumas centenas (MIRANDA, 2011). Outro grande problema é o descarte desse material, que apresenta grandes problemas ambientais por não existirem métodos eficazes de reciclagem e reaproveitamento.

- **Baterias de Fluxo Regenerativo**

Esta tecnologia consiste em dois eletrólitos em soluções salinas. A energia é liberada ou armazenada através das reações eletroquímicas reversíveis, que ocorrem por uma membrana seletora de íons que divide os dois materiais, conforme apresentado na Figura 16 (MIRANDA, 2011).

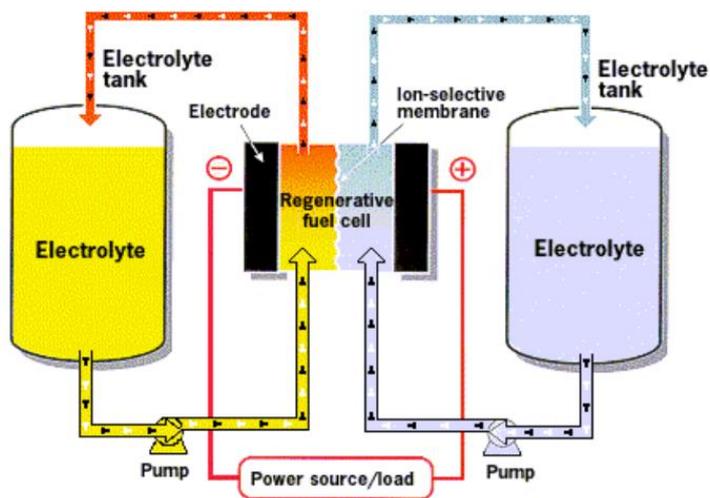


Figura 16 - Apresentação de uma Bateria de Fluxo Regenerativo

Uma das vantagens desse método é a facilidade em aumentar ou reduzir a potência desejada, bastando aumentar os tanques de eletrólitos, porém uma desvantagem observada é o elevado custo de manutenção e transporte, não apresentando uma relação boa de volume *versus* energia.

- **Térmica**

O armazenamento de energia térmica consiste na geração de calor e conversão de estado de um elemento com o objetivo de armazenar a energia e utilizá-la na inversão de tal estado.

Como exemplo prático, pode-se observar as torres de solares, Figura 17. (MIRANDA, 2011)

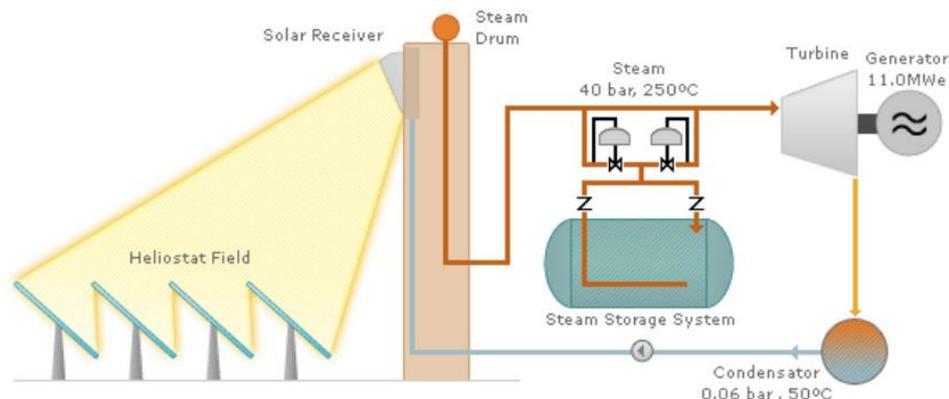


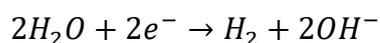
Figura 17 - Ilustração de uma Torre Solar

Nesse sistema, os refletores solares transmitem os raios do sol concentrando-os no topo da torre, onde está um reservatório de solução salina. Essa solução gera vapor e aciona uma turbina, gerando energia elétrica. O sal utilizado pode ser aquecido nos momentos de incidência solar, com a energia sobressalente, e utilizado para a geração posterior de vapor.

- **Hidrogênio**

A produção de hidrogênio é realizada a partir do princípio eletrolítica, em que uma corrente elétrica contínua passa através de um eletrólito imerso em água, separando as moléculas de hidrogênio e oxigênio.

A reação global pode ser apresentada pela fórmula:



A conversão reversa em energia pode ser obtida pela queima do hidrogênio e geração de energia a partir da sua combustão, ou pela utilização de pilhas, junto com o ar atmosférico, conforme apresentado na Figura 18. (MIRANDA, 2011).

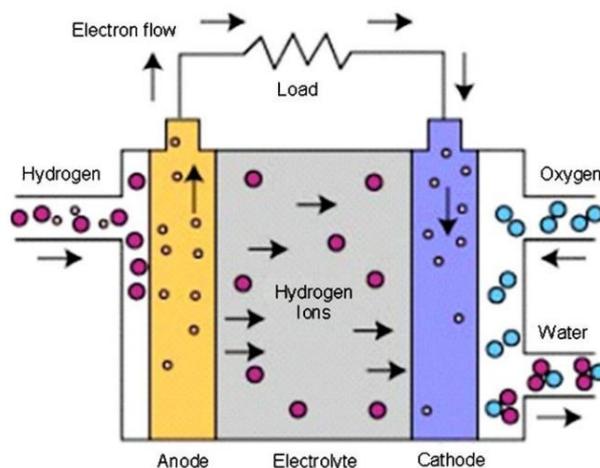


Figura 18 - Pilha a base de Hidrogênio

Outras vantagens do uso do hidrogênio, quando realizado a partir de fontes renováveis de energia, exemplo do Hidrogênio Verde, é a possibilidade de armazenamento e transporte de energia limpa, suprimindo demandas globais de energia com exportação e importação de energia.

2.1.3 MERCADO DE ENERGIA NO BRASIL

O setor energético brasileiro é composto por 7 instituições, conforme Figura 19.

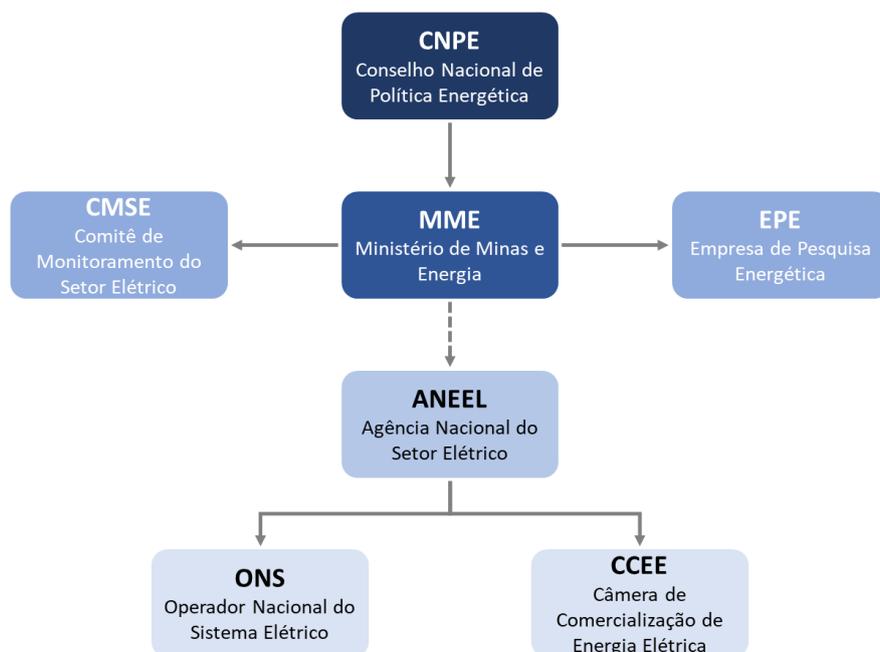


Figura 19 - Estrutura do Mercado Brasileiro de Energia

Os agentes podem ser definidos como se segue (MME, 2021):

- **CNPE – Conselho Nacional de Política Energética**

Órgão interministerial de assessoramento à Presidência da República que tem como principais atribuições a formulação de políticas e diretrizes de energia que assegurem o suprimento de insumos energéticos a todas as áreas do país.

- **MME – Ministério de Minas e Energia**

Órgão do Governo Federal responsável pela condução das políticas energéticas do país.

- **CMSE – Comitê de Monitoramento do Setor Elétrico**

Órgão sob coordenação direta do MME, criado para acompanhar e avaliar a continuidade e a segurança do suprimento elétrico em todo território nacional. O Comitê é formado pelos órgãos MME, Aneel, ONS, EPE, CCEE e ANP (Agência Nacional do Petróleo, não abordado nesse tema).

- **EPE – Empresa de Pesquisa Energética**

Instituição vinculada ao MME cuja finalidade é a realização de estudos e pesquisas destinadas à subsidiar o planejamento do setor energético.

- **ANEEL – Agência Nacional de Energia Elétrica**

As atribuições da Aneel são de regularização e fiscalização da produção, transmissão, distribuição e comercialização de energia elétrica.

- **CCEE – Câmara de Comercialização de Energia Elétrica**

A CCEE reúne empresas e instituições que viabilizam operações de compra e venda de energia em todo o país.

- **ONS – Operador Nacional do Sistema Elétrico**

Responsável por operar, supervisionar e controlar a geração de energia elétrica no Sistema Integrado Nacional (SIN) e por administrar a rede básica de transmissão de energia elétrica no Brasil.

Conforme apresentado anteriormente, a matriz energética brasileira é predominantemente hídrica, o que implica na administração de um recurso variável, a água. Assim tornou-se necessário realizar a integração do sistema e otimização da geração com o objetivo de reduzir a possibilidade de falta de energia e realizar uma geração com o menor custo possível. Dessa forma, a ONS atua no SIN, que interliga todo o sistema nacional em 4 sub-mercados, que são definidos de acordo com os limites de transmissão entre um sub-mercado e outro, sendo Sul, Sudeste/Centro-Oeste, Nordeste e Norte. Maiores detalhes do sistema podem ser observados na Figura 20. (ONS, 2022).

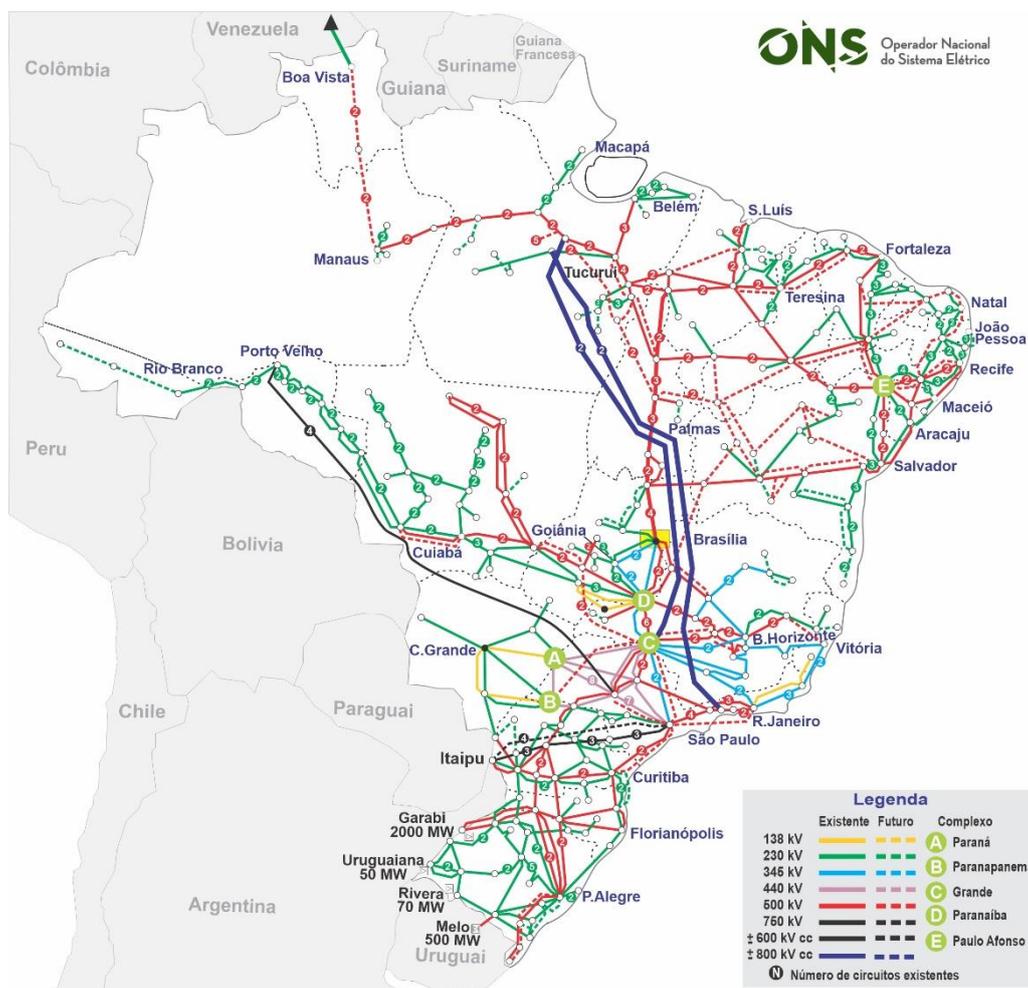


Figura 20 - Sistema Interligado Nacional (SIN) horizonte 2024

Existem ainda partes não conectadas ao sistema interligado, chamadas de **Sistemas Isolados**. Eles estão presentes em sua maioria no Norte do país nos estados de Rondônia, Acre, Amazonas, Roraima, Amapá e Pará, além da ilha de Fernando de Noronha em Pernambuco e algumas localidades do Mato Grosso. A única capital que é atendida ainda por sistemas isolados é Boa Vista em Roraima. Porém a representatividade do consumo nessas regiões é baixa, quando comparado ao total do país, representando cerca de 1% da carga (ONS, 2022).

Dessa forma, o mercado de energia brasileiro é muito conectado e busca a otimização de acordo com os parâmetros da ONS, que foca na redução do custo de geração, utilizando menos possível a quantidade de usinas térmicas, e a disponibilidade de água, utilizando hidrelétricas apenas quando existem previsões de chuvas nos próximos meses. Com isso, o preço da energia varia em função desse uso do sistema.

O preço da energia é dado por **R\$/MWh** (reais por mega watt-hora). Existem dois ambientes no mercado brasileiro, sendo (CCEE, 2022):

- **ACR – Ambiente de contratação Regulada**

A contratação de energia é realizada por meio de leilões de energia, promovidos pela CCEE, que fornecem energia para as distribuidoras que, por sua vez, atenderão aos consumidores regulados, até o momento todos com carga inferior a 0,5 MW.

- **ACL – Ambiente de contratação Livre**

Nesse cenário o contrato é realizado diretamente entre gerador/comercializador e o consumidor final, sendo que o consumidor deve ter potência entre 0,5 MW e 1,5 MW para ser considerado Consumidor Especial, ou acima de 1,5 MW para ser considerado consumidor livre.

O esquemático da Figura 21 apresenta o comparativo entre os dois ambientes (baseado a partir de CCEE, 2022).

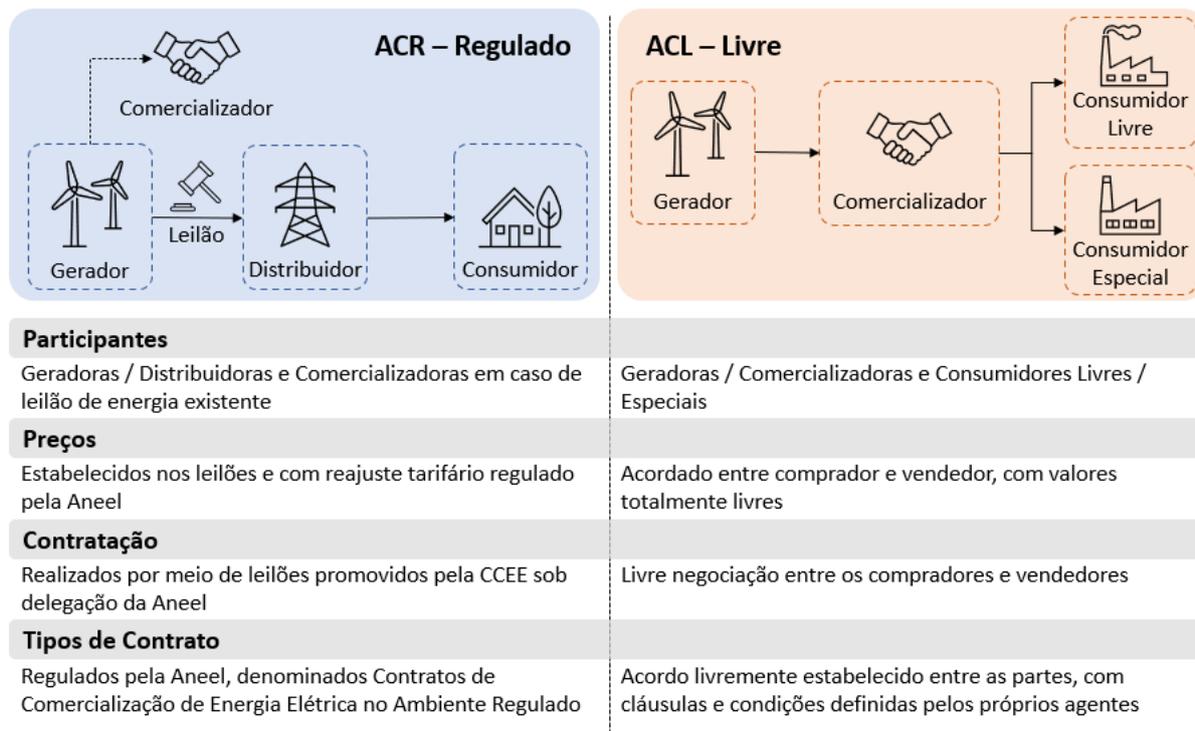


Figura 21 - Comparação entre o ACR e ACL

O ambiente regulado não possui influência do consumidor, devendo realizar o pagamento da tarifa definida pela Aneel para a distribuidora, que realiza o pagamento da energia para a geradora com base na energia leiloadada. Devido à isso, esse trabalho focará no ambiente livre de contratação, principalmente para a definição de preços.

O número de consumidores no mercado livre de energia cresceu mais de 5 vezes nos últimos 7 anos, e representa ~36% do consumo total do país, conforme apresentado na Figura 22. (PORTO, 2022)

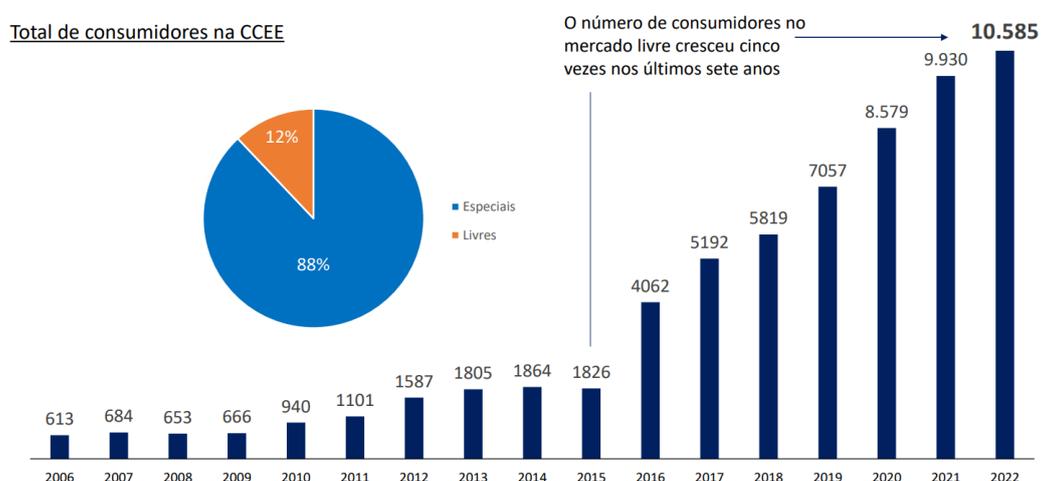


Figura 22 - Evolução dos Consumidores no ACL (PORTO, 2022)

Aproximadamente 35% dos consumidores do ACL fazem parte da categoria de comércio, sendo seguidos pelo setor de serviços, com cerca de 18%. A estimativa é que até 2028 o mercado de energia livre esteja aberto para a totalidade de consumidores, observando-se as mitigações para os possíveis impactos de contratos legados do ambiente ACR e métodos de desligamento de consumidores (PORTO, 2022).

A precificação no ambiente livre de contratação é baseada fortemente no PLD, Preço Líquido das Diferenças, calculado pela CCEE em uma base horária. Esse preço indica o setor naquele momento, ponderando a quantidade de energia ofertada *versus* a quantidade demandada no curtíssimo prazo. Essa metodologia parte do princípio de que a energia é um bem-produzido e consumido instantaneamente e no controle realizado pela ONS para o despacho das usinas, conforme explicado anteriormente. A Figura 23 apresenta essa dinâmica exemplificada.

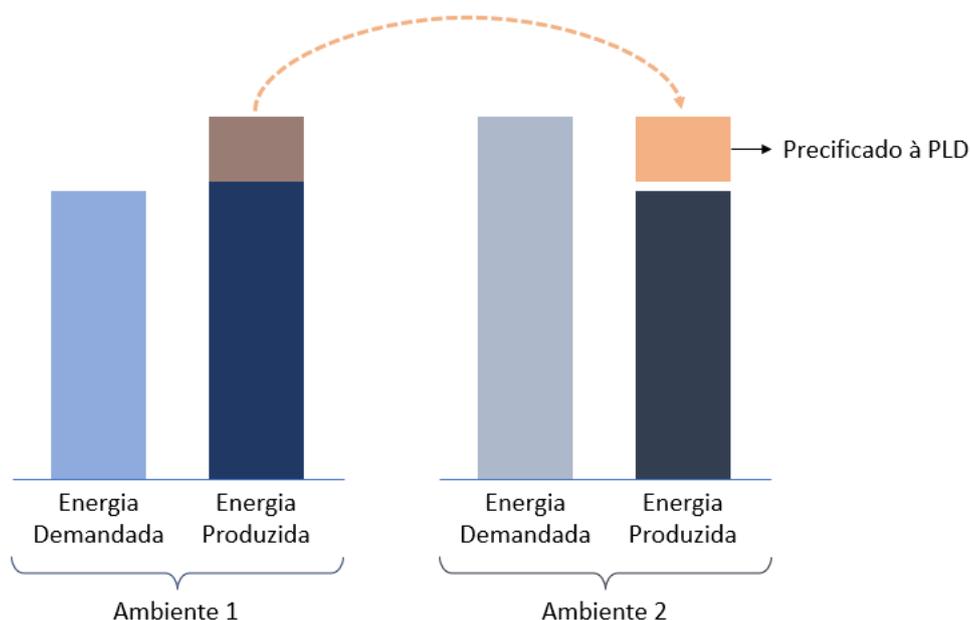


Figura 23 - Exemplificação do Uso do PLD

Para a modelagem do PLD horário, são utilizados modelos matemáticos, os mesmos utilizados pela ONS para o despacho de energia, pela CCEE. Esse preço é calculado para cada sub-mercado, considerando fatores como geração hidráulica, térmica e restrição de transmissão entre os sub-mercados. O processo de definição de preço é dado da seguinte forma:

- Avaliação dos **cenários energéticos** pelos modelos computacionais NEWAVE, DECOMP e DESSEM, conforme Figura 24 (CCEE, 2022).



Figura 24 - Modelos utilizados para a definição do PLD

Sendo:

- **NEWVAE**: Planejamento da operação do sistema hidrotérmico de longo prazo (até 5 anos), apresentando discretização mensal. Usinas hidrelétricas e térmicas são modeladas no sistema, as demais fontes são incluídas como UNSI – Usinas Não Simuladas Individualmente. Assim, esse modelo indica a estratégia de geração hidráulica e térmica que minimiza o custo de operação para todo o período analisado. As funções de custo futuro providas por este modelo são utilizadas no próximo passo, para a modelagem de curto prazo.
 - **DECOMP**: Planejamento da operação do sistema hidrotérmica de curto prazo (2 meses), apresentando discretização semanal. Este modelo apresenta a lógica de simulação das usinas similar ao NEWAVE, e fornece a função de custo futuro para o modelo de curtíssimo prazo.
 - **DESSEM**: Modelo de aprimoramento, avaliando o planejamento de operação de sistema hidrotérmicos de curtíssimo prazo (7 dias), com discretização diária. Neste modelo as informações do sistema como um todo é mais detalhada e as previsões mais assertivas. Assim, é fornecido o Custo Marginal de Operação (CMO) de cada sub-mercado para cada horário.
- Avaliação do PLD mínimo e Máximo
 - O **PLD Mínimo** é dado pelo maior valor entre a Tarifa de Energia de Otimização da UHE Itaipu e a Tarifa de Energia de Otimização (TEO) das outras usinas hidrelétricas do Sistema Interligado Nacional – SIN;
 - O **PLD Máximo** possui como margens o PLD Máximo Estrutural, dado pelo nível de proteção de risco de 95% da função densidade de probabilidade da renda inframarginal, e o PLD Máximo Horário, calculado pela média ponderada pela potência instalada dos Custos Variáveis Unitários (CVUs) das usinas térmicas a óleo diesel.
 - Cálculo do PLD, tendo como limite superior e inferior o PLD máximo e o PLD mínimo, respectivamente.

A Figura 25 apresenta a variação do PLD nos últimos 10 anos, apresentando oscilação dos valores de acordo com o período e sub-mercado, importante notar que os valores são médias dos valores obtidos em cada mês correspondente.

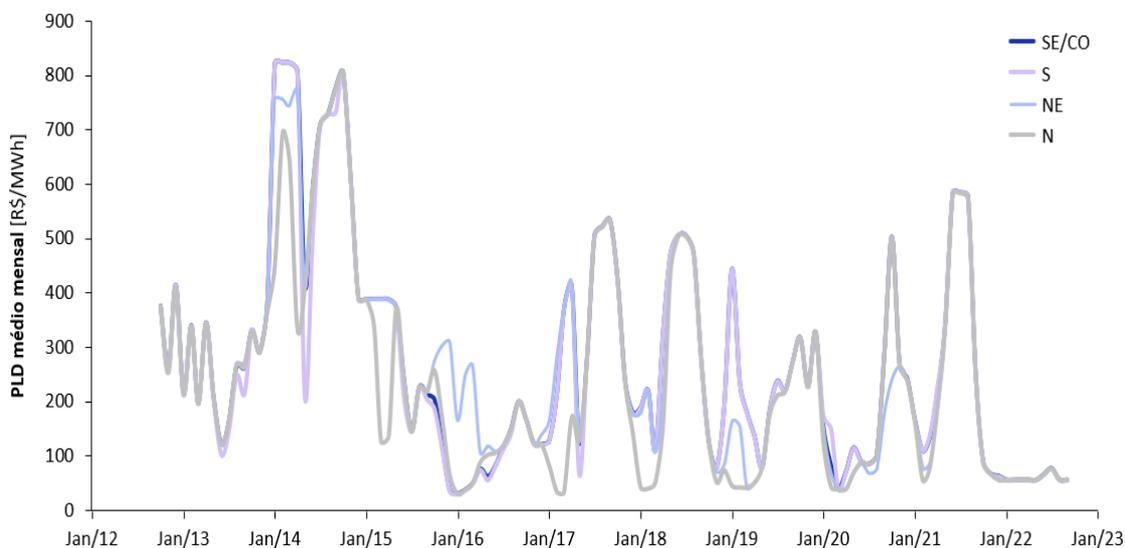


Figura 25 - PLD nos últimos 10 anos

Adicionalmente, o mercado de energia apresenta algumas características de geração que são importantes de serem observadas, sendo:

- **Garantia Física**

Indica a quantidade média de energia que pode ser gerada por uma usina, dada em megawatt médio (*MWm*), indica estatisticamente quanto que a usina irá produzir de energia, em média, nos seus primeiros anos de geração.

A usina Eólica normalmente possui garantia física próximo do seu P90, que é a probabilidade de geração em 90% do tempo; já a usina Fotovoltaica apresenta garantia física próxima do P50, por ser uma energia mais confiável, representando a probabilidade de geração da usina em 50% do tempo; por fim, a usina Hidrelétrica apresenta como base da garantia física a Energia Firme, que corresponde à geração média em um período crítico, com baixa vazão histórica do rio em que está inserida.

- **Demanda Contratada**

Refere-se ao valor que consumidores de média e alta tensão contratam das distribuidoras de energia, com o objetivo de possuírem um valor em quilowatts sempre disponível. Esse valor é cobrado em kW (quilowatt) disponível e, após o uso, existe a cobrança também da energia consumida em kWh (quilowatts hora).

- **Consumo ponta e fora ponta**

Consumo ponta corresponde ao consumo em horário de pico, onde existe o maior uso de energia, e fora ponta corresponde ao consumo em horários de baixa. Esses valores foram definidos para alterar o preço de energia para consumidores de alta tensão, visando a migração da demanda para fora ponta e evitar a sobrecarga do sistema elétrico.

2.2 ANÁLISE DE DADOS E INTELIGÊNCIA ARTICIAL

2.2.1 ANÁLISE DE DADOS E BIG DATA

Nas últimas décadas a evolução tecnológica gerou um aumento significativo no acesso à informações pela sociedade, o que, ao mesmo tempo, implicou em um aumento significativo da quantidade de dados trocados entre as pessoas, muitas vezes sem nem perceber. Com isso, torna-se importante fornecer um método para avaliar e organizar essa quantidade de informações, surgindo assim a análise dados (CONCOLATO; CHEN, 2017).

Para obter um resultado adequado na análise da dados pode-se seguir o chamado ciclo de vida da análise de dados, proposto por Song e Zhu (2017), e sumarizado em conjunto com o ciclo de vida da Ciência de Dados por Caceres (2020), conforme Figura 26.

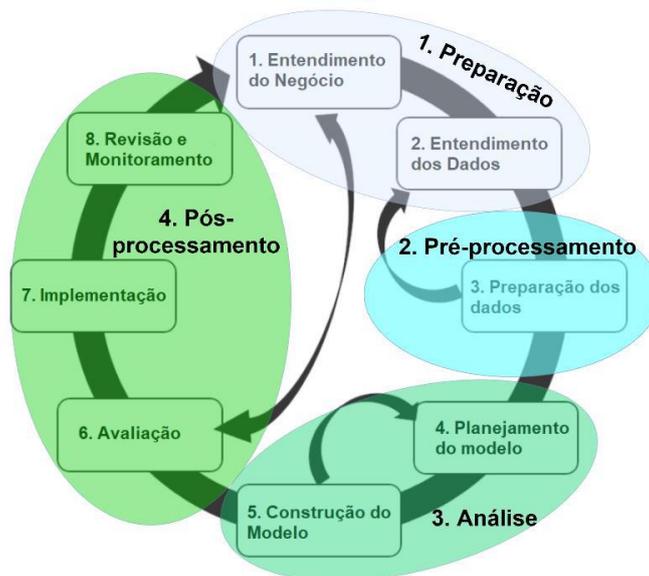


Figura 26 - Ciclo de Vida Composto - Análise de Dados e Ciência de Dados (Caceres, 2020)

Pode-se resumir o ciclo de vida nos seguintes processos (SONG; SHU, 2017; ROSARIO, 2020; CACERES, 2020):

- **Preparação**
 - Avaliação do problema e definição do problema proposto
 - Criação de Hipóteses e premissas
 - Busca, refino e avaliação dos dados
- **Pré-processamento**
 - Filtragem, limpeza e adaptação dos dados obtidos
 - Avaliação da qualidade dos dados obtidos
- **Análise**
 - Análise crítica dos dados pré-processados
 - Avaliação dos métodos de tratamento e modelagem dos dados (regressão, previsão, classificação ou agrupamento)
 - Indicação das variáveis chaves e auxiliares para o modelo
 - Modelagem dos dados

- **Pós-processamento**

- Avaliar e testar o modelo proposto
- Interpretar e documentar os resultados obtidos
- Comunicar os resultados
- Integração de modelos e métodos de controle
- Comunicação de recomendações e monitoramento de melhora e desempenho

Os dados obtidos podem estar em diferentes formatos e serem obtidos de diferentes fontes, dessa forma eles se apresentam em uma das três maneiras distintas (ROSARIO, 2020):

- **Dados não estruturados:** todo dado que não apresenta estrutura que pode ser trabalhada e analisada em conjunto diretamente, como vídeos, áudios, imagens etc.
- **Dados semiestruturados:** Dados que apresentam uma estrutura para análise conjunta, como tabelas, softwares, XML, HTML.
- **Dados estruturados:** Dados prontos para serem compilados e analisados em conjunto, como repositórios, data bases (SQL, MySQL, etc.)

É importante utilizar métodos estatísticos para a avaliação dos dados obtidos, principalmente na parte de pré-processamento e análise, como (CACERES, 2020) histogramas, gráfico de setores, gráfico de barras, box plot, gráfico de dispersão, etc.

Por fim, a modelagem dos dados pode ser realizada de diversas formas, basicamente divididos nos seguintes grupos (ROSARIO, 2020; CACERES, 2020), também apresentado na Figura 27:

- **Classificação:** modelo em que os dados são separados por categorias de acordo com suas especificidades, resultados são no formato discreto;
- **Regressão:** modelo com indicação contínua de resultado, utilizado como forma de previsão de saída dada uma entrada específica;
- **Agrupamento:** modelo com o objetivo de unir os dados similares, de acordo com algumas características, porém sem predefinição de grupos, o que diferencia do modo de classificação.

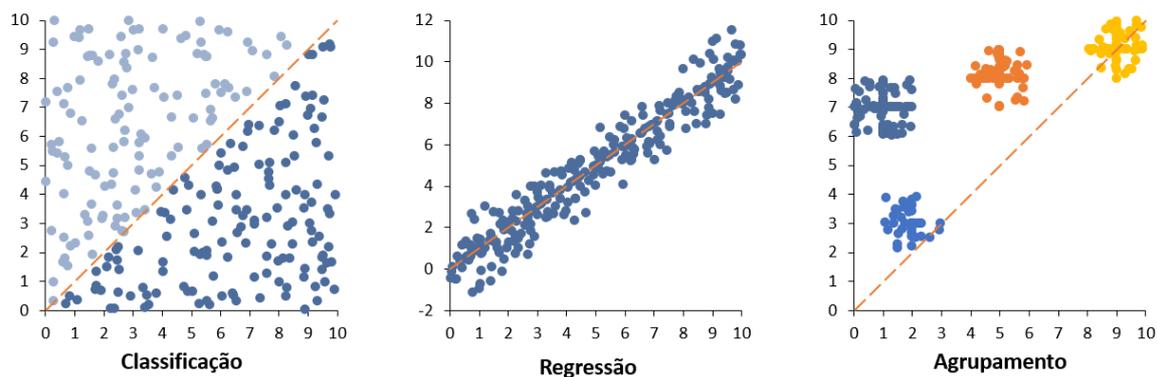


Figura 27 - Métodos de Modelagem (Autor)

2.2.2 INTELIGÊNCIA ARTIFICIAL

A inteligência artificial surge com a ideia de criar uma inteligência, baseada em conhecimentos históricos, computadorizada, assim ela pode agir autonomamente em um ambiente, aprendendo continuamente com seus acertos e erros e, conseqüentemente, evoluindo a cada iteração que realiza (RUSSEL; NORVIG, 2009).

As definições e forma de trabalho com a inteligência artificial remete há muito tempo na história, uma das bases veio da lógica filosófica de Aristóteles com o silogismo, que é um formato dedutível em que se baseia em uma premissa maior, uma menor e, finalmente, uma conclusão. Alinhado à esse pensamento, somou-se a evolução da engenharia na busca por máquinas autônomas e em conhecimentos do cotidiano para gerar a base utilizada para a inteligência artificial (NILSSON, 2009).

Em Caceres (2020) pode-se observar as principais características presentes na IA, sendo:

- **Entendimento da Linguagem Natural:** indica a capacidade da IA de se comunicar em alguma linguagem, sendo entendida e entendendo;
- **Raciocínio lógico:** capacidade de obter resultados e ações com base nas informações coletadas e armazenadas;
- **Aprendizado:** capacidade de aprender e evoluir à medida que mais informações são fornecidas e armazenadas;
- **Visão:** capacidade de obter informações do seu meio, por via de sensores, câmeras, etc.

- **Robótica:** integração de sistemas físicos e computacionais para a obtenção de resultados e ações no mundo físico.

Observa-se que dentro da inteligência artificial têm-se dois grandes grupos, que representam certa interação e níveis diferentes de linguagem, sendo: (ROSARIO, 2020)

- **Aprendizado de Máquina:** tem por objetivo a organização de dados históricos e criação de lógicas para solução de problemas similares, seguindo um método de aprendizagem correspondente;
- **Computação Evolutiva:** Métodos de resolução de problemas complexos, baseados nos conceitos de evolução aplicados à programação computacional.

O aprendizado de máquina é uma das principais utilizações dentro da inteligência artificial. Com ele, é possível obter resultados de programas que não são programados diretamente para isso, mas aprendem a partir de fontes de dados. Os aprendizados podem ser divididos em três principais (RUSSELL; NORVIG, 2009; VERMEULEN,2020):

- **Aprendizado supervisionado:** Os dados são marcados e as entradas e saídas conhecidas. Com essa metodologia é possível ensinar a máquina a desenvolver um método de aprendizado, podendo ser a regressão ou classificação.
- **Aprendizado não supervisionado:** Nesse modelo os dados não são previamente etiquetados, e apenas um conjunto de informações é fornecida ao sistema. Com isso, o sistema busca similaridades entre os dados que não são conhecidas ainda. Muito utilizado para agrupamento e detecção de anomalias.
- **Aprendizado por Reforço:** O aprendizado acontece na interação do sistema com seu meio, aprendendo o que ele pode ou não pode fazer de acordo com os requisitos desejados.

A Figura 28 indica a organização apresentada anteriormente para melhor exemplificar.



Figura 28 - Estrutura de Organização - Inteligência Artificial

Para os aprendizados supervisionados, normalmente utilizados, é importante seguir um fluxo de definição do modelo, conforme apresentado na Figura 29 (CACERES, 2020).



Figura 29 - Fluxo de Desenvolvimento de Modelo de AI

Dentro desse fluxo, pode-se destacar as seguintes etapas (ROSARIO, 2020):

- **Ajuste dos Dados Históricos:** Primeiro passo é avaliar os dados históricos obtidos, com isso pode-se ajustar essas informações com o auxílio das ferramentas estatísticas apresentadas anteriormente, de forma que o modelo aprendido não contenha erros devido à má informação fornecida.

- **Validação Cruzada:** Na validação cruzada é importante utilizar parte dos dados históricos para o aprendizado, normalmente 70%, validar esse resultado e, então, realizar o teste com os outros 30% de dados. Essa divisão normalmente é realizada de forma aleatória para evitar vícios de modelagem.
- **Seleção de Atributos:** Os atributos devem ser selecionados de forma que consigam gerar o melhor resultado, com a menor quantidade de atributos, então devem possuir uma correlação mínima entre eles para fazerem sentido. Os métodos mais comumente vistos são os seguintes (CACERES, 2020):
 - **Wrappes:** O treinamento do modelo é utilizado para a avaliação dos dados;
 - **Filtragem:** Utiliza a estatística para quantificar a relevância dos atributos indicados;
 - **Método Embarcado:** Combina as duas técnicas anteriores, apresentando maior robustez pois utiliza mais de uma técnica para a obtenção dos melhores atributos.
- **Seleção do Modelo:** De acordo com os dados e objetivos da máquina implementada, deve-se implementar o modelo correspondente para obter melhores resultados;
- **Aprendizagem e Refino do Modelo:** Nessa etapa deve-se ensinar o modelo o resultado que deve ser gerado, de acordo com as entradas fornecidas. Após a aprendizagem utiliza-se os demais dados para teste e para refinar o modelo com o objetivo de atingir melhor o resultado esperado.

A **aprendizagem por reforço** é muito utilizada e contém uma aproximação com o pensamento humano, já que são fornecidas recompensas e penalidades em caso de acerto e erro, respectivamente. Dessa forma, a ideia é que o agente busque uma otimização do reforço obtido, aprendendo a gerar as respostas corretas de acordo com as entradas fornecidas (CACERES, 2020).

Um esquema geral pode ser observado na Figura 30 (CACERES, 2020).

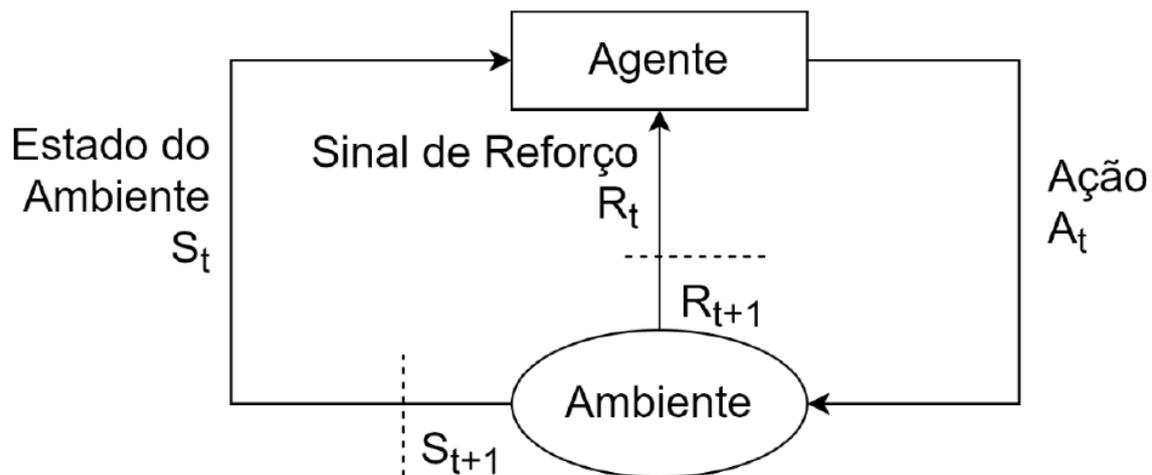


Figura 30 - Esquema genérico do aprendizado por reforço

Os principais elementos obtidos na aprendizagem por reforço podem ser descritos como o seguinte (CACERES, 2020):

- **Política:** Define como um agente deve agir em cada circunstância obtida, definindo, assim, os estados que o sistema deve seguir.
- **Sinal de Recompensa ou Reforço:** Indica o objetivo que deve ser alcançado, sendo o sinal que penaliza ou recompensa o agente de acordo com a resposta correta ou incorreta.
- **Função de Valor:** Indica o conjunto de recompensas de um estado ao longo da vida útil do agente, o ideal é otimizar a função custo/valor de um sistema.
- **Modelo do ambiente:** Sistema que imita o ambiente que o agente estará inserido. Os aprendizados podem ser divididos em:
 - *Model-based:* em que um modelo pode ser obtido para a simulação do ambiente;
 - *Model-free:* em que não é possível obter um modelo para simular o ambiente e, dessa forma, o aprendizado será por tentativa e erro.

Por fim, pode-se avaliar a **computação evolutiva** para concluir a revisão de inteligência artificial. A computação evolutiva apresenta métodos para a resolução de problemas complexos de otimização, baseado na teoria Darwiniana, em que a evolução da espécie se dá pelos organismos melhor adaptados e tal evolução é repassada de geração em geração (ENGELBRECHT, 2007).

Os elementos presentes nos algoritmos evolutivos são os seguintes (CACERES, 2020; ENGELBRECHT, 2007):

- População de Indivíduos: cada indivíduo possui um cromossomo que indica suas características e o torna único, esse indivíduo represente uma possível solução para o problema.
- Geração de Indivíduos: Conjunto dos indivíduos que apresentam as melhores características evolutivas da geração anterior.
- Função de *fitness*: Função matemática que apresenta quão bem cada indivíduo sobrevive no ambiente proposto.
- Operadores de seleção: apresenta o método de seleção os melhores indivíduos para a etapa de reprodução, importante indicar que o melhor, nesse caso, é o que apresenta as melhores características e não necessariamente o mais apto.
- Operadores de reprodução: método de geração de novos indivíduos a partir da combinação das características de dois ou mais indivíduos para gerar uma nova geração mais apta ao ambiente.
- Condições de parada: Indica quando o algoritmo deve parar a execução, podendo ser desde por quantidade de gerações obtidas, convergência de solução ou falta de mudança nas novas gerações.

2.2.3 SOFTWARES AUXILIARES PARA INTELIGÊNCIA ARTIFICIAL

Para o desenvolvimento desse projeto será utilizada a ferramenta *toolbox* do software computacional *Matlab/Simulink* que permitem o desenvolvimento e treinamento de agentes de inteligência artificial computacionalmente, chamada de *Reinforcement Learning Toolbox* (Biblioteca de Aprendizagem por Reforço).

Esse aplicativo permite a modelagem de agentes de inteligência artificial via aprendizagem por reforço, incluindo métodos para os agentes mais comumente utilizados no meio industrial e acadêmico, como DQN, PPO, SAC e DDPG (MATLAB, 2023). A Figura 31 apresenta a interface com o usuário do aplicativo.

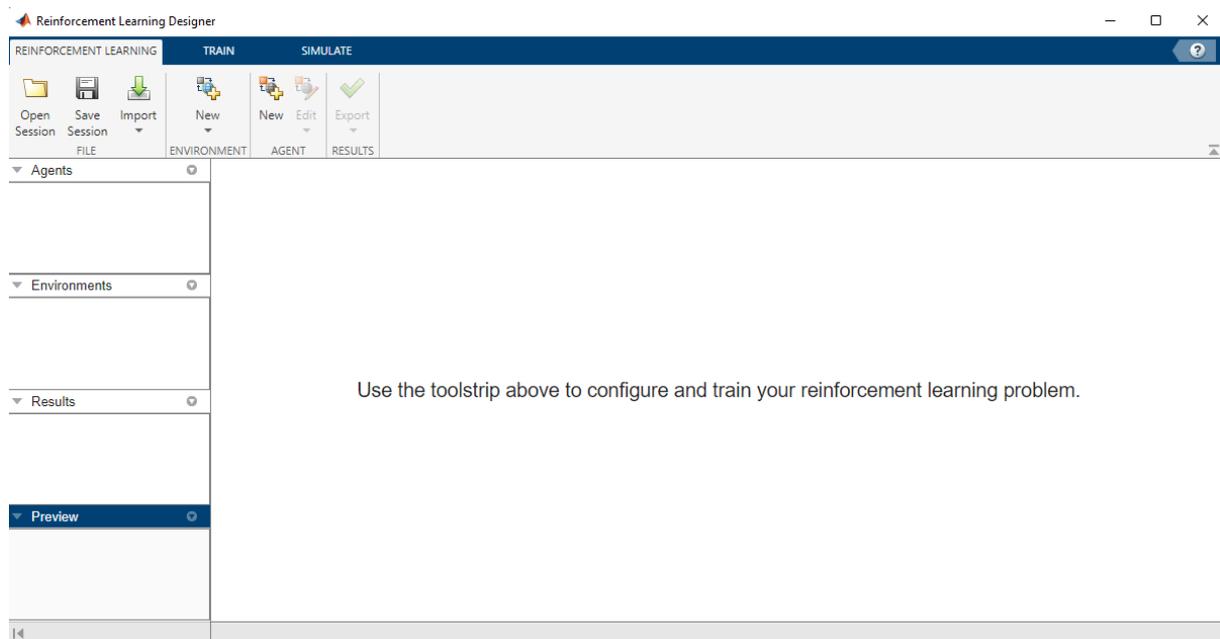


Figura 31 - Interface com o usuário da Toolbox de Aprendizado por Reforço

Conforme apresentado no capítulo anterior, a implementação de inteligência artificial utilizando o aprendizado por reforço requer dois elementos principais, que interagem entre si, sendo o Agente (*Agent*) e o Ambiente (*Environment*). Neste aplicativo é possível importar Ambientes modelados ou customizados para cada aplicação, sendo que esses ambientes podem ser implementados via programação (*Matlab*) ou via elementos de blocos (*Simulink*), conforme apresentado na Figura 32.

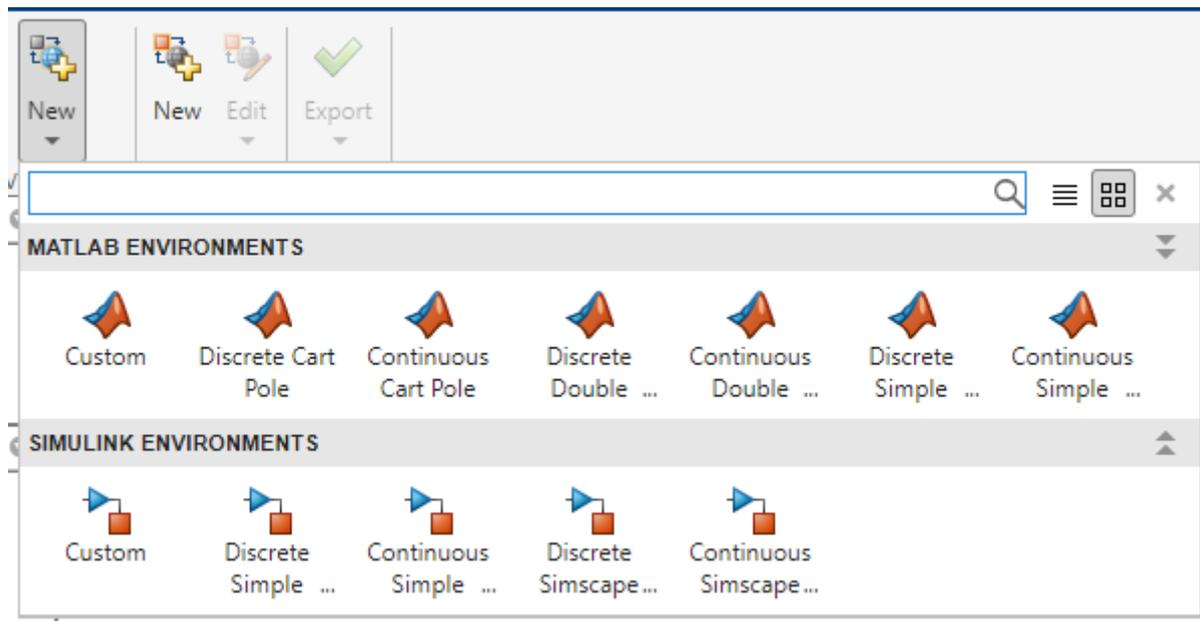


Figura 32 - Importação de Ambientes para a geração de Agentes

Para a criação do agente pode-se utilizar as linhas de comando do Matlab, possuindo uma função específica para cada tipo de agente desenvolvido, sendo, por exemplo, a função $rlDQNAgent(observationInfo, actionInfo)$ utilizada para a criação de um agente do tipo DQN, em que são necessárias as informações do vetor de Observação do Ambiente de Ação do Agente, que contém informação de dimensionamento e tipo (discreto ou contínuo), de acordo com cada Ambiente desenvolvido. Além disso, pode-se criar diretamente no aplicativo o Agente escolhido, para tal é necessário primeiramente importar um ambiente para o sistema e então criar um agente com as características de cada um, conforme Figura 33.

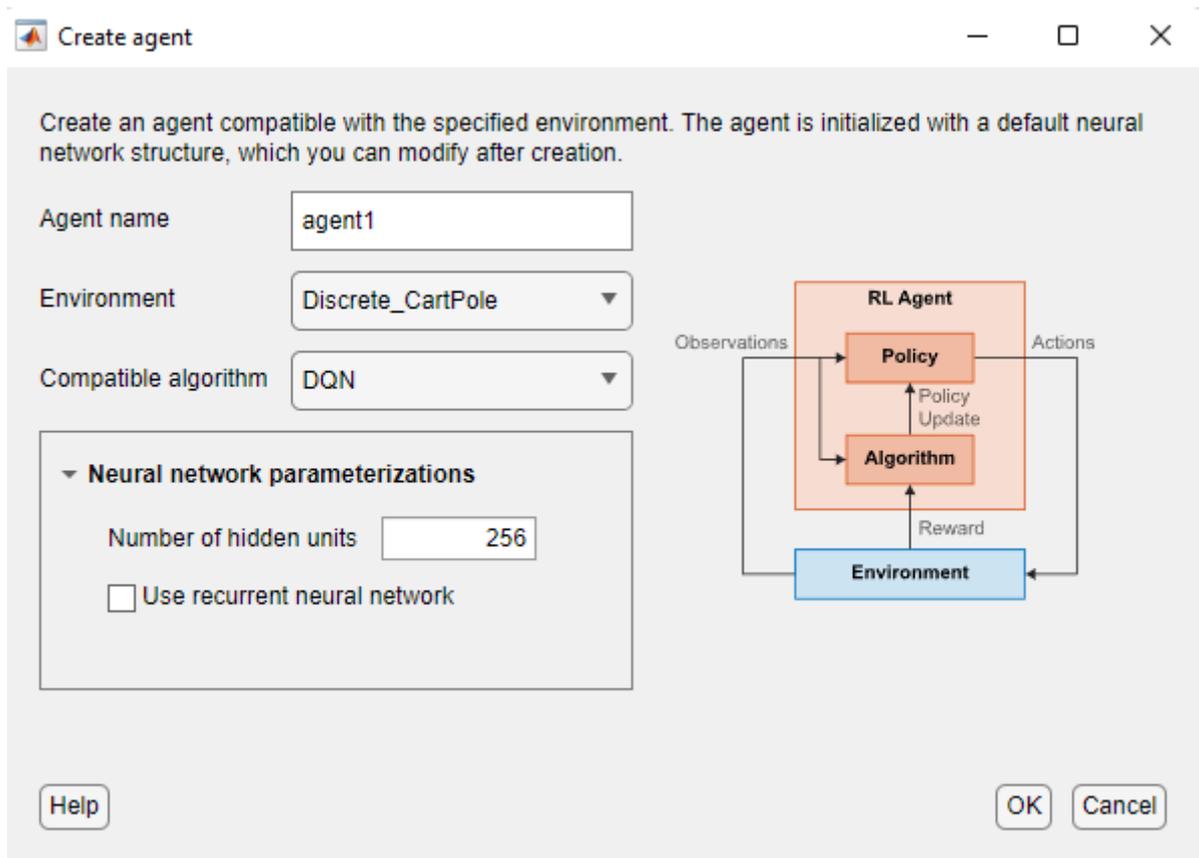


Figura 33 - Criação de um novo Agente via aplicativo Matlab

Com o ambiente e agente definidos, pode-se realizar o treinamento do agente, de acordo com algumas especificações básicas, sendo:

- Número máximo de episódios
- Quantidade máxima de passos em cada episódio
- Janela para o cálculo da média das recompensas
- Critério de parada, podendo ser:
 - Média de passos por episódio
 - Média de recompensa total por episódio
 - Recompensa do episódio
 - Passos totais somados globalmente
 - Quantidade total de episódios simulados

Com tais definições é aberta uma janela apresentada os resultados das simulações, sendo o valor de Q_0 , valor estimado de recompensa para o episódio, definido pelo crítico, recompensa média e recompensa de cada episódio, conforme apresentado na XXXXX.

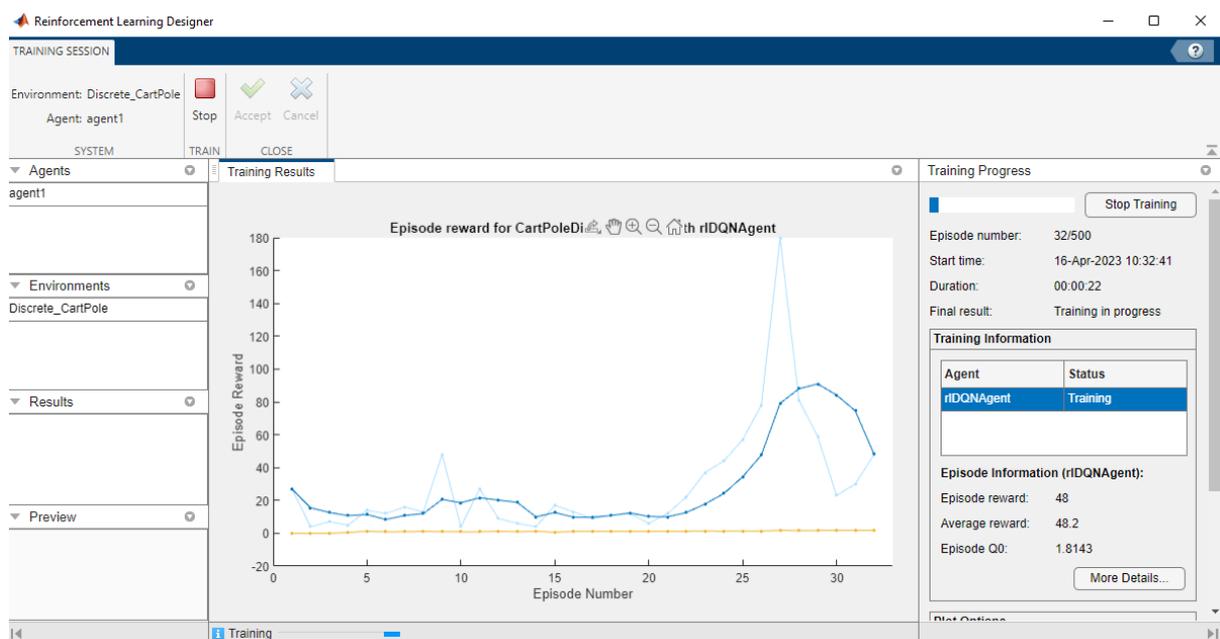


Figura 34 - Treinamento de Agente via aplicativo Matlab

Ao final do treinamento, se os resultados foram os esperados, é possível aceitar, finalizar o treinamento e exportar o agente para o *workspace* do *Matlab*, possibilitando a utilização do agente para demais simulações.

Adicionalmente o software ainda permite a inclusão ou exportação de resultados para códigos de programação, como *Python* e *C++*, e contém ainda ambientes modelados para auxiliar no aprendizado da ferramenta, como:

- **Ambientes discretizados:** *Pendulo simples, Integrador Duplo e Cart Pole;*
- **Ambientes contínuos:** *Pendulo simples, Integrador Duplo e Cart Pole.*

Sendo, assim, uma ótima ferramenta para aprendizado e simulação de diversos Ambientes e Agentes.

2.3 PESQUISA OPERACIONAL E APLICAÇÃO NA INDÚSTRIA DE ENERGIA

A pesquisa operacional (PO) está contida dentro da matemática aplicada e visa a resolução de problemas complexos com a aplicação de modelos matemáticos, com o principal objetivo de otimizar a resolução do problema, sendo aplicada em diversas áreas como Finanças, Administração, Governo, Logística e Energia (CACERES, 2020).

A PO data de meados de 1940, iniciando no Reino Unido na segunda guerra mundial e logo chegou aos Estados Unidos, sendo que um dos principais objetivos era a busca eficiente do uso dos recursos escassos da época. (CHURCHMAN; ACKOFF; ARNOFF, 1957).

Embora seu desenvolvimento tenha se iniciado em um contexto militar, foi durante a revolução industrial que a PO sofreu grande evolução, isso ocorre devido à mudança, principalmente, do tamanho das empresas, que passaram de pequenas para grandes corporações, com divisão de atividades e responsabilidades. Com isso, surgiram problemas de tomada de decisão, em que cada departamento da empresa tem um objetivo diferente e busca otimizar um ponto específico. Um exemplo pode ser observado na Figura 35. (CHURCHMAN; ACKOFF; ARNOFF, 1957).



Figura 35 - Exemplo da Otimização via Pesquisa Operacional

Nesse exemplo, a pesquisa operacional consegue auxiliar a empresa na busca da otimização de um objetivo conjunto, que não irá atender o ponto ótimo local de cada área, mas sim o global da empresa.

A pesquisa operacional é dividida em 6 etapas, sendo: (CHURCHMAN; ACKOFF; ARNOFF, 1957)

- **Formulação do Problema**

Definição do problema que deve ser resolvido. Deve-se realizar uma análise do sistema sob influência, seus objetivos e suas possibilidades de ação. É importante definir outros aspectos que serão afetados com a solução do problema, e incluí-los na formulação. Por fim, define-se uma medida de efetividade.

- **Construção de um modelo matemático**

O problema matemático indica a efetividade do sistema em função de um conjunto de variáveis, sendo que essas variáveis são divididas entre as que possuímos controle e as que não possuímos controle (entradas e saídas do sistema).

- **Obtendo uma solução do Modelo matemático**

A solução deve ser obtida realizando uma análise dupla, sendo: (i) **Analítica**, em que o modelo é avaliado com base matemática de resolução de problemas, aplicando diversas técnicas para avaliar os impactos das variáveis, uma na outra e; (ii) **Numérica**, em que são realizadas iterações para as variáveis de controle a fim de obter um resultado ótimo final.

- **Teste do Modelo e da Solução**

O modelo deve representar o mais próximo possível a realidade do sistema em estudo, assim é importante avaliar se o resultado do modelo está condizente com o que deveria ser na realidade. Assim uma forma de se testar é realizar a comparação da aplicação das soluções do sistema com a não aplicação, utilizando dados históricos, e realizar uma análise crítica do resultado obtido.

- **Estabelecimento de controle sobre a solução**

O modelo só é válido enquanto as variáveis não controláveis e suas relações continuam válidas, então é importante criar um controle dessas variáveis e relações para que se forem alteradas, mudanças no modelo sejam aplicadas para continuar sua utilização e resultado otimizado.

- **Implementação da Solução**

Por fim, a solução ótima obtida deve ser implementada e traduzida de forma fácil para que as pessoas responsáveis possam implementá-la da maneira correta.

Caceres (2020) apresentou algumas aplicações de PO em diversas áreas, alguns exemplos serão apresentados a seguir:

- **Logística**

A logística trata da forma que os materiais e produtos são transportados, podendo ser dentro ou fora das empresas. O Dilema do Caixeiro Viajante é um grande exemplo dos desafios da logística, em que se deve otimizar o caminho de um caixeiro que deve passar por algumas cidades, há certa distância uma da outra.

Diversos trabalhos são realizados com a aplicação da PO dentro dessa área, Caceres cita três exemplos interessantes, sendo um o reprojeto de um sistema de distribuição para entrega expressa de encomendas (PARRIANI et al., 2019), outro sendo a otimização do rearranjo de um pátio de contêineres (BACCI et al., 2019) e por fim a minimização da distância percorrida pelos trabalhadores carregando produtos (BUÉ et al., 2019).

- **Ciências Sociais**

A aplicação de resoluções matemáticas em problemas de ciências sociais vem crescendo, mostrando a importância da interconexão de áreas que antes não eram correlatas. Exemplos da aplicação podem ser observados em Konrad et al. (2017) em que é abordado o tema de PO para a resolução do problema de tráfico de pessoas, outro exemplo é nas realocações de animais para otimizar o tempo de adoção (GENTILI; GERBER; GUE, 2019).

- **Energia**

Dentro da área de Energia, existem diversos fatores que fazem com que a PO possa ser utilizada na otimização da geração de energia. Nenhuma fonte de energia é completamente sustentável, como apresentado anteriormente, e cada uma causa impactos ambientais e sociais diferentes que devem ser levados em conta. Porém a

produção de energia se tornou um fator essencial para a evolução da sociedade e redução de desigualdades.

Dois exemplos apresentados em Caceres (2020) são o da aplicação da PO na definição de políticas públicas em energia (WEYANT, 1994), em que a geração de energia é avaliada sob um ponto de vista econômico, com os impactos das políticas públicas. Outro exemplo é obtido em Momoh (2017), que otimiza o fluxo de potência tendo como referência os custos, confiabilidade e utilização de sistemas inteligente.

As técnicas de pesquisa operacional, visando a otimização de cenários complexos, junto com a aplicação da Inteligência Artificial, possuem um forte potencial de otimizar os recursos energéticos de diversos tipos de cidades. Assim é importante realizar a avaliação de diversos tipos de cenários para constatar tal potencial. Este trabalho busca tal avaliação estudando a implementação dessas técnicas em cidades de pequeno, médio e grande porte, conseguindo abranger as particularidades de cada uma, e, conseqüentemente, as características necessárias.

Assim, a grande evolução das cidades e o aumento no uso de tecnologias, torna essencial o uso de recursos energéticos, principalmente renováveis, visando a melhora da vida em sociedade e preservação do meio em que as pessoas habitam. O uso de recursos matemáticas inovadores, de análise de dados, inteligência artificial e pesquisa operacional, permitem a otimização do uso desses recursos, utilizando como base a implementação de baterias para suportar os momentos de baixa geração, e utilizando o mercado de energia para torna financeiramente viável tal implementação. Porém, torna-se necessário definir quais variáveis e quais cenários devem ser abordados dentro da inteligência artificial, o que será abordado em maiores detalhes no capítulo a seguir.

3 INTELIGENCIA ARTIFICIAL E ANÁLISE DE DADOS

Este capítulo busca delimitar o estudo da análise de dados e inteligência artificial para o problema proposto, da geração híbrida de energia com a busca pela otimização de algumas variáveis chaves. Com isso, busca-se apresentar variáveis que façam sentido para o estudo proposto e que auxiliem na resolução e otimização do problema.

Para tal, divide-se a discussão nos seguintes tópicos:

- **Escopo do Projeto**

Visa delimitar o escopo do projeto, apresentando a estrutura entre os diversos agentes do sistema, as variáveis que auxiliem na resolução do problema e, adicionalmente, o escopo que deverá ser implementado no âmbito da inteligência artificial e otimização. Apresenta-se, ainda, a complementariedade da geração solar e eólica, que permitem que o sistema seja o mais otimizado possível.

- **Trabalho de Referência**

Indica-se o trabalho que foi a base para a elaboração desse estudo, indicando as metodologias aplicadas, motivadores e processo desenvolvido. Dessa forma é possível construir e observar toda a base para o trabalho, obtendo-se, assim, um ponto de partida para os estudos realizados.

- **Modelagem Proposta**

Esta etapa busca abranger o tipo e processo de modelagem utilizada para a obtenção do resultado esperado. Para melhorar a fluidez e desenvolvimento, divide-se em duas partes, sendo:

- **Estratégias Propostas**

Indicando as possíveis estratégias que podem ser implementadas, benefícios e problemas que elas podem enfrentar para obtenção do resultado desejado;

- **Cenários de Implementação**

Analisa os cenários que a modelagem pode ser implementada, e quais são os fatores mais importantes que devem ser levados em conta nessa definição.

Observa-se os pontos positivos e negativos dos possíveis cenários, e possíveis desafios para cada um.

3.1 ESCOPO DO PROJETO

Este projeto foca na análise da aplicação de técnica de inteligência artificial dentro do setor de energia, considerando geração, consumo e seu mercado de compra e venda. Dessa forma, a inteligência artificial funciona como um tomador de decisão que poderá ter algumas ações definidas dentre desse escopo proposto. A Figura 36 demonstra a interação dos diversos fatores do sistema.

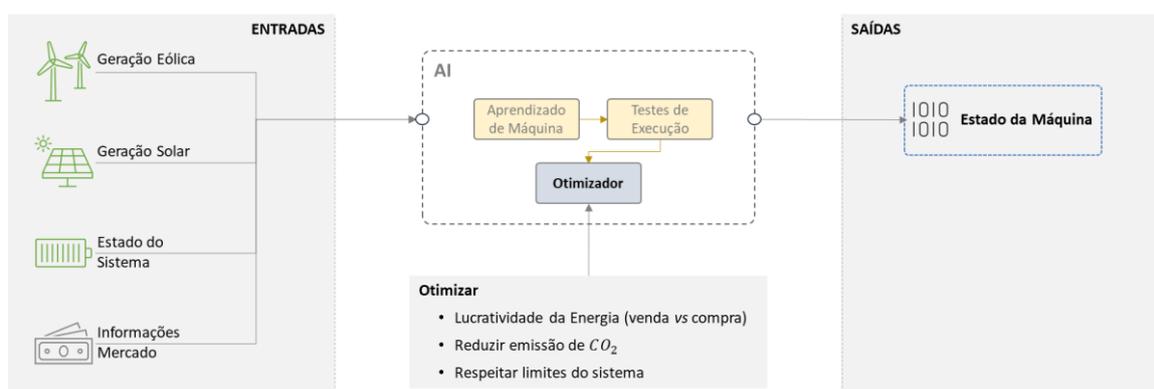


Figura 36 - Interação dos Agentes do Projeto

É possível observar que existem diversos componentes dentro do sistema proposto, a seguir será detalhado cada um deles.

- **Geração Eólica e Solar**

Essas fontes de energia representam um dos principais objetivos do sistema, a produção de energia limpa e autonomia energética do local de trabalho. As gerações de energia eólica e solar tendem a ser complementares no Brasil, conforme exemplificado na Figura 37 (ONS, 2022). Dessa forma, busca-se que a energia possa suprir totalmente a demanda exigida, porém a curva de demanda é muito variada, e dependendo do local de aplicação pode ser necessária mais energia em um momento do dia, ou mesmo em uma estação, do que em outra. Assim a geração de energia atual é uma entrada muito importante para o sistema.

Adicionalmente, o treinamento da AI deve ser elaborado de tal forma que consiga avaliar informações dos **insumos da geração**, nesse caso **velocidade de vento** e **irradiação solar**, para que consiga prever, com base no aprendizado de máquina, qual a tendência desses insumos nas próximas horas e, assim, tomar a melhor decisão do uso da energia.

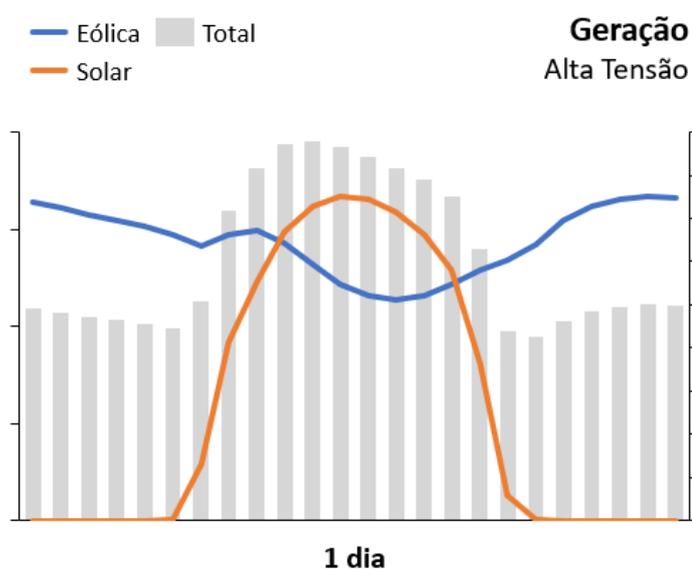


Figura 37 - Exemplificação da Complementariedade Solar e Eólica

- **Informações do Mercado**

O Mercado de energia sofre grande volatilidade no preço, que pode ser obtido em frequência horária. Como apresentado anteriormente, esse cálculo leva em consideração fatores ambientes, no caso do cenário brasileiro, que são as chuvas previstas, para que então seja estimado o uso das hidrelétricas ou térmicas, e o preço de geração de cada uma delas.

Os dados da ONS (2022) apresentam uma visão do nível dos reservatórios nos últimos 5 anos, para cada sub-mercado de energia, e, fazendo uma avaliação em relação ao preço PLD (Preço Líquido das Diferenças) da CCEE (2022) no mesmo período, é possível observar que a relação entre eles é inversamente proporcional, sendo o nível dos reservatórios, ou até mesmo o índice pluviométrico, uma boa variável para o

aprendizado de máquina do sistema. A Figura 38 apresenta esta relação nos 4 sub-mercados.

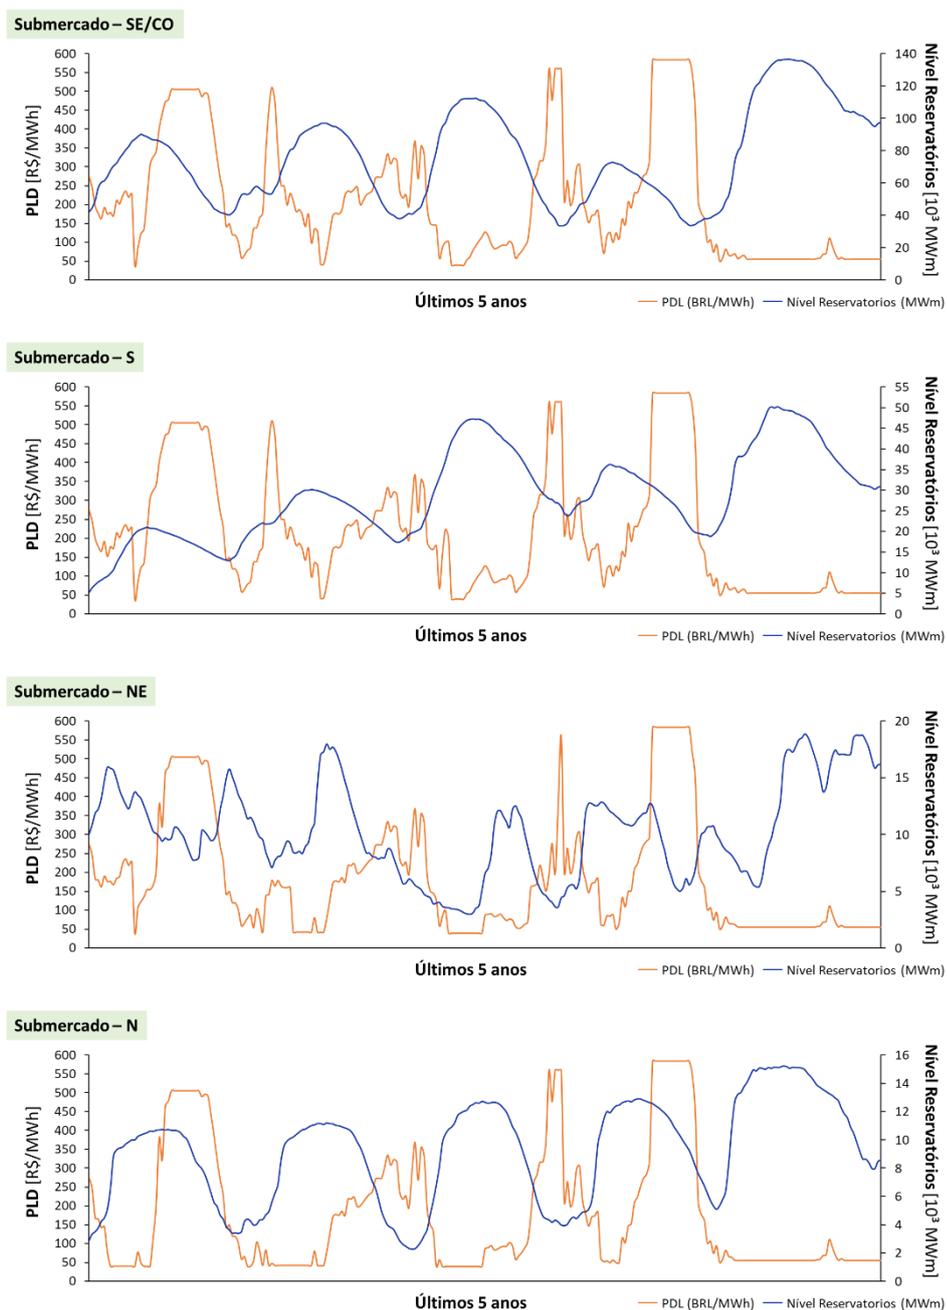


Figura 38 - Relação de PLD versus Nível dos Reservatórios nos últimos 5 anos

Como análise adicional, para observar a relação, é possível observar um gráfico de dispersão dos valores apresentados anteriormente, tal gráfico é apresentado na Figura 39.

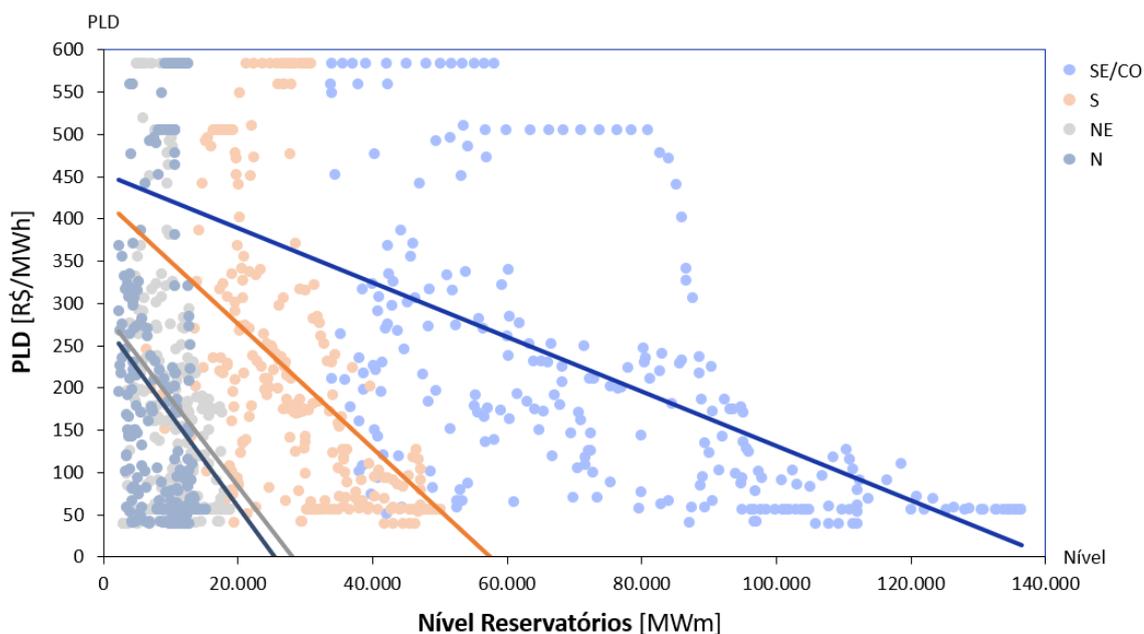


Figura 39 - Correlação entre o preço PLD e o Nível dos Reservatórios

É interessante observar na Figura 4 que todos os sub-mercado possuem correlação entre os dois fatores, porém alguns apresentam uma inclinação maior ou menor entre eles. Isso ocorre pois o preço do PLD é dado com base no sistema como um todo e a variação dos reservatórios depende do tamanho disponível de cada um. Por fim, é interessante observar também os limites máximos e mínimos que ficam visíveis no gráfico de dispersão, apresentando esse limitador da fórmula.

- **Estado do Sistema / Estado de Máquina**

Esse fator é a principal informação que a inteligência artificial fornecerá para todo o sistema. O estado indica qual ação deve ser tomada pelo sistema no momento adequado, observando-se as diversas variáveis presentes e otimizando a função custo programada. Exemplo de estados que podem ser utilizados, no escopo específico desse projeto:

- **Carregamento das Baterias**

Momento em que o sistema escolhe pelo carregamento das baterias, ou por estar gerando em excesso, ou pelo custo reduzido da energia na rede, dependendo do peso fornecido de cada variável para a tomada de decisão

- **Fornecimento de Energia para cobrir a demanda**

Utiliza a geração para suprir a demanda local de energia, não carregando, nem descarregando as baterias

- **Descarregamento da bateria**

Momento em que o sistema deve utilizar a carga armazenada para a venda de energia ou para uso no consumo da demanda local

- **Compra de energia da Rede**

A compra pode ser realizada ou para carregamento das baterias, ou para o consumo interno, dependendo dos fatores otimizados

O número de estados é ilimitado, e podem ser definidos mais ou menos de acordo com a complexidade e tomadas de decisões que o modelo pode oferecer.

- **Inteligência Artificial**

A inteligência artificial será a responsável pela tomada de decisão do sistema, de acordo com o aprendizado obtido e buscando otimizar alguns parâmetros pré-definidos. Ela será composta por:

- **Aprendizado de Máquina**

O aprendizado é realizado com base em dados históricos, e na realização de testes com o modelo final. Com ele, o sistema consegue realizar previsões estimadas das respostas, com base em fatores momentâneos observados.

É uma etapa fundamental da implementação do sistema, passando por toda a estrutura de desenvolvimento a fim de obter os melhores resultados

○ **Otimizador**

Dentro do otimizados será implementada a função custo do sistema, e tal função deverá contar com a relação das variáveis que devem ser otimizados, como a receita/preço da energia, geração de gás carbônico ou mesmo bem-estar social da população.

Com as informações obtidas desses dois fatores, junto com as informações externas, é possível obter uma decisão de qual é o melhor estado que o sistema deve realizar, mantendo ou alterando o estado atual. A Figura 40 apresenta um exemplo da relação da inteligência artificial com o sistema proposto.

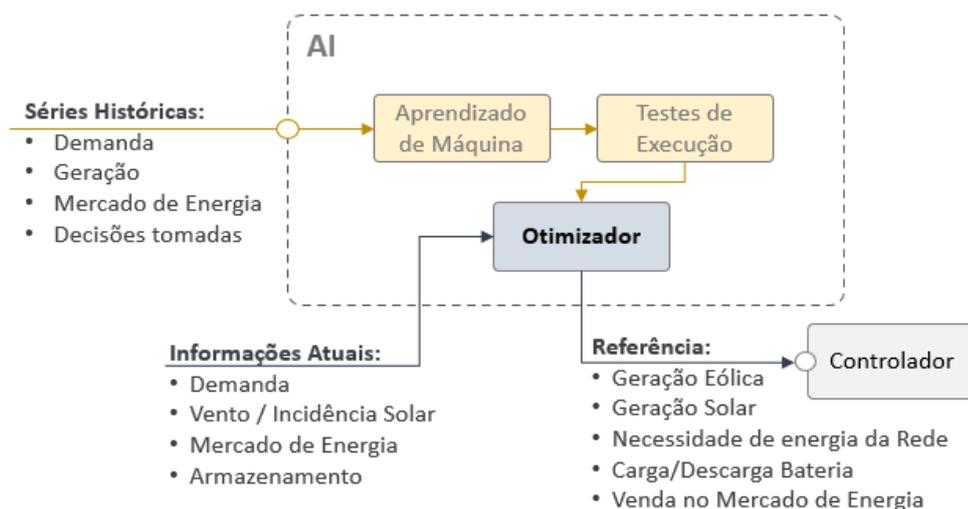


Figura 40 - Exemplo da aplicação de Inteligência Artificial na Geração de Energia

O controlador apresentado representa a tradução do estado ou referência que a inteligência artificial fornecerá para ações no próprio sistema, como ligar/desligar algum agente ou mesmo realizar a compra/venda no mercado livre de energia.

3.2 TRABALHOS DE REFERÊNCIAS

Para este projeto, foi utilizada como principal referência e forma de base a tese de doutorado de Caceres (2020). Em que é abordado o tema de inteligência artificial aplicada em diversos casos, dentro deles, em que será focado este trabalho, o do sistema de geração e fornecimento de energia elétrica. Adicionalmente, como base para os estudos e modelos de energia renovável, este trabalho baseia-se na tese de doutorado de Mora Montañez (2020).

Para a realização do estudo, foi dividido o problema em 8 etapas, seguindo metodologia proposta por Caceres (2020) em seu trabalho, sendo:

- Definição e delimitação do caso
- Modelagem matemática dos sistemas
- Obtenção e tratamento da base de dados utilizada
- Desenvolvimento de ferramentas de simulação
- Avaliação das limitações e problemas com base na análise de dados
- Criação de soluções com o auxílio da inteligência artificial
- Seleção das soluções criadas anteriormente
- Estudo comparativo com modelo tradicional

A primeira etapa baseia-se na **definição e delimitação do estudo de caso**, no caso de Caceres (2020) o sistema foi definido como uma **Geração Distribuída de Energia**, que corresponde a um sistema em que pequenos geradores produzem a energia e distribuem para a rede comum, sem a necessidade de grandes usinas. Esse modelo de geração está sendo amplamente implementado atualmente, observando-se crescente potência instalada de energia solar nos tetos das casas. O modelo apresentado por Caceres (2020), baseado em Mora Montañez (2020) é o indicado na Figura 41.

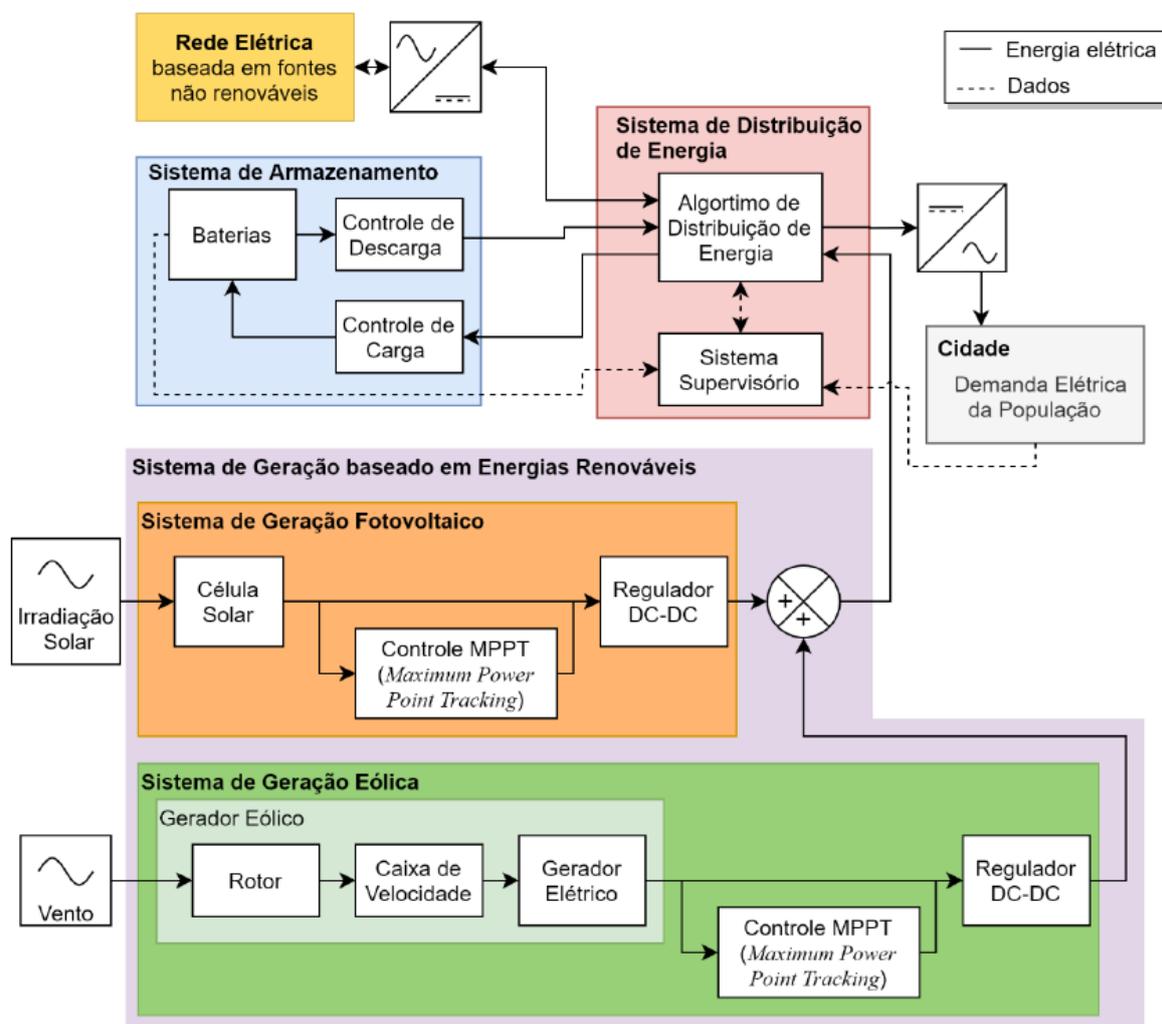


Figura 41 - Modelo proposto por Caceres (2020)

Para limitar o escopo de estudo, a implementação e levantamento de dados foi realizada com base em uma área rural, próxima de Barranquilla, Colômbia, de coordenadas geográficas (10.9750°, -74.8715°). Tal localidade possui alta potência de geração solar e eólica, sendo, por este motivo, escolhida para o estudo em questão.

Para a segunda etapa, avalia-se a **modelagem matemática dos agentes que compõem o estudo**. Assim, têm-se:

- **Sistema de Geração Fotovoltaica**

Mora Montañes (2020) define o sistema de geração fotovoltaica com a utilização de três equações principais, (3), (4), (5):

$$I = I_{ph} - I_o \left[e^{\left(\frac{V+I+R_S}{AN_s \frac{KT_c}{q}} \right)} - 1 \right] - \frac{V + R_S I}{R_p} \quad (3)$$

$$I_{ph} = \frac{(I_{ph,ref} + \mu \Delta T) * G}{G_N} \quad (4)$$

$$I_o = I_{SC,ref} \left(\frac{T_c}{T_{c,ref}} \right)^3 e^{\left(\frac{-V_{OC,refg}}{AN_s \frac{KT_c}{q}} \right)} e^{\left[\left(\frac{qE_g}{AK} \right) \left(\frac{1}{T_{c,ref}} - \frac{1}{T_c} \right) \right]} \quad (5)$$

Onde:

I = corrente da célula;

I_{ph} = corrente gerada pela luz incidente, sendo proporcional à irradiação solar;

I_o = corrente de fuga;

V = tensão do diodo;

A = fator de idealidade, depende do fabricante;

N_s = número de células conectadas em série;

K = constante de Boltzman (1.380e-23 J/K);

T_c = temperatura atual [K];

q = constante de carga de um elétron (1,602 e-19 C);

$I_{SC,ref}$ = corrente de saturação nominal do diodo;

G = radiação de corrente no local;

G_N = radiação nominal estabelecida (1000 W/m²)/

ΔT = Diferença entre a temperatura atual (T_c) e a de referência ($T_{c,ref}$);

μ = coeficiente de temperatura atual.

Adicionalmente, regula-se a geração via controlador MPPT (*Maximum Power Point Tracking*) e conversores *buck-boost*.

- **Sistema de Geração Eólico**

O modelo da turbina eólica foi obtido de Mora Montañes (2020), sendo (6), (7), (8):

$$P_m = \frac{C_p(\lambda, \beta) * \rho * A * v^3}{2} \quad (6)$$

$$C_p(\lambda, \beta) = 0.00044\lambda^3 - 0.012\lambda^3 + 0.097\lambda^2 - 0.2\lambda + 0.11, \quad (7)$$

para $\beta = 0$

$$\lambda = \frac{\omega R}{v} \quad (8)$$

Onde:

P_m = potência mecânica máxima obtida;

C_p = coeficiente de desempenho da turbina;

β = ângulo de inclinação da pá;

λ = relação de velocidade da ponta da asa do rotor com a velocidade do vento;

A = área da superfície da pá;

v = velocidade do vento;

ρ = densidade do ar;

ω = velocidade angular da turbina;

R = raio do rotor.

A fim de ajustar o ciclo útil do conversor, implementa-se um controlador antes do regulador de tensão DC-DC.

- **Sistema de Armazenamento**

Caceres (2020) utiliza o sistema de baterias proposto por Mora Montañes, sendo as baterias de chumbo-ácido. Tais elementos são definidos pelas equações a seguir (9), (10), (11), (12), (13):

$$V_B = E_m \pm I_B R_B \quad (9)$$

$$E_m = E_{m0} - K_e(273 + T_e)(1 - SOC) \quad (10)$$

$$SOC(t) = SOC_0 + \frac{\eta_c Q(t)}{C} \quad (11)$$

$$Q(t) = I_B t \quad (12)$$

$$\eta_c = 1 - e^{\left(\frac{20,73}{I_B + 0,55} (SOC - 1) \right)} \quad (13)$$

Onde:

V_B = tensão da bateria;

E_m = tensão de circuito aberto;

I_B = corrente atual da bateria;

R_B = resistência interna da bateria definida pelo fabricante;

E_{m0} = tensão do circuito dado pela carga máxima da bateria;

K_e = constante fornecida pelo fabricante;

T_e = temperatura do eletrólito;

SOC = estado da carga da bateria que varia de 0 a 1;

SOC_0 = estado inicial de carga para $t = 0$;

Q = carga entregue ou liberada;

C = capacidade da bateria;

η_c = eficiência da bateria;

I_{10} = corrente com uma capacidade de descarga completa em 10 horas;

C_{10} = valor obtido através da curva característica da bateria.

No caso das baterias, é importante observar que elas possuem comportamentos distintos dependendo do seu estado atual e estado futuro, assim, para o **carregamento** a fórmula obtida é a seguinte (14):

$$V_B = [2 - 0.16 SOC] + \frac{I}{C_{10}} \left(\frac{6}{1 + I_B^{0.86}} + \frac{0.48}{(1 + SOC)^{1.2}} + 0.036 \right) * (1 - 0.025 \Delta T_B) \quad (14)$$

Já para o **descarregamento** a bateria funciona seguindo a seguinte fórmula (15):

$$V_B = [2.085 - 0.12(1 - SOC)] + \frac{I}{C_{10}} \left(\frac{4}{1 + I_B^{1.3}} + \frac{0.27}{SOC^{1.5}} + 0.02 \right) (1 - 0.007 \Delta T_B) \quad (15)$$

A Figura 42 apresenta as curvas típicas de carregamento e descarregamento de baterias, para exemplificação.

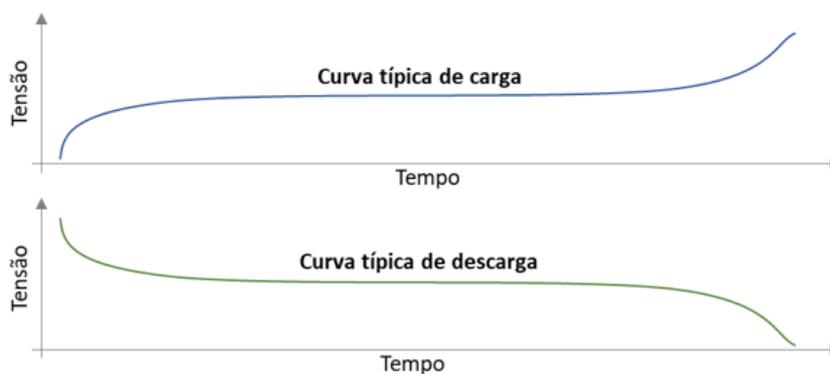


Figura 42 - Curvas típicas de carregamento e descarregamento de baterias, para exemplos apenas

- **Sistema de Distribuição de Energia**

O sistema completo, apresentado por Mora Montañes (2020) apresenta a relação das potências da geração renovável (P_{RS}), bateria (P_{BS}), energia da rede (P_{CS}) e carga (P_L), com o objetivo de apresentar a distribuição de potência do sistema. A equação característica (P_{MG}) é dada por (16):

$$P_{MG}(t) = P_{RS}(t) + P_{CS}(t) \pm P_{BS}(t) - P_L(t) \quad (16)$$

Mora Montañes (2020) apresenta um diagrama de tomada de decisão com referência da potência gerada pelo sistema. Tal fluxograma pode ser observado na XXX.

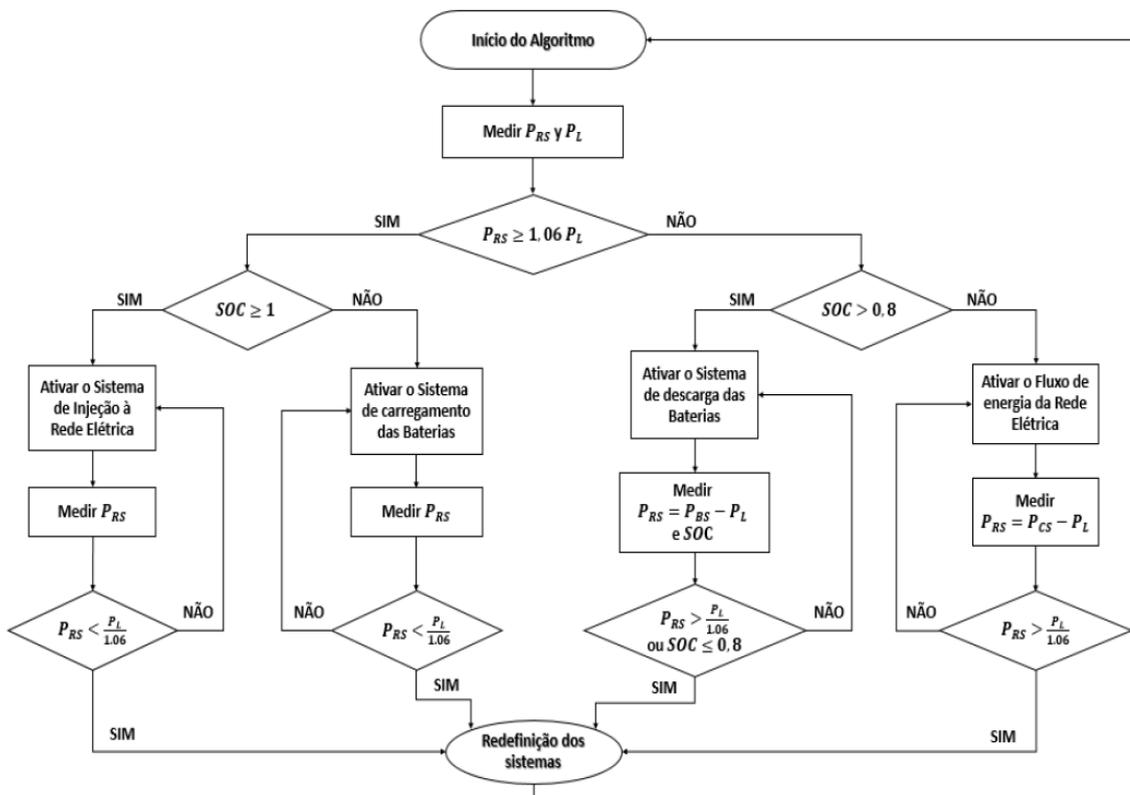


Figura 43 - Diagrama de Decisão para o sistema de Potência (MORA MONTAÑES, 2020)

Finalizada a modelagem dos agentes, deve-se iniciar a **obtenção e tratamento da base de dados** que será utilizada para a implementação do sistema.

Para as informações relacionadas à capacidade de geração de energia, sendo a irradiação solar e velocidade do vento para a região escolhida, foi obtida com agências de fomento e fontes governamentais. Para a carga da região, Carceres (2020) realizou uma aproximação via Monte Carlo, conseguindo dessa forma gerar um banco de dados aproximado para auxiliar no estudo.

As bases foram divididas entre *online* e *offline*, a primeira, por conter menos informações e serem mais dificilmente coletadas, foi utilizada para avaliação estatística e comparações, já a segunda, por possuir grande quantidade de dados, foi usada para o treinamento do sistema que seria implementado. Após uma avaliação de estatística descritiva, foi escolhida a base de dados a NSRDB (*National Solar Radiation Data Base*) para o estudo desenvolvido.

Então, pode-se definir os indicadores de desempenho que posteriormente serão utilizados para a otimização do sistema. Caceres (2020) utilizou dois indicadores de desempenho, sendo:

- **Indicador Financeiro:** Poupança no Custo de Energia

Este indicador apresenta a diferença do custo da energia comprada, preço de comprar x energia comprada, versus o custo da energia vendida, sendo o preço da energia vendida x energia vendida.

- **Indicador Ambiental:** Poupança de CO₂

A medida é realizada em toneladas equivalentes de carbono, realizando a medição do traço de carbono passado e atual. Mora Montañes (2020) apresentou a formulação para o sistema implementado em Carceres (2020), sendo (17):

$$C_F = (Em_{dir} + Em_{met})N_{tot}Pot_{out} + (Em_{i\&f} + Em_{met} + Em_{cv})N_{tot}Pot_{tot} \quad (17)$$

Sendo:

Em_{dir} = emissões diretas de carbono na natureza;

$Em_{i\&f}$ = emissões de carbono relacionadas à infraestrutura e à cadeia de suprimentos do sistema;

Em_{met} = outros tipos de poluentes emitidos na natureza;

Em_{cv} = emissões de carbono relacionadas com o ciclo de vida do sistema;

N_{tot} = número de componentes que geram a contaminação;

Pot_{out} = potência instantânea no sistema;

Pot_{tot} = potência instalada no sistema.

Passa-se, então, para a quarta etapa do processo, sendo o **desenvolvimento das ferramentas de simulação**.

Para isso, inicialmente deve-se dimensionar o sistema. Mora Montañes (2020) indica a metodologia do LCOE. A metodologia consiste na definição do custo para a produção de 1 kWh utilizando as fontes em análise. No eixo horizontal indica-se a porcentagem de uma das fontes, e o custo da outra fonte será o tanto suplementar para atingir os 1 kWh necessários. No

caso do estudo de Caceres (2020), foi definido como ponto ótimo o percentual de 45,46% para a energia eólica e 54,53% para a fotovoltaica, conforme a Figura 44.

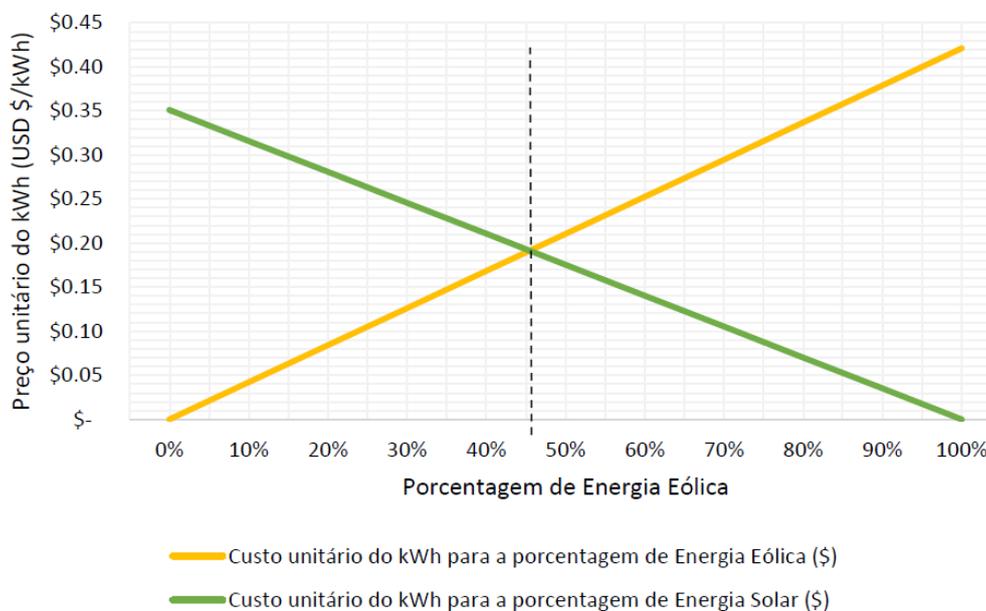
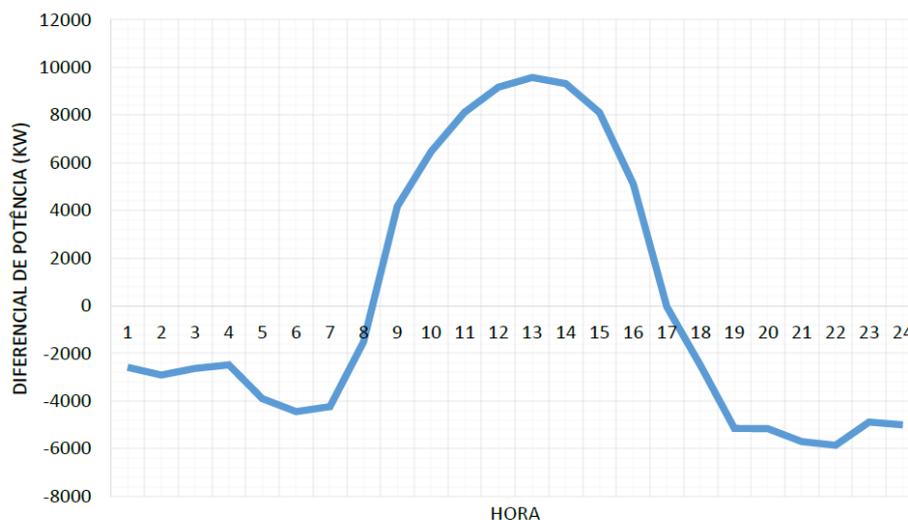


Figura 44 - Custo da implementação de um sistema Híbrido de Geração (CACERES, 2020)

Caceres (2020) indica que a melhor distribuição, dada as restrições de energia requerida, fator de capacidade e dimensionamento das usinas, seria de 6,3 MW para a usina eólica, e 510 Watts pico para o sistema fotovoltaico, correspondente à 169 painéis em série e 251 em paralelo.

Para o dimensionamento das baterias, utilizou-se um cenário de baixa geração de energia, devido a fatores ambientais, e alta demanda, sendo assim um caso extremo de necessidade de um banco de energia disponível. Caceres (2020) realizou a análise para o sistema implementado e indicou a necessidade de 59 GW de energia, conforme apresentado na Figura 45. Fornecendo assim a necessidade de um banco de baterias de 5 baterias em paralelo e 5600 em série, sendo baterias de 2V e 3000 Ah.



Fonte: Elaborado pelo Autor.

Figura 45 - Diferença entre demanda vs geração de energia (CACERES, 2020)

Para a realização da simulação, foi utilizado como base os modelos implementados computacionalmente por Mora Montañes (2020) para a geração de energia eólica e fotovoltaica, porém adaptas via regressão linear por Caceres (2020) para o estudo específico. Obtendo-se as seguintes equações (18), (19):

$$P_f(GHI) = \begin{cases} 0, & GHI \leq 0 \\ 0,0772GHI^2 + 20247GHI + 28194, & GHI > 0 \end{cases} \quad (18)$$

Para o **sistema fotovoltaico**, em que:

P_f = Potência Gerada;

GHI = Irradiação Global Horizontal.

$$P_v(V_{110}) = \begin{cases} 0, & V_{110} \leq 2 \\ -0,0024V_{110}^6 - 0,0353V_{110}^5 + 1,2973V_{110}^4 - 8,1474V_{110}^3 + 35,637V_{110}^2 - 46,142V_{110} + 3,881 & 2 < V_{110} < 12 \\ 2100, & V_{110} \geq 12 \end{cases} \quad (19)$$

Para o **sistema eólico**, em que:

P_v = Potência Gerada;

V_{110} = Velocidade do vento a 110m.

Essas aproximações foram realizadas com o objetivo de melhorar o tempo de execução computacional da simulação. O sistema de armazenamento foi implementado computacionalmente com a utilização das equações de carregamento e descarregamento.

Com isso, é obtido o sistema completo simulado, apresentando como única saída o próximo estado da bateria, podendo ser **aguardar, carregar, descarregar**.

A implementação realizada por Caceres (2020) baseia-se na programação orientada a objetos, com uma máquina de estados de apenas 2 estados, sendo **Step**, em que o sistema avança uma hora na simulação, e **Reset**, retornando ao estado inicial pré-definido.

Para o quinto passo, em que se deve definir as **limitações da simulação**, Caceres (2020) indica que o simulador proposto não consegue avaliar outros fatores de otimização do sistema, tal como técnico, socioeconômico e ambiental.

A etapa de **implementação de inteligência artificial** nesse sistema pode auxiliar na otimização de todas as etapas descritas, buscando a ponderação entre fatores técnicos, socioeconômicos e ambientais (CACERES, 2020). Para o estudo discutido, escolheu-se o aprendizado por reforço, escolhendo os KPIs que permitam uma avaliação correta e gerenciamento de energia em uma população definida.

Caceres (2020) indica que o sistema por aprendizado deve seguir a máquina de estados da Figura 46.

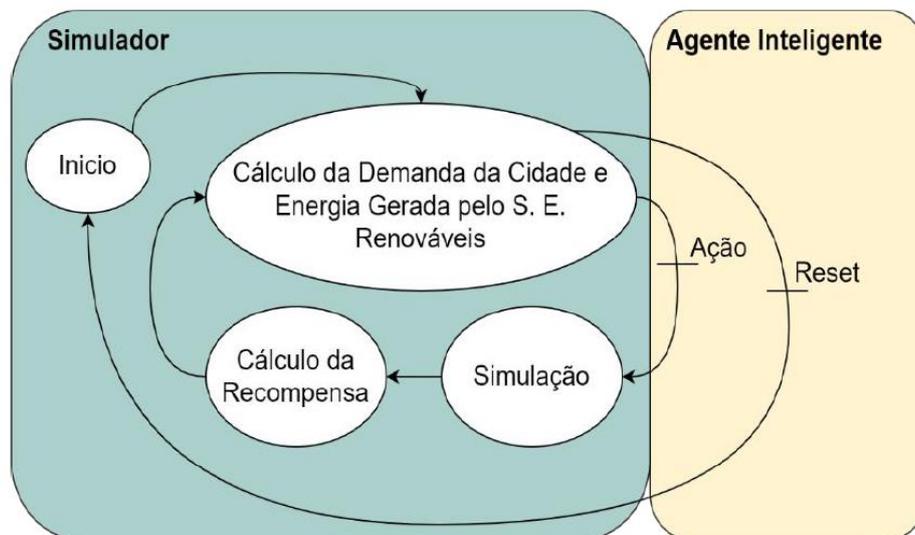


Figura 46 - Máquina de Estados com a Inteligência Artificial (CACERES, 2020)

Em que a recompensa, sendo reforço ou punição, é calculada com base em não permitir que o sistema ultrapasse seus limites de carregamento e descarregamento. Além disso, o sistema deve conhecer o estado atual do sistema, seguindo o processo de decisão de *Markov*.

Tal estado é definido por:

- S_t = Horário atualizado do sistema;
- S_{SOC} = SOC atual do sistema de armazenamento;
- S_D = Demanda da cidade;
- S_R = Energia gerada pelo sistema de energias renováveis

Fornecendo a seguinte equação (20):

$$S(t) = \{S_t(t), K_{SOC}S_{SOC}(t), S_D(t), S_R(t)\} \quad (20)$$

Sendo que K_{SOC} é uma constante apenas para mandar o estado da bateria no mesmo nível de grandeza dos demais fatores.

Quatro soluções foram implementadas por Caceres (2020), uma breve apresentação é apresentada a seguir:

- **Solução 1: Máquina de Estados**

Esta solução é baseada em uma tomada de decisão com base no estado atual, observando o que pode ser realizado com o sistema de armazenamento, conforme Figura 47.

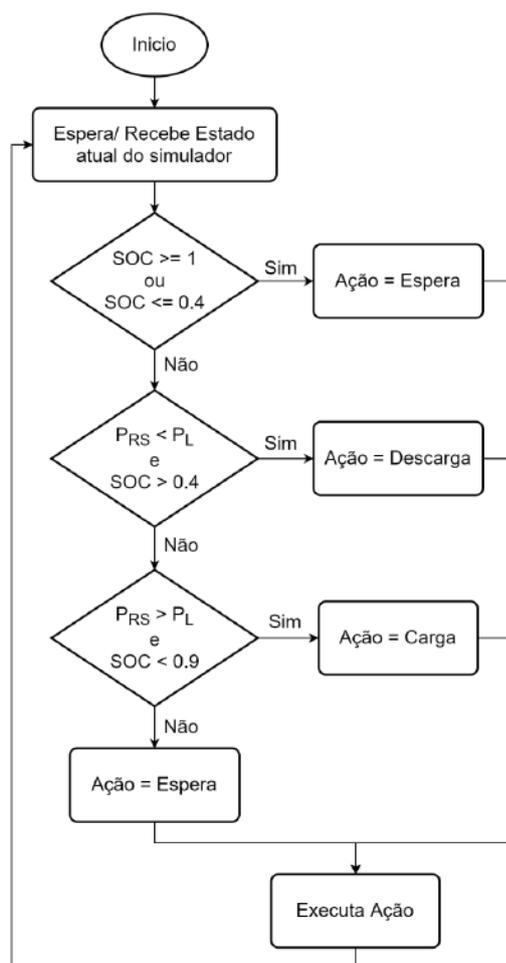


Figura 47 - Diagrama de Máquina de Estados (CACERES, 2020)

Em 48h de simulação a função de custo obteve um valor de ~ -100 , alta penalidade.

- **Solução 2: *Neural Fitted Q Iteration* (NFQI)**

Esta técnica gera uma rede neural que atua como um agente inteligente, do tipo feedforward, apresentando 4 neurônios de entrada, 3 camadas intermediárias de 30 neurônios totalmente conectadas e 3 neurônios de saída, apresentando cada um o estado futuro da máquina de estados, fornecendo o que possui maior valor. O formato implementado é apresentado na Figura 48.

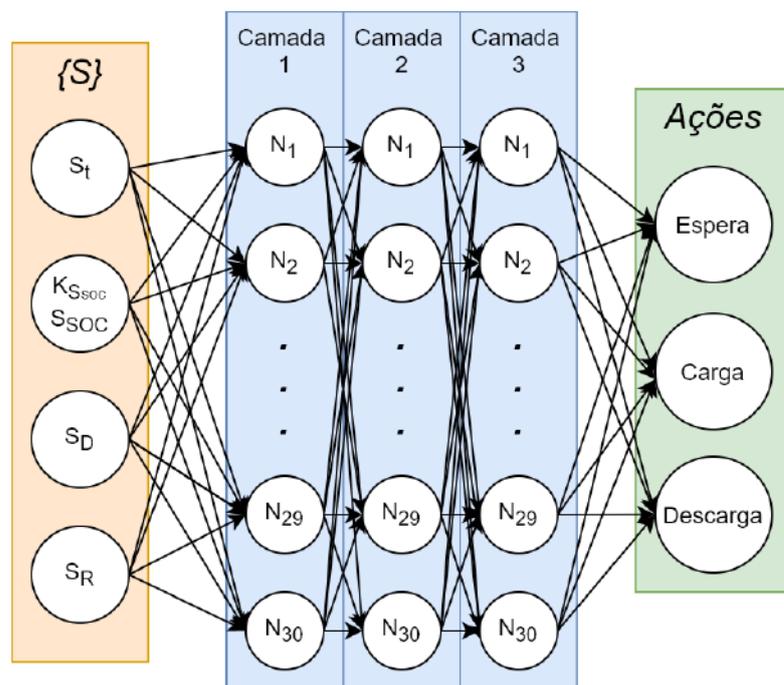


Figura 48 - Arquitetura da Rede Neural da Solução 2 (CACERES, 2020)

Nessa solução a função custo apresentou um valor de $\sim -9,6$, uma redução significativa da solução 1.

- **Solução 3: *Neural Fitted Q Iteration* com previsão de 1h (NFQI-1h)**

Nessa solução é implementado o mesmo sistema da solução 2, porém com a inclusão de mais dois elementos na equação do espaço de estados, uma para a previsão de 1h da demanda de energia, e outra para a previsão de 1h de geração de energia renovável. Aumentando o número de informações do sistema e permitindo projetar um agente otimizado.

Para realizar as previsões, pode-se utilizar diversas técnicas, desde as clássicas, até as com a aplicação de redes neurais. Caceres (2020) apresenta o estudo para selecionar o melhor modelo dentre os apresentados na Figura 49.

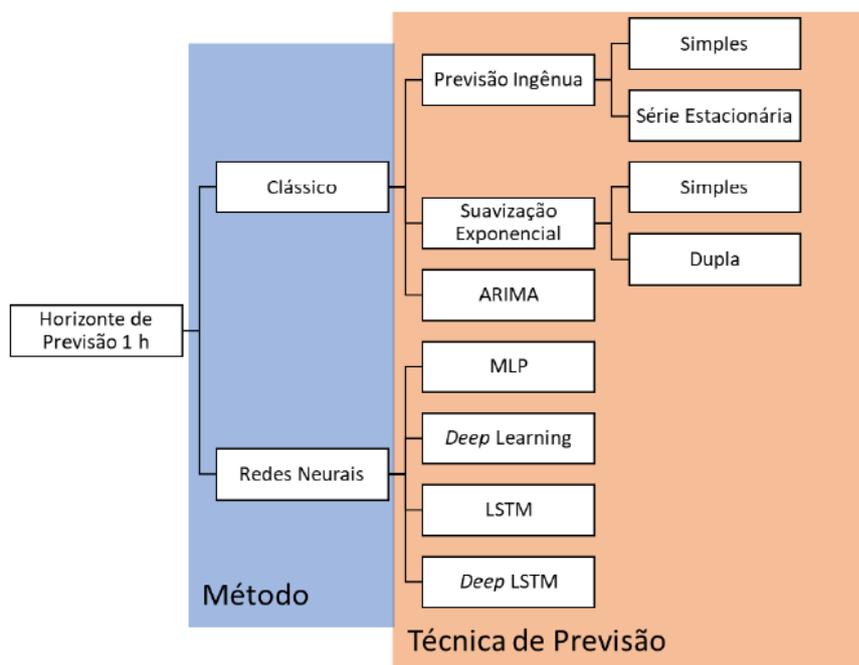


Figura 49 - Métodos de Previsão (CACERES, 2020)

Os seguintes modelos de previsão foram selecionados:

- **Energia Fotovoltaica:** LSTM (multivariável e dados não estacionários), $R=0,96$
- **Energia Eólica:** LSTM Bidirecional (dados não estacionários), $R=0,995$
- **Demanda de Energia:** LSTM Bidirecional (dados não estacionários), $R=0,782$

A função de recompensa para essa solução, dentro de 48h, foi de $\sim +18$.

- **Solução 4: *Neural Fitted Q Iteration* com previsão de 24h (NFQI-24h)**

Esta solução busca melhorar o estudo apresentado na solução 3. A previsão de 24h deve ser implementada hora a hora, dessa forma, cada hora será um estado do sistema, provendo 52 neurônios de entrada, que representam o espaço de estados.

Nessa solução, os modelos de previsão selecionados para o estudo de 1h são exatamente os apresentados para a solução 3, já para o estudo das 24 horas adicionais foram os seguintes:

- **Energia Fotovoltaica:** LSTM Bidirecional (multivariável e dados não estacionários), $R=0,93$;
- **Energia Eólica:** LSTM Bidirecional (Dados não estacionários), $R=0,75$;

- **Demanda de Energia:** LSTM Bidirecional (Dados não estacionários), $R=0,788$.

A função recompensa, para o estudo em 48h, foi de $\sim +66$.

Com isto, pode-se iniciar a **análise e seleção das soluções**. Observando simplesmente a função recompensa das soluções aplicadas, a melhor seria a 4, e a pior a 1. Porém, Caceres (2020) propôs um estudo aprofundado para definir a melhor solução, com isso foram analisados períodos de 15 dias, 480 vezes, somando 20 anos.

Com isso, os resultados são apresentados em histogramas da somatória das funções recompensa de cada um, para cada teste. A Figura 50 apresenta tais histogramas.

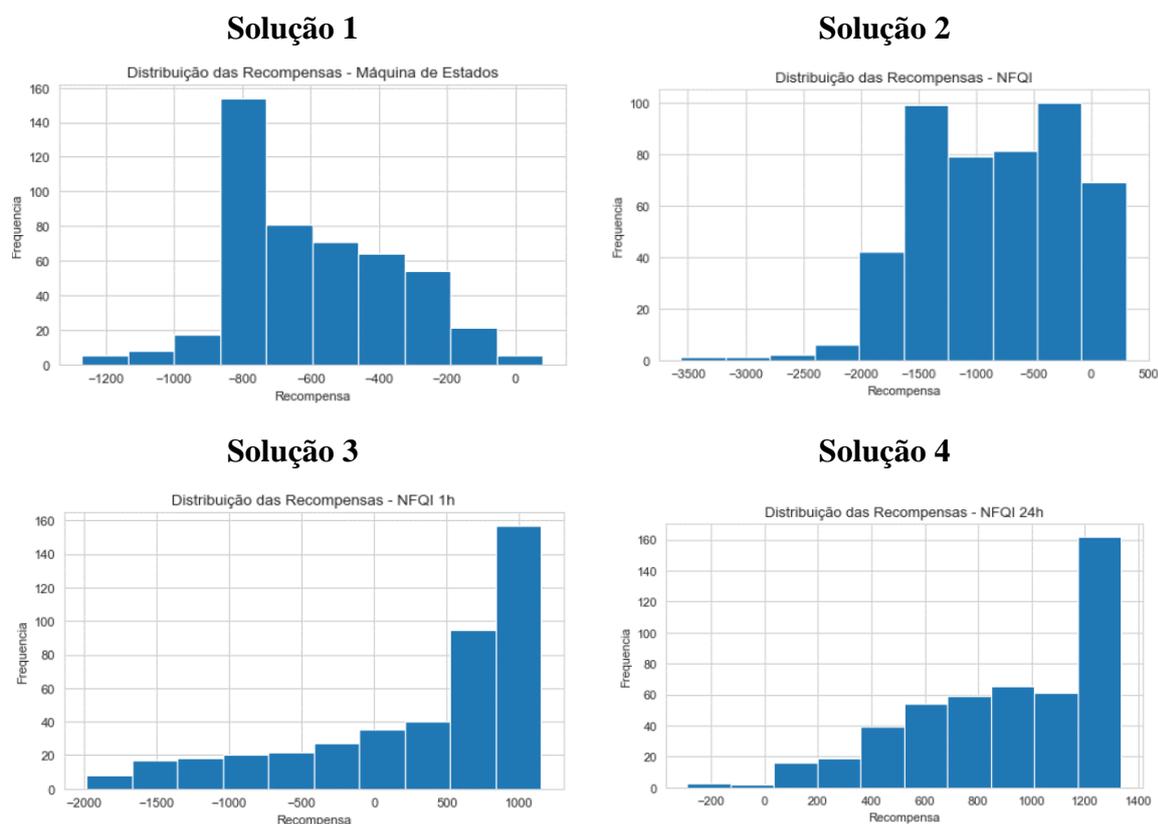


Figura 50 - Histogramas das 4 soluções propostas - Somatória da Função Recompensa (CACERES, 2020)

Para uma análise mais detalhada e comparativa, pode-se observar os gráficos consolidados em uma única imagem, como função de probabilidade, como apresentado na Figura 51.

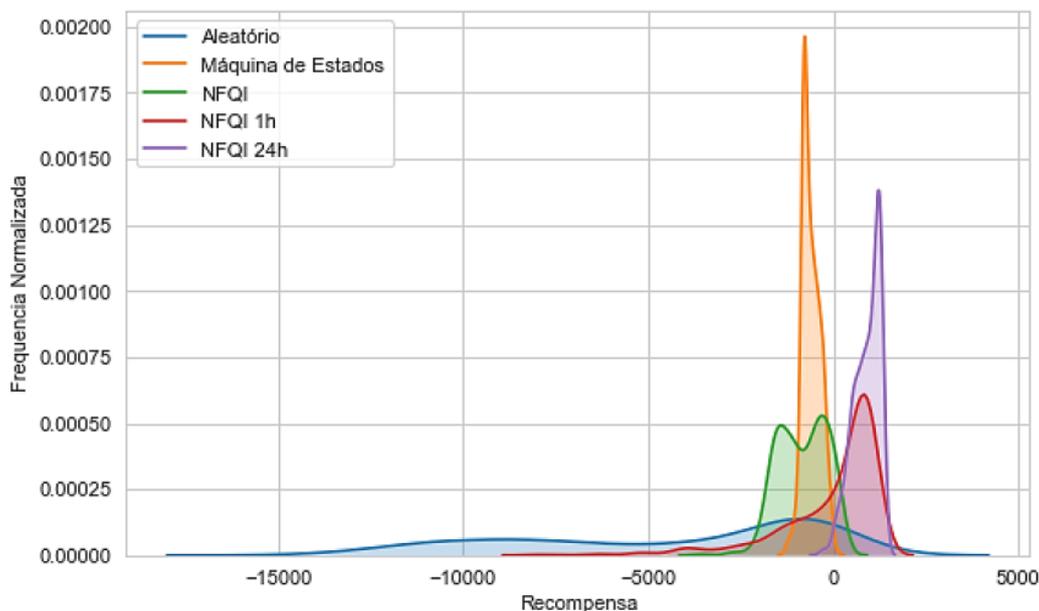


Figura 51 - Distribuição das probabilidades da função de recompensa (CACERES, 2020)

O agente aleatório foi adicionado por Caceres (2020) com o objetivo apenas comparativo, assim pode-se observar que todos os cenários apresentam decisões inteligentes. Porém maiores recompensas são obtidas com a implementação da solução 4, além dela apresentar um desvio padrão menor que as demais soluções.

Por fim, realizando a **comparação com o modelo tradicional**, Caceres (2020) demonstra que a solução 4: NQFI-24h apresenta desempenho 2,5 vezes melhor que o cenário tradicional, de máquina de estados, observando, ainda, que os piores cenários da solução 4 correspondem às melhores da solução 1.

3.3 MODELAGEM PROPOSTA

Definindo-se o trabalho de referência pode-se focar nas estratégias que serão implementadas nesse trabalho. Buscando otimizar os resultados, transformando em algo prático para ser implementado no dia a dia, conforme inclusive indicou Caceres (2020) quando cita os trabalhos futuros.

Com isso, apresenta-se as estratégias que serão abordados no contexto desse projeto e os possíveis cenários de implementação que serão avaliados.

3.3.1 ESTRATÉGIAS PROPOSTAS

O intuito desse trabalho é o desenvolvimento de uma ferramenta que facilite a implementação, análise e testes de diferentes cenários de acordo com as premissas pré-estabelecidas.

Para isso, a solução será baseada na implementação de energia eólica e fotovoltaica, devido à complementariedade delas, e a inclusão de um banco de baterias. Todo o sistema será integrado com a rede externa de energia, tanto para venda como compra de energia, quando necessário. Para permitir uma escolha do melhor momento de venda/compra de energia, inclui-se também um banco de baterias, funcionando como um buffer do sistema. A Figura 52 indica o exemplo da estratégia que será implementada.

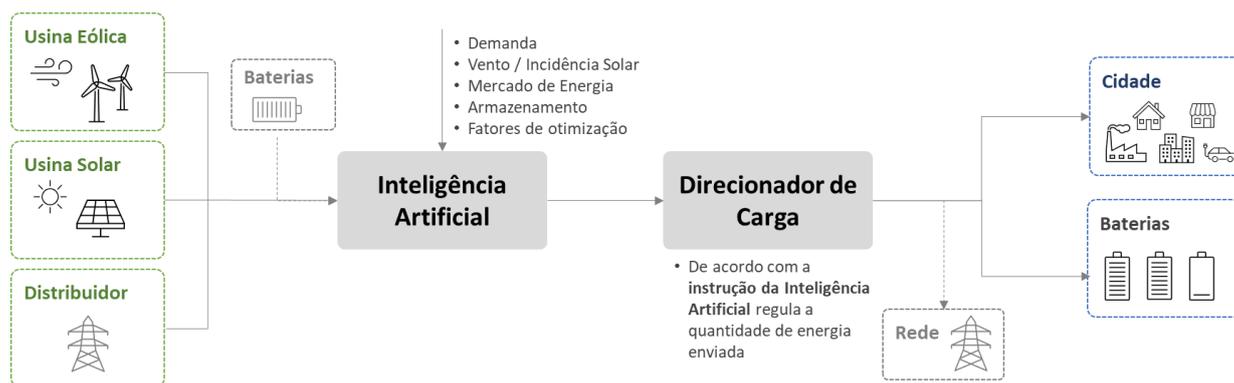


Figura 52 - Estrutura Proposta para o Projeto

Assim, para definir o sistema de cada cenário será necessário o desenvolvimento dos seguintes passos, baseados no definido em Caceres (2020):

- **Levantamento das Informações e Premissas Base**

Idealmente será testado para um tipo de Turbina e Pannel Fotovoltaico padrão, podendo, posteriormente, ser adicionado sensibilidades de outros tipos de componentes para avaliação;

Os dados da cidade são importantes para o dimensionamento do sistema de geração e para o treinamento da Inteligência Artificial, sendo importante os dados de (i) Consumo; (ii) Irradiação Solar; (iii) Velocidade do Vento; (iv) Mercado de Energia na Região; e (iv) outros interessantes para a avaliação.

- **Dimensionamento do sistema de Geração**

Com os dados anteriormente levantados, deve-se realizar uma análise para otimizar o custo do sistema de Geração, similar ao apresentado por Caceres (2020), com o uso do LCOE de cada um dos agentes. Importante destacar que para cada cenário avaliado, uma nova estrutura de Geração e Armazenamento deve ser calculado para se certificar que ele poderá atender à cidade ou região selecionada.

- **Definição e Seleção dos fatores de Otimização**

Definido o sistema, passa-se para a terceira etapa em que se avalia quais fatores podem ser incluídos na otimização do sistema, como exemplo de Caceres (2020) em que foi utilizado a pegada de carbono junto com a redução do custo de energia.

- **Implementação da inteligência Artificial**

A princípio serão implementados cenários mais simples de inteligência artificial, utilizando as técnicas de aprendizagem de máquina por reforço, para em próximos passos otimizar o sistema para melhores inteligências artificiais.

- **Simulação**

Realizar a simulação com os fatores definidos anteriormente, por um período de, a princípio, 48 horas, podendo ser avaliado fatores sazonais para melhorar a análise dos cenários propostos.

○ **Avaliação dos Resultados**

Com as simulações realizadas, os resultados são analisados para serem comparados em uma mesma base analítica e, assim, entendido pontos de melhoria e potenciais de implementação real para cada um. Nessa etapa busca-se também uma análise da viabilidade financeira da implementação do projeto.

○ **Implementação de Melhorias e Otimizações**

Com o objetivo de melhoria contínua, avalia-se dentro dos resultados obtidos o que pode ser incluído ou retirado para melhorar os resultados obtidos, desde as conclusões até os tempos de avaliação da simulação e fatores utilizados.

Com isso, a estratégia é baseada na implementação de um sistema híbrido de energia, com foco em otimização de indicadores selecionados. A Figura 53 resume a estratégia de implementação descrita anteriormente.

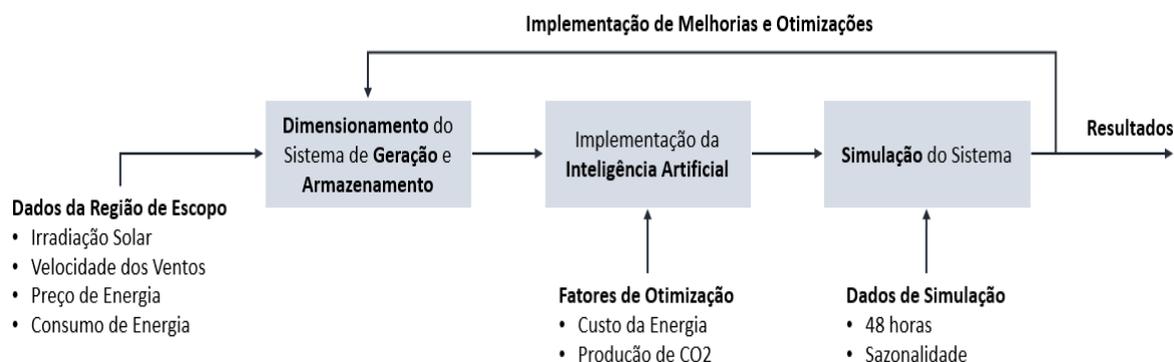


Figura 53 - Fluxo da Estratégia de Implementação do Sistema

3.3.2 CENÁRIOS DE IMPLEMENTAÇÃO

A implementação do modelo proposto será realizada, a princípio, em três cidades, de tamanhos e características distintas, a fim de avaliar a implementação de tal tecnologia em diferentes cenários e observar as diferenças, problemas e vantagens de cada implementação.

Os requisitos para a cidade fazer parte de um dos cenários de avaliação são os seguintes, que serão detalhados a seguir:

- Acesso ao SIN (Sistema Interligado Nacional) de energia elétrica
- Tamanho da Cidade
- Recursos Financeiros
- Potencial de Geração pela Velocidade de Vento e Irradiação Solar

O **Acesso ao SIN** é importante para garantir que o sistema utilize a rede externa para complementar sua geração e dar uma possibilidade maior para a inteligência artificial trabalhar com o mercado aberto de energia. Segundo a ONS (2022), os estados brasileiros que são totalmente atendidos pelo SIN são:

- Rondônia
- Acre
- Amazonas
- Roraima
- Amapá
- Pará
- Mato Grosso (atendido parcialmente)
- Ilha de Fernando de Noronha (Pernambuco)

Assim, eliminando estes estados, com exceção da Ilha de Fernando de Noronha que será excluída apenas a Ilha, o Brasil apresenta 5117 municípios, divididos em 5 grandes regiões, com a seguinte divisão apresentada na Figura 54.

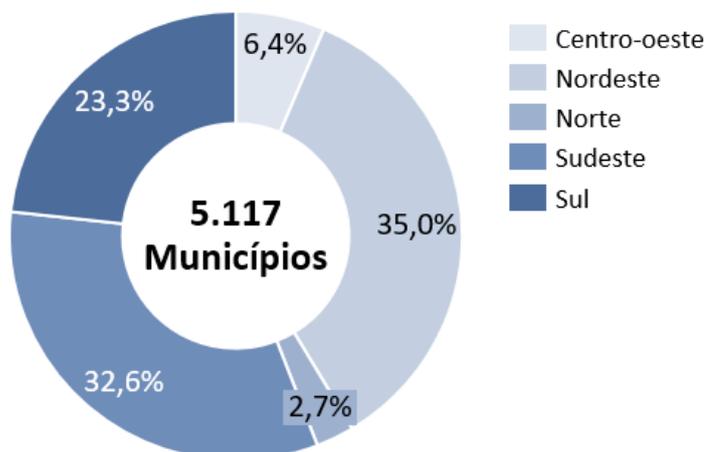


Figura 54 - Divisão dos Municípios no Escopo de estudo

Dentro desse escopo definido, pode-se observar o segundo ponto que é o **tamanho das cidades**, o grande número de municípios no Brasil reflete que as cidades são divididas com pequenas populações, ainda mais considerando a alta densidade demográfica de grandes centros, como São Paulo, Rio de Janeiro e Belo Horizonte.

Para avaliar o tamanho populacional das cidades do escopo pode-se utilizar a classificação proposta pelo IBGE (Instituto Brasileiro de Geografia e Estatística), órgão do governo responsável pelo censo demográfico nacional. Nessa divisão têm-se as divisões e quantidade de cidades conforme apresentado na Figura 55.

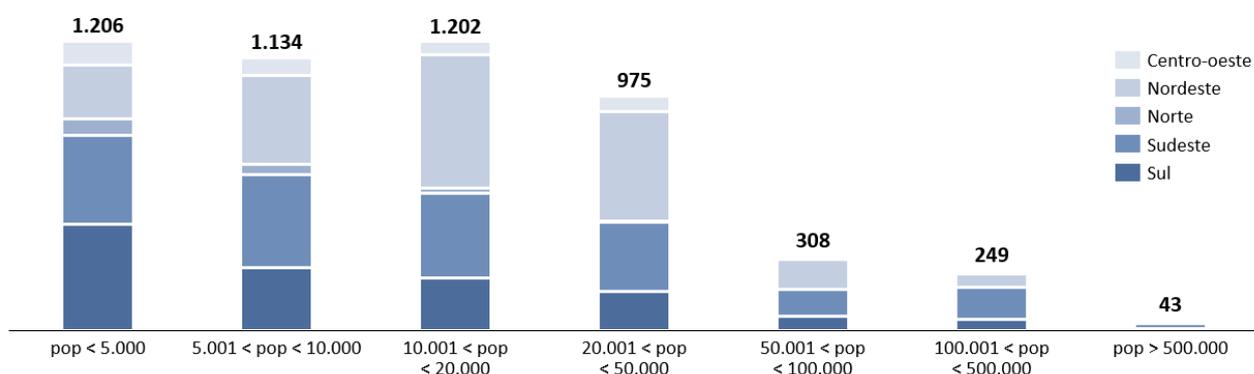


Figura 55 - Distribuição das cidades conforme população

Mesmo apresentando cerca de 88% das cidades com população abaixo de 50.000 habitantes, a quantidade de população no Brasil está concentrada nas grandes cidades, conforme apresenta a Figura 56, em que é possível observar que 58% da população está concentrada nas cidades com população acima de 100.000 habitantes.

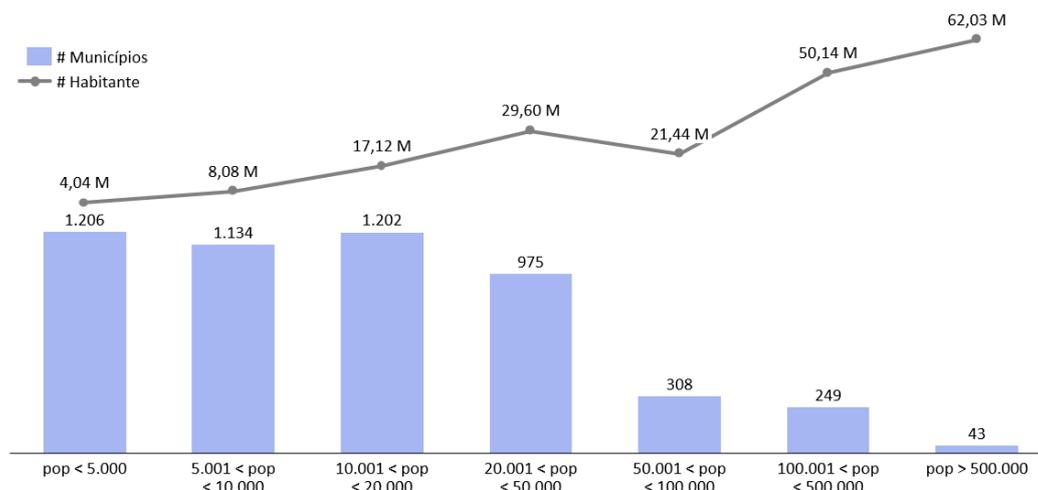


Figura 56 - Quantidade de Municípios e População Total nas divisões sugeridas

Cidades muito populosas tendem a apresentar forte estrutura elétrica, mas maior dificuldade na implementação de novos sistemas de teste, e cidades muito pequenas podem apresentar problemas de investimento. Assim, o ideal seria escolher cidades entre 5.000 e 100.000 habitantes.

Seguindo para a avaliação dos **Recursos Financeiros** das cidades, fator importante para avaliar a capacidade de investimento público na geração de energia renovável de forma otimizada, pode-se avaliar o PIB per capita das cidades em questão. Outro indicador interessante é o valor adicionado pela indústria em cada município, pelo PIB total do município, esses valores auxiliam em dimensionar o interesse do município em receber tal projeto, já que indústrias tendem a ser eletrointensivas.

Tais informações podem ser organizados em um gráfico de dispersão, conforme apresentado na Figura 57. Com isso, as cidades com melhor participação industrial e PIB per capita tendem a possuir maior interesse no desenvolvimento de projetos elétricos renováveis e otimizados.

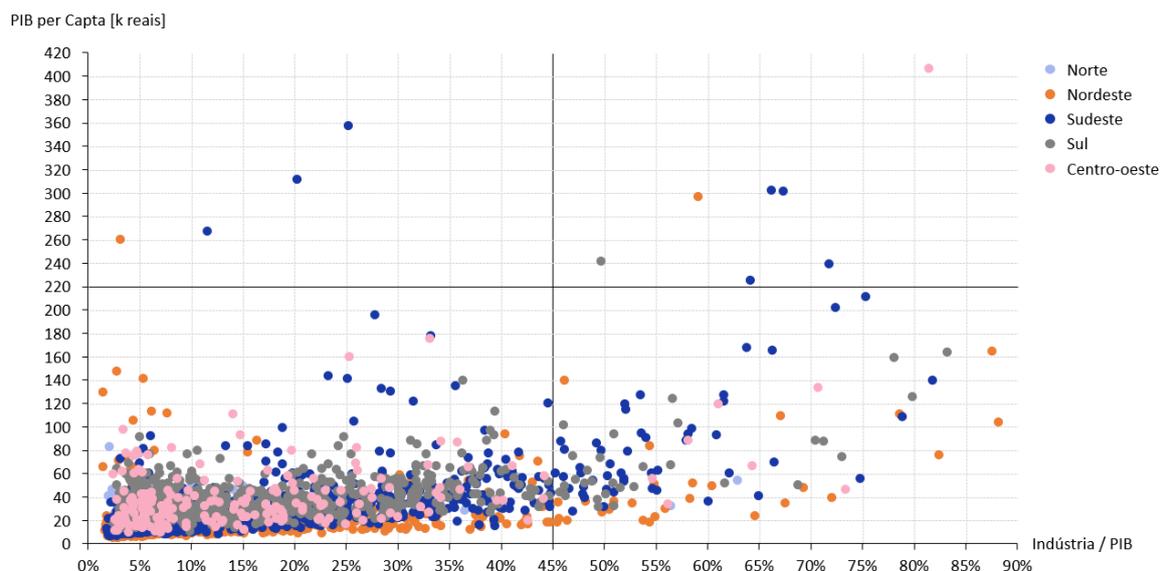


Figura 57 - Gráfico de dispersão dos municípios com base no PIB per capita e Valor adicionado da Indústria no total do PIB

Por fim, é importante observar o **Potencial de Geração Elétrica Renovável**, com base na irradiação solar e velocidade do vento para os cenários indicados.

Esta etapa deve ser adaptada para o tipo de energia que será estudado, no caso desse projeto, a irradiação direta horizontal no Brasil e a velocidade do vento no Brasil na altura de 100 metros são os fatores mais indicados para análise.

Pereira et al. (2017) apresenta o potencial de energia solar no Brasil, com base nas medições realizadas de irradiação global horizontal, conforme apresentado na Figura 58. O CEPEL (2013) apresenta o estudo de velocidade do vento no Brasil há uma altura de 100 metros, que é o padrão da maioria das turbinas de alta geração eólica, com isso é possível observar o potencial de geração de energia eólica no país, conforme apresentado na Figura 59.

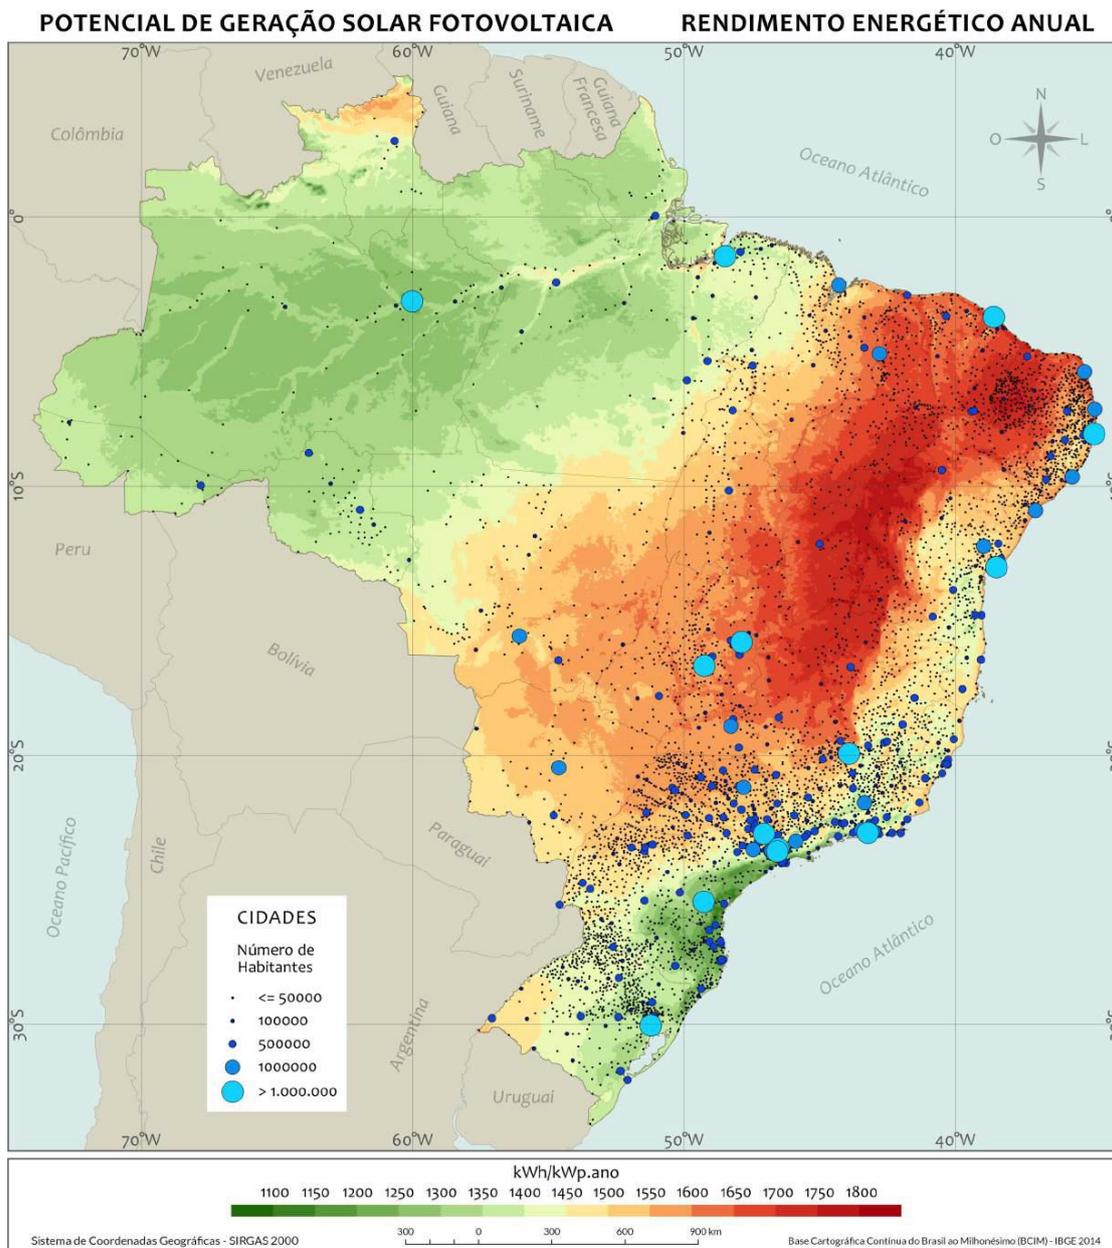


Figura 58 - Potencial de Geração de energia solar - Brasil (PEREIRA et al., 2017)

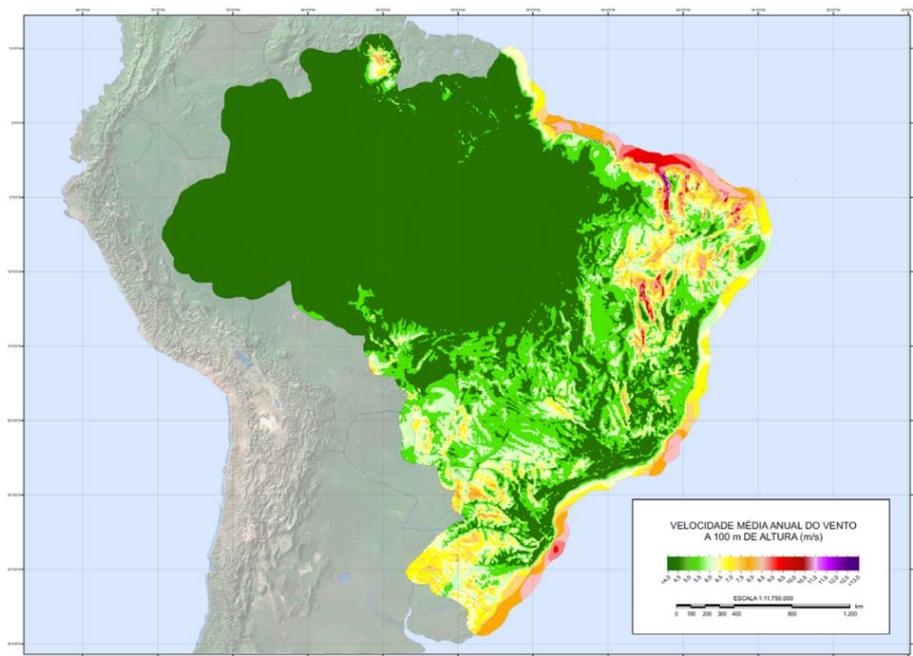


Figura 59 - Velocidade do Vento a 100 metros de altura (CEPEL, 2013)

Assim, observando os dois mapas em conjunto é possível observar que a melhores regiões para a implementação de um projeto híbrido solar e eólico é na região **Nordeste** ou ainda, com menor potencial, na região costeira do **Sudeste**.

3.4 COMENTÁRIOS E CONCLUSÕES DO CAPÍTULO

Após a definição do escopo do projeto, tratando de um sistema híbrido de energia fotovoltaica e eólica, pela complementariedade das duas fontes, definiu-se o formato de inteligência artificial e fatores de otimização aplicados ao projeto, com base no trabalho de referência de Cáceres (2020). Por fim, com base nas características de possuir rede externa de eletricidade, possuir recursos financeiros e capacidade de geração, devem ser selecionadas as 3 cidades que farão parte das análises como cenários distintos de tamanhos de população.

Feito isso, como próxima etapa, deve-se levantar as informações e dados desses cenários para então iniciar a implementação e estudo do projeto proposto, conseguindo avaliar vantagens e desvantagens de cada um.

4 UTILIZAÇÃO DE TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL PARA A GERAÇÃO HÍBRIDA DE ENERGIA

Neste capítulo, o objetivo é utilizar todas as técnicas apresentadas nos capítulos anteriores para implementar a inteligência artificial no modelo de geração híbrida de energia e, com isso, otimizar esse problema com a buscando melhorar a eficiência do uso de recursos naturais para a geração de energia que, por sua vez, está cada vez mais sendo demandada e tornando-se um fator importante nas finanças empresariais e governamentais.

Com o objetivo de atingir tais resultados, o capítulo é dividido da seguinte forma:

- **Seleção de Cenários**

Com base nas técnicas e fatores relevantes apresentados no capítulo 3, busca-se selecionar cidades que atendem ao objetivo proposto e possam fornecer informações válidas para a análise das técnicas implementadas.

- **Avaliação de dados disponíveis através de históricos**

Levantamento de dados históricos para os cenários definidos. Tais dados auxiliam na definição da inteligência artificial e no aprendizado de máquina, tanto para treinamento como para simulação das soluções. Dentre os dados avaliados estão a demanda de energia de cada localidade, custo histórico de energia, irradiação solar e velocidade de vento para as localidades propostas. Essas informações podem ser aproximadas, de acordo com a disponibilidade de dados.

- **Estudo da implementação**

Por fim, será aplicada as técnicas nos cenários definidos, utilizando ferramentas apresentadas nos capítulos anteriores. Dessa forma, inicialmente será definido o dimensionamento necessário do sistema de geração de energia, tanto solar como eólica, para cada localidade, buscando sempre a otimização dos custos avaliados. Com isso, avalia-se a inclusão do sistema de baterias necessário para suportar e garantir o funcionamento intermitente do sistema proposto. E então, aplica-se o aprendizado de máquina em conjunto com a inteligência artificial e controle para cada localidade proposta, obtendo-se, assim, o modelo final de cada cenário estudado.

4.1 SELEÇÃO DE CENÁRIOS

Com base nos parâmetros apontados no capítulo 3, pode-se observar que a região do Nordeste brasileiro apresenta uma característica interessante para a geração de energia renovável. Tanto a irradiação solar, como a velocidade dos ventos são altas em comparação com as demais regiões do país.

Porém é importante obter diferentes regiões geográficas para conseguir captar no estudo as particularidades de cada uma, tanto de recursos naturais para a geração de energia limpa, como também para o sub-mercado de energia correspondente, que possuem diferentes curvas de preço, conforme apresentado nos capítulos anteriores.

Dessa forma, as regiões selecionadas para a seleção das cidades que irão fazer parte do estudo proposto foram o Nordeste – NE, Centro-Oeste – CO e Norte – N, conforme apresentado na Figura 60.

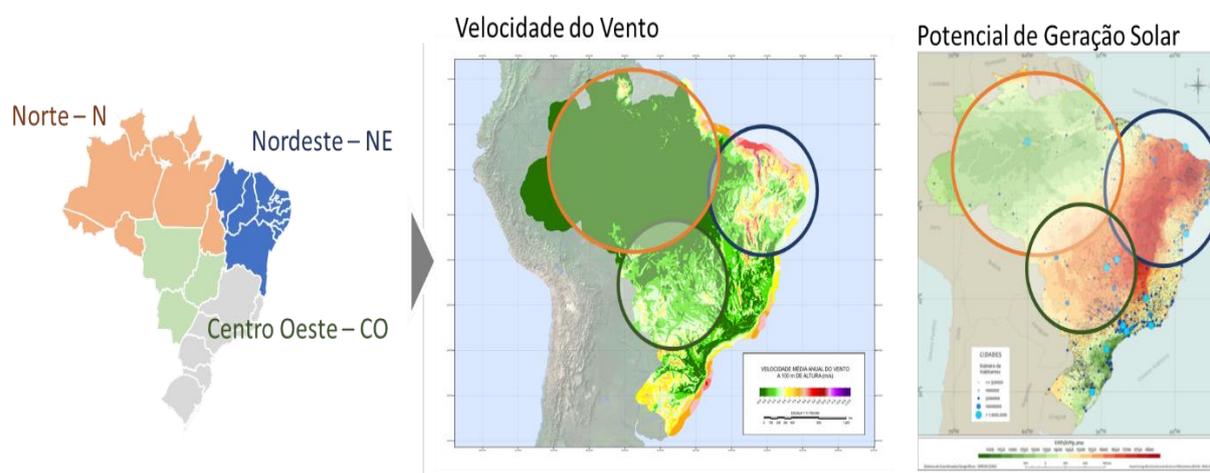


Figura 60 - Região com Alto Potencial de Geração de Energia Renovável

Para a escolha, é importante observar o âmbito populacional, já que se busca uma avaliação dos impactos e benefícios em diferentes cenários. Então foram selecionadas três cidades com populações diferentes, sendo uma pequena, uma média, e uma grande.

Por fim, é importante que a cidade tenha um valor significativo de participação da indústria no PIB, preferencialmente acima de 30%, e um PIB per capita relevante, para garantir os investimentos necessários, acima de 50 mil reais por habitante.

Com o objetivo de possuir uma diversidade de sub-mercado e fatores naturais, foram selecionadas três cidades presentes nos estados de Alagoas – AL, Goiás – GO e Tocantins – TO, conforme apresentado na Figura 61.



Figura 61 - Cidades selecionadas para avaliação do projeto (Google Maps, 2023)

Com isso, as 3 cidades selecionadas para o estudo desse projeto, são as seguintes:

- **Marechal Deodoro – Alagoas (AL)**
 - População: 52.849
 - Valor atribuído da Indústria: 37%
 - PIB per capita: R\$ 54.137,00
 - Coordenadas: 9°45'37.0"S 35°52'22.4"W (-9.760266, -35.872896)

- **Ipameri – Goiás (GO)**
 - População: 27.365
 - Valor atribuído da Indústria: 33%
 - PIB per capita: R\$ 67.166,00
 - Coordenadas: 17°43'10.9"S 48°09'33.2"W (-17.719690, -48.159223)

- **Peixe – Tocantins (TO)**
 - População: 11.996
 - Valor atribuído da Indústria: 42%
 - PIB per capita: R\$ 57.409,00
 - Coordenadas: 12°02'10.6"S 48°32'31.6"W (-12.036269, -48.542115)

4.2 AVALIAÇÃO DE DADOS DISPONÍVEIS ATRAVÉS DE HISTÓRICOS

Para a obtenção de um sistema eficiente com o uso de inteligência artificial, é essencial a coleta de dados relevantes para o aprendizado de máquina e dimensionamento do sistema proposto.

Dessa forma, será avaliado os três principais conjuntos de dados, sendo (i) consumo; (ii) precipitação; e (iii) índices de irradiação solar e velocidade dos ventos, para as três cidades selecionadas para o estudo.

4.2.1 CONSUMO DE ENERGIA

O consumo de energia é dado pela grandeza Potência x Tempo de utilização, denominada, normalmente, megawatt hora ou MWh.

No Brasil, o sistema de fornecimento de energia é todo conectado pelo SIN (*Sistema Integrado Nacional*) e dividido em quatro sub-mercado. Toda transação energética é passada pela CCEE (*Câmara de Comercialização de Energia Elétrica*). Maiores informações dessa dinâmica são fornecidas no Capítulo 2 desse trabalho.

O sistema não fornece informações de consumo por município, porém são apresentados valores por estado e por sub-mercado, podendo assim estimar o consumo do município conforme essas grandezas macro. A Figura 62 apresenta o consumo de energia para o estado de Alagoas, representando a cidade de Marechal Deodoro, com o objetivo de observar tanto a evolução histórica do consumo nesse estado, como também o consumo mensal nos últimos cinco anos.

Consumo de Energia – Alagoas (AL)

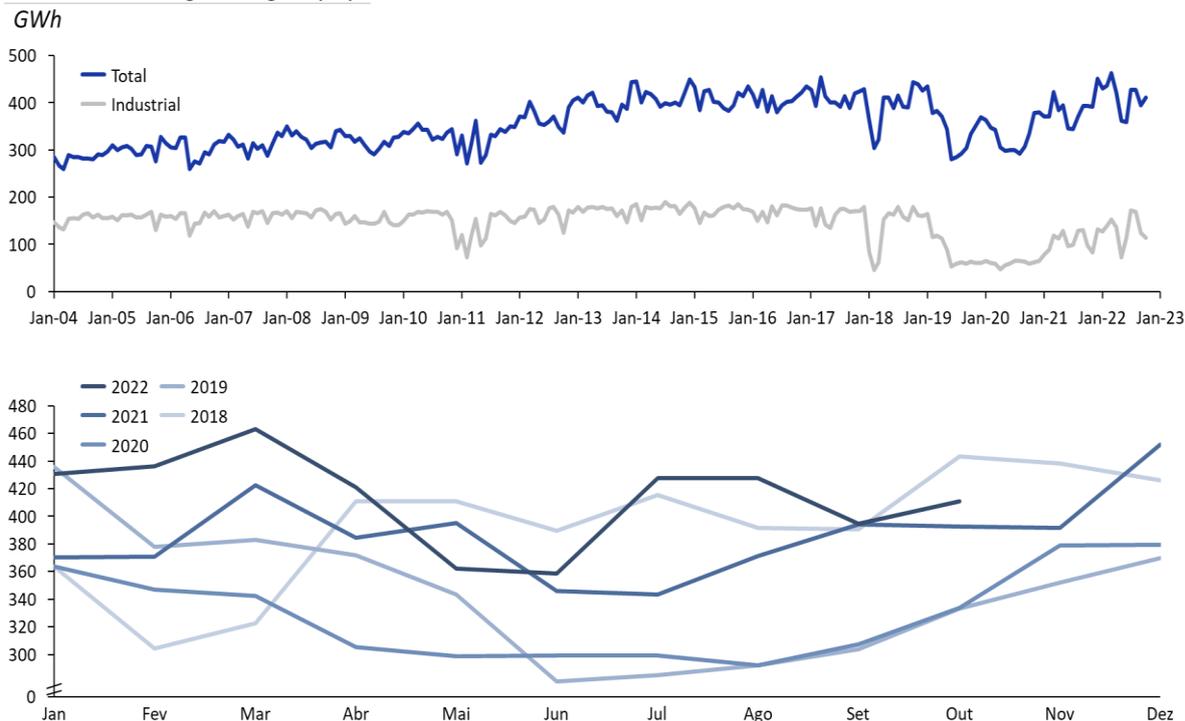


Figura 62 - Consumo de Energia em Alagoas - AL (CCEE, 2023)

Pode-se observar que o consumo de energia no estado de Alagoas vem crescendo ao longo do tempo, com uma baixa, principalmente industrial, no ano de 2020, devido principalmente às paralisações devido a pandemia da COVID 19.

Quando as curvas são sobrepostas para observar a variação mensal, é possível perceber a evolução da energia consumida ao longo do tempo, e certa correlação entre os anos, sendo possível realizar o estudo em apenas um ano operacional, com exceção do ano de 2020 que distorce dos demais. Pode-se observar que a curva de consumo anual do ano de 2021 possui baixa correlação com os demais anos apresentados, sendo desde $\sim 0,1$ em 2018 até $\sim 0,6$ em 2017. Porém, mesmo com a baixa correlação, é possível observar que as médias são similares e variam dentro de um range parecido, com desvio padrão da média em 8,4%, sendo possível observar o ano de 2021 já que é o último ano com dados completos e que apresenta informações mais atuais.

A mesma análise pode ser realizada para o estado de Goiás – GO, representando a cidade de Ipameri, na Figura 63, com as informações do consumo no mesmo período e avaliação mensal nos últimos 5 anos.

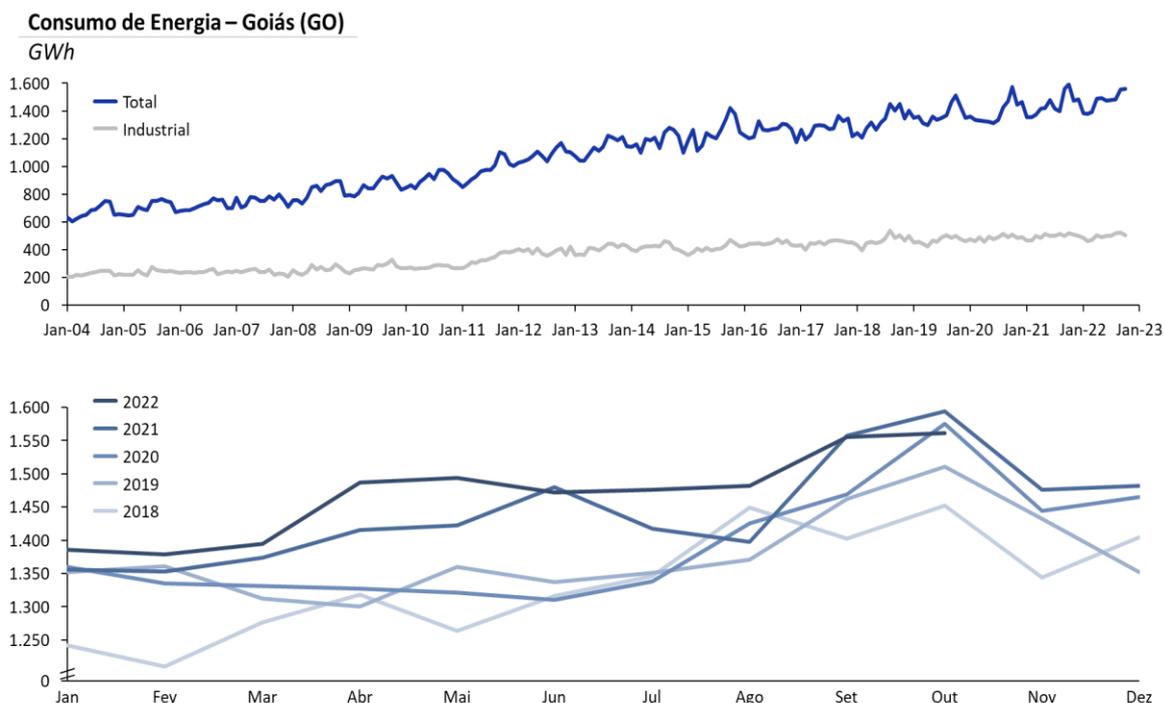


Figura 63 - Consumo de energia no estado de Goiás - GO (CCEE, 2023)

A evolução do consumo é visível no estado de Goiás, porém o desenvolvimento industrial se mostrou constante, o que é esperado por ser um estado forte na economia agrícola, dando foco para esse setor de atividade. A correção da curva de consumo total do ano 2021 com os demais anos apresentados é alta, sendo $\sim 0,7$ em 2018 e $\sim 0,9$ em 2022, dessa forma é possível utilizar o ano de 2021 também como base, já que apresenta boa correlação com os demais anos e dados mais recentes durante todo o período.

A Figura 64 apresenta as mesmas informações de consumo histórico, total e industrial, e o consumo mensal nos últimos 5 anos para o estado de Tocantins – TO, representando a cidade Peixe.

Consumo de Energia – Tocantins (TO)

GWh

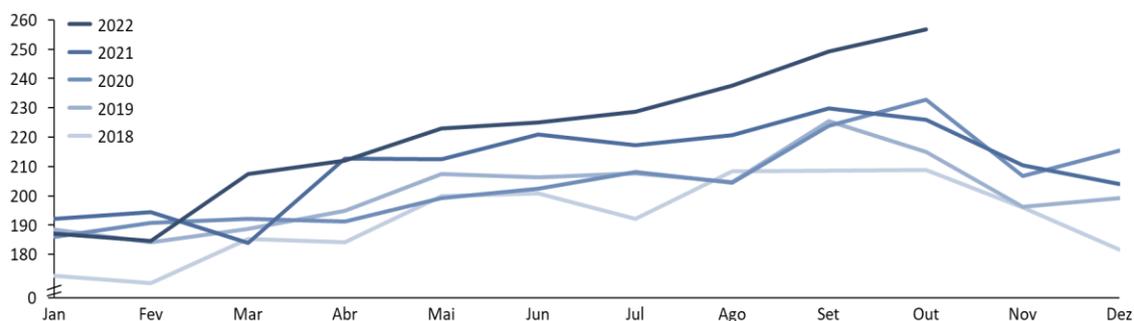
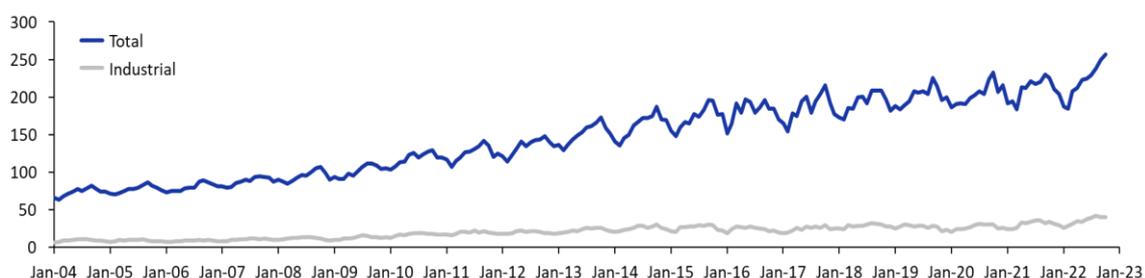


Figura 64 - Consumo histórico de energia para o estado de Tocantins - TO (CCEE, 2023)

Sendo um estado novo, apresenta o maior crescimento dentre os 3 analisados, mas com baixa participação industrial no consumo, mesmo apresentando uma certa evolução, junto com o consumo total de energia.

Tocantins apresenta as melhores correlações entre o ano de 2021 e os demais, apresentando valores entre $\sim 0,8$ em 2017 até $\sim 0,9$ em 2020 e 2022, sendo assim uma boa aproximação utilizar as informações do ano de 2021 para as avaliações desse projeto.

O sistema implementado nesse projeto terá uma realização de avaliação hora a hora, para poder otimizar justamente as variações horários do consumo e geração de energia do dia a dia. As informações de consumo de energia horária serão adaptadas a partir de cada sub-mercado, que são os dados disponíveis e a melhor aproximação da característica de consumo horária da região (ONS, 2023).

Inicialmente, é possível observar as curvas de consumo de energia nos sub-mercados correspondentes durante o ano de 2021, em que as curvas dos meses de maior consumo e menor consumo são destacadas em azul completa e pontilhada, respectivamente. A Figura 65, Figura 66 e Figura 67, indicam o comportamento dos subsistemas Nordeste, representando Marechal

Deodoro – AL, Sudeste / Centro-Oeste, representando Ipameri – GO, e Norte, representando Peixe – TO, respectivamente.

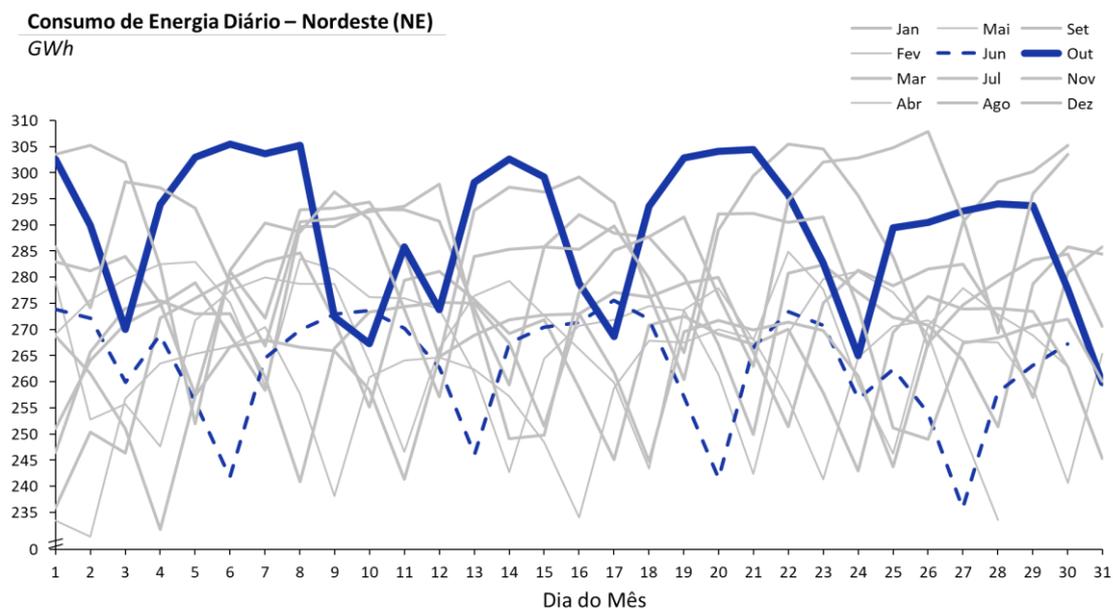


Figura 65 - Comportamento diário em 2021 do Sub-mercado Nordeste (ONS, 2023)

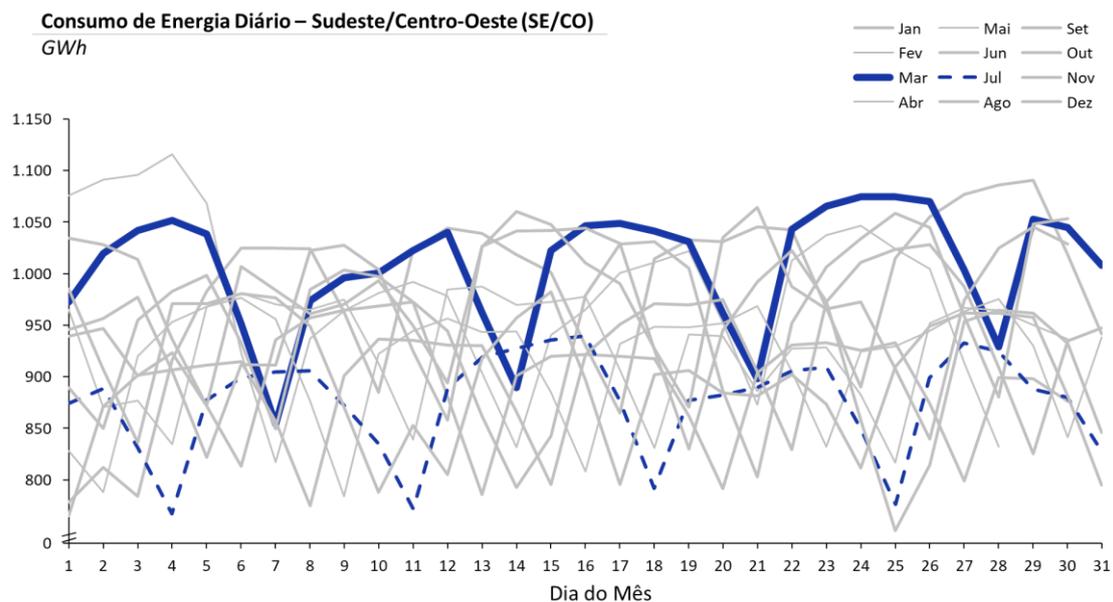


Figura 66 - Comportamento diário em 2021 do Sub-mercado Sudeste/Centro-Oeste (ONS, 2023)

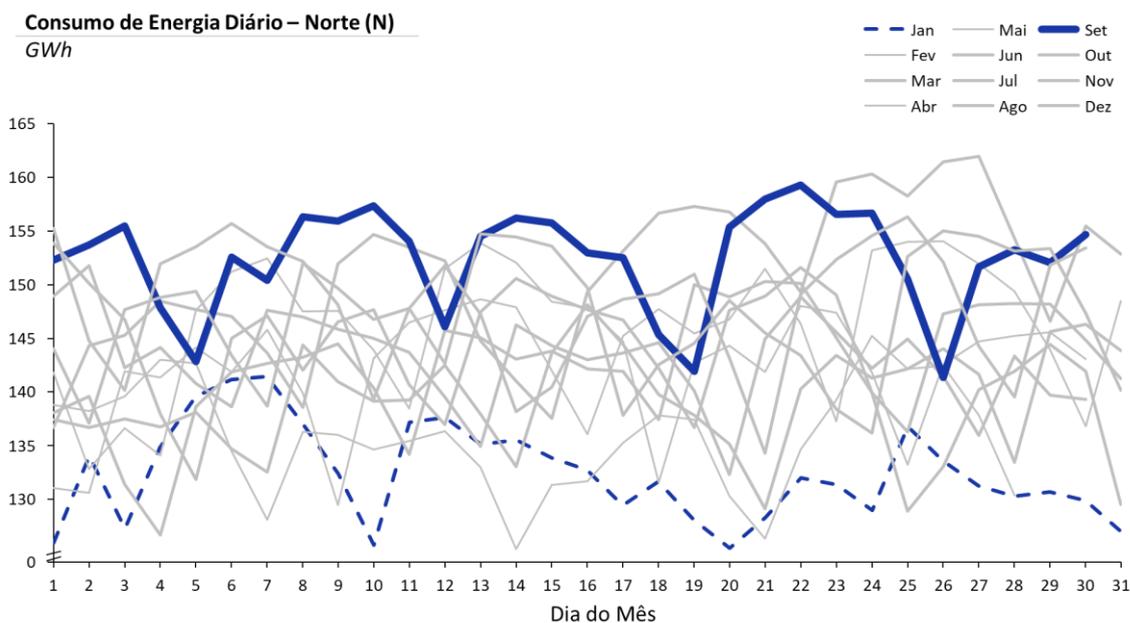


Figura 67 - Comportamento diário em 2021 do Sub-mercado Norte (ONS, 2023)

É interessante observar que os comportamentos são cíclicos durante os meses, e podem representar diferenças de acordo, inclusive, com o dia da semana observado, como pode ser observado na Figura 68, Figura 69 e Figura 70, em que se pode visualizar que os consumos são maiores nos dias de semana, devido às atividades industriais, e menores em finais de semana, sendo que a diferença se apresenta maior no cenário Sudeste / Centro-Oeste já que possui uma atividade industrial mais demandante.

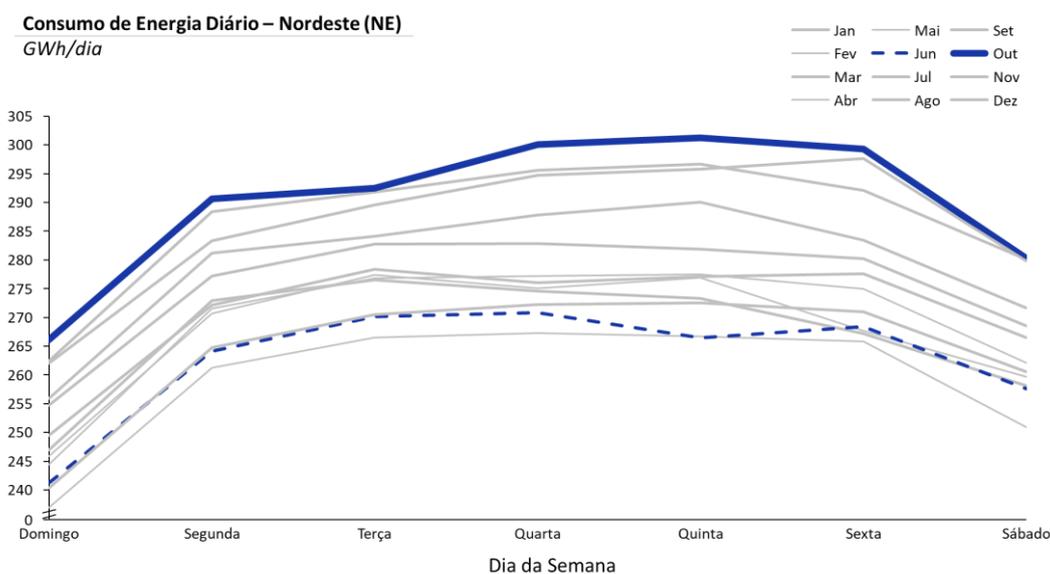


Figura 68 - Consumo de Energia por dia de semana no subsistema Nordeste (ONS, 2023)

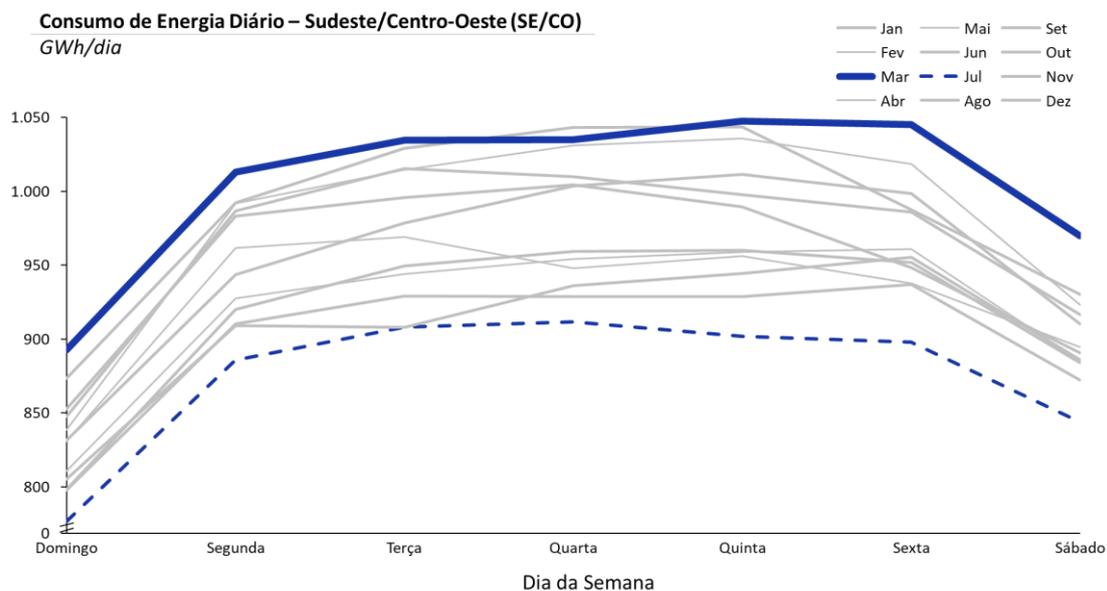


Figura 69 - Consumo de Energia por dia de semana no subsistema Sudeste / Centro-Oeste (ONS, 2023)

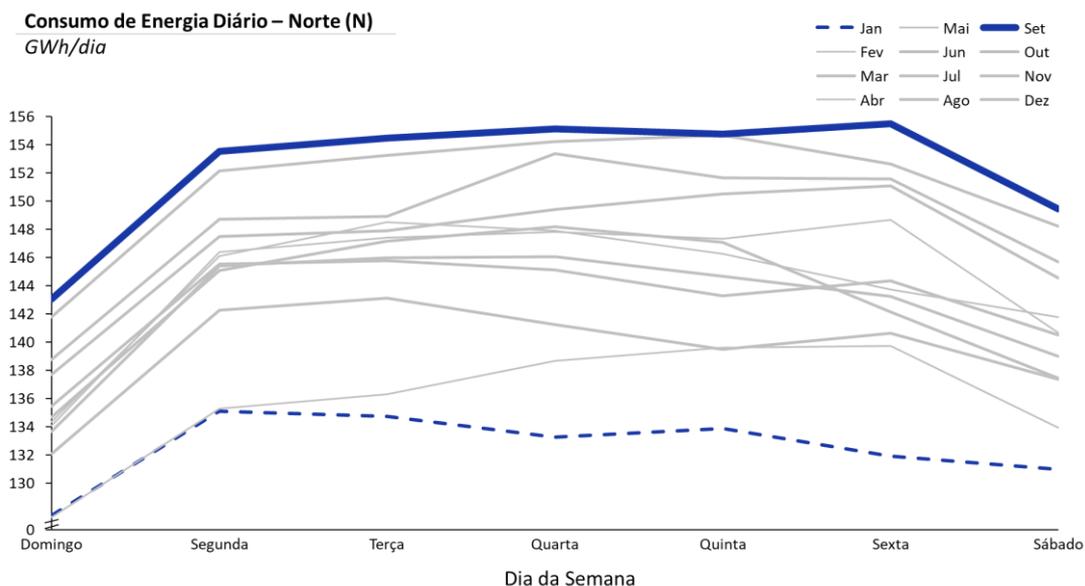


Figura 70 - Consumo de Energia por dia de semana no subsistema Norte (ONS, 2023)

Buscando o tratamento de base que será utilizado no projeto, é importante observar o comportamento horário do consumo de energia, para fins de demonstração, será apresentado o consumo em um sábado e em uma terça-feira do mês com maior consumo de cada subsistema. Tais informações podem ser observadas na Figura 71.

Consumo de Energia Horária

GWh/hora

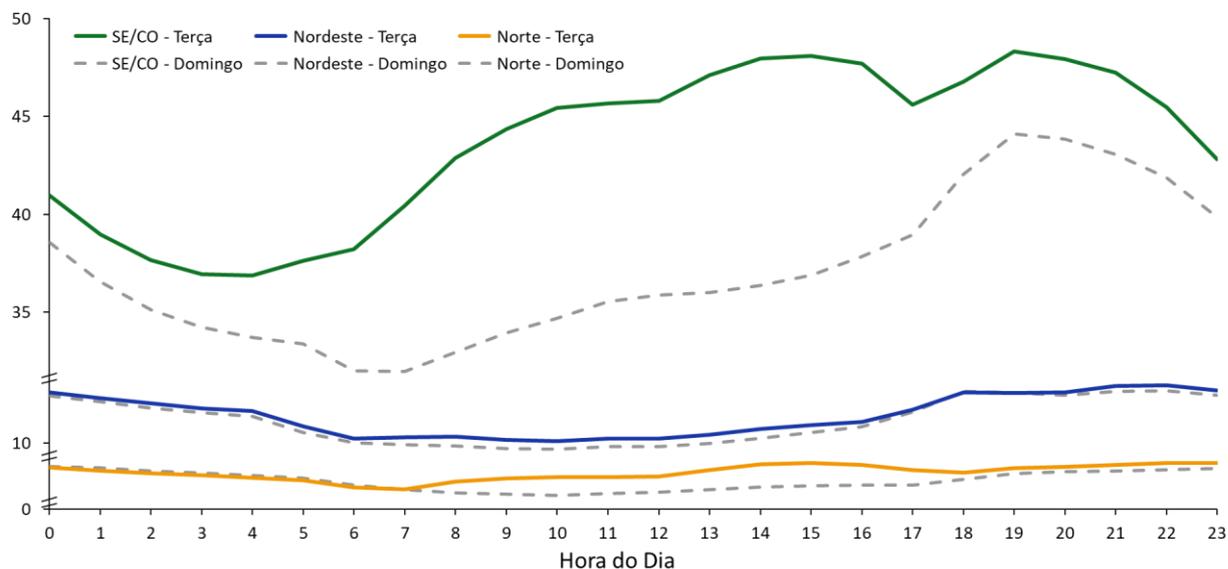


Figura 71 - Consumo de energia horária para os três subsistemas observados (ONS, 2023)

Observa-se que o consumo de energia nas regiões Norte e Nordeste são muito similares de finais de semana e dias de semana, sendo bem diferente na região SE/CO, tal fato ocorre pela forte presença industrial nessa região, que demanda alto consumo de energia. Outro ponto que pode ser observado é que o consumo tende a reduzir nos períodos noturnos e matutinos da região SE/CO, já no Norte e Nordeste o consumo permanece constante, muito devido ao uso de ar-condicionado nesse período e sendo maior o consumo residencial do que o industrial.

As informações de consumo de energia municipais são escassas, existindo apenas as informações anuais de consumo do mercado cativo, aquele mercado que não foi transferido para o livre. Assim, para fins do estudo desse projeto, será realizada uma estimativa da curva horária de cada município tomando como base o seguinte processo, apresentado também na Figura 72:

- Avaliação da energia anual de cada município
- Extração do percentual de participação do município no mercado cativo do estado
- Extração do percentual do mercado cativo no mercado total do estado
- Extração do percentual do sub-mercado no mercado total de cada estado
- Aplicação dos percentuais compostos na curva horário do sub-mercado para a obtenção da curva horária do município

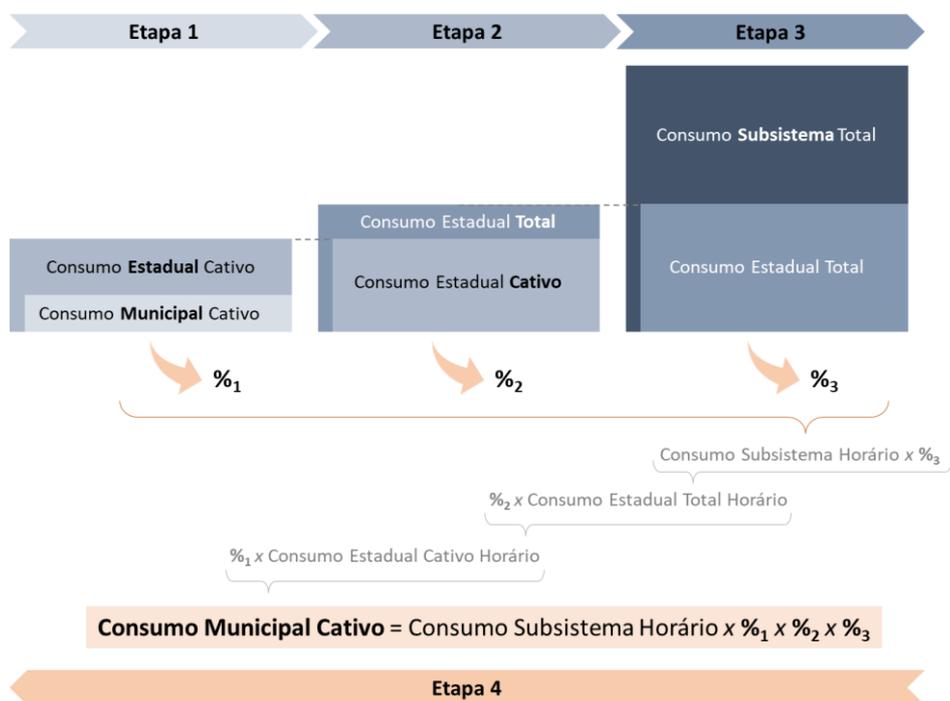


Figura 72 - Definição por aproximação da curva horário municipal

Para a **Etapa 1**, pode-se observar as curvas anuais de cada município, de 2010 até 2021, junto com o percentual dessa curva em relação ao consumo estadual cativo, a Figura 73, Figura 74 e Figura 75 apresentam tais informações para os municípios de Marechal Deodoro – AL, Ipameri – GO e Peixe – TO, respectivamente.

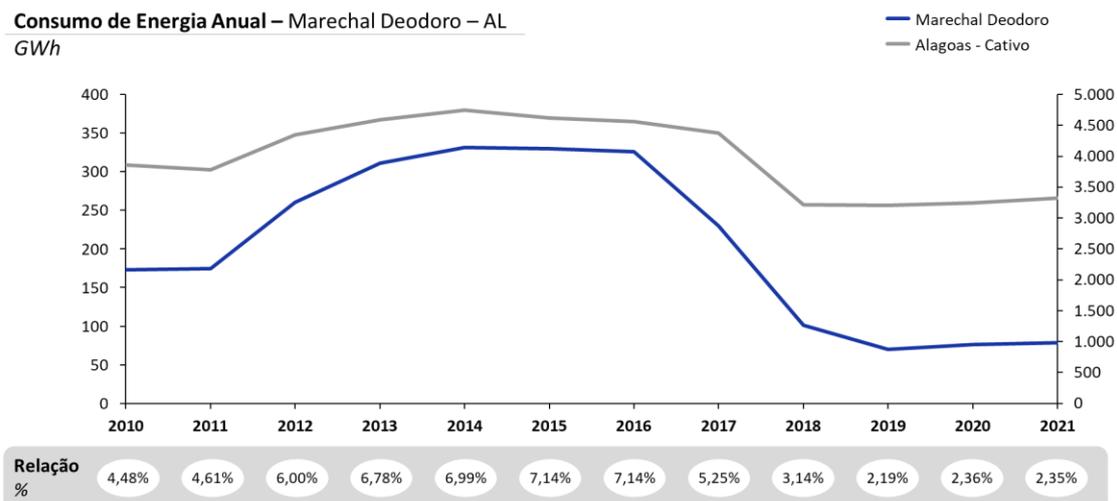


Figura 73 - Consumo de Energia Municipal vs Estadual – Alagoas

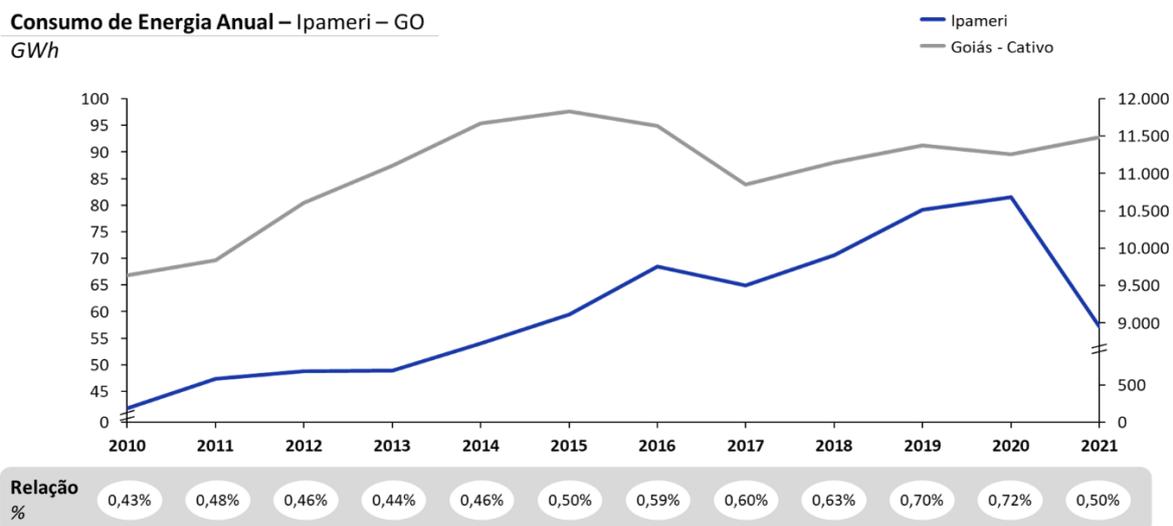


Figura 74 - Consumo de Energia Municipal vs Estadual - Goiás

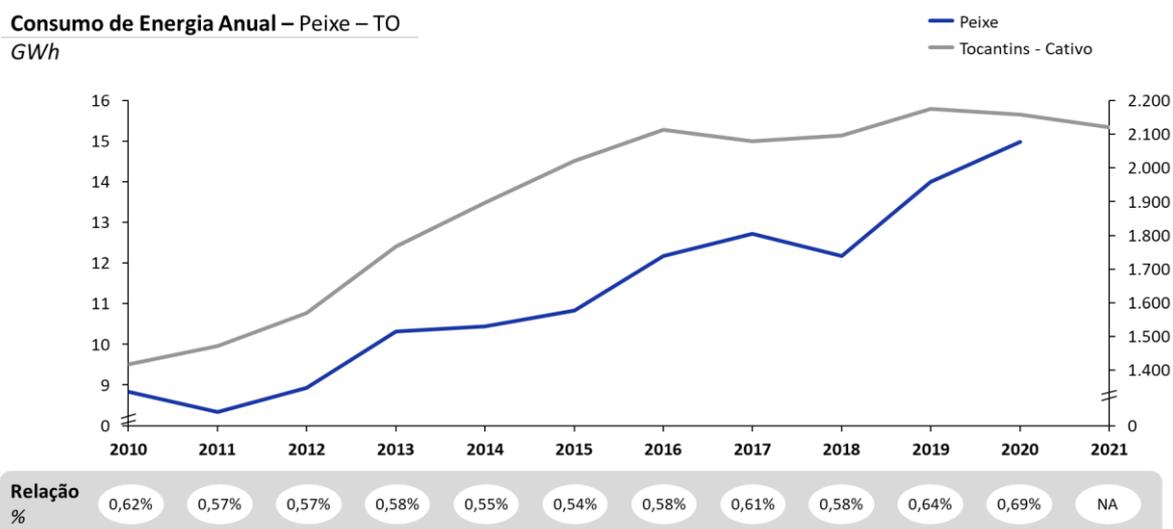


Figura 75 - Consumo de energia Municipal vs Estadual - Tocantins

Dessa forma, pode-se utilizar o fator do ano 2021 para o estudo de aproximação, que representa o mais recente indicador. Para o município Peixe – TO, será utilizado uma aproximação linear com base no crescimento dos anos 2017 a 2020. Assim os valores obtidos foram os seguintes:

- Marechal Deodoro – AL: **2,35%**
- Ipameri – GO: **0,50%**
- Peixe – TO: **0,71%**

Então, para a **Etapa 2**, será avaliado a participação percentual do mercado cativo anualmente de 2005 até 2021, com o mercado total para cada estado, apresentado na Figura 76.

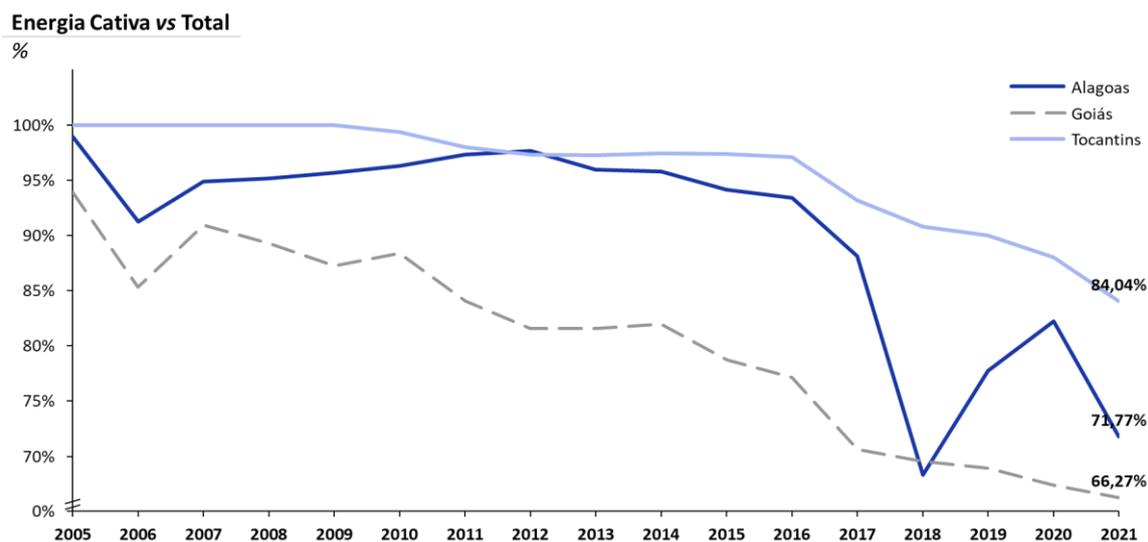


Figura 76 - Consumo de Energia Cativo vs Total

Observa-se que o consumo cativo vem diminuindo ao longo do tempo com base no consumo total, isso ocorre, principalmente, pelo forte crescimento do mercado livre de energia, em que os consumidores são livres para selecionar de qual fonte a energia será adquirida. Além disso, outro ponto forte nessa visível redução é a redução do consumo, principalmente residencial, devido à implementação de painéis fotovoltaicos em residências, utilizando a geração distribuída de energia.

Os valores considerados, para esse segundo fator, são os referentes ao ano de 2021, por serem mais recentes, podendo ser:

- Marechal Deodoro – AL: **71,77%**
- Ipameri – GO: **66,27%**
- Peixe – TO: **84,04%**

A **Etapa 3** consiste na comparação do consumo de energia no subsistema, com o consumo nos estados em estudo, tal comparação pode ser observada na Figura 77.

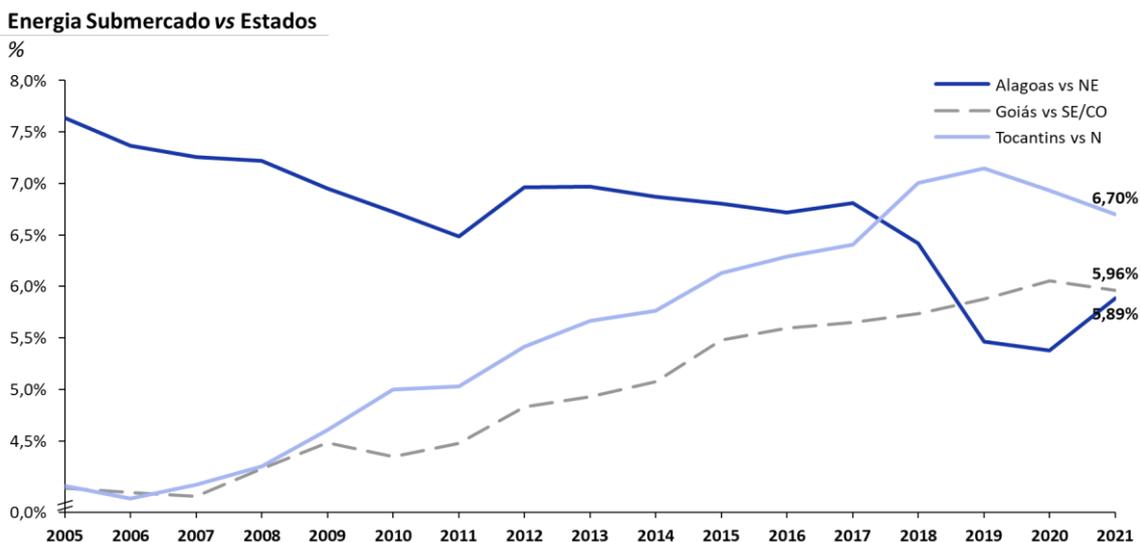


Figura 77 - Consumo de energia Estado vs Sub-mercado

A representatividade dos estados das duas menores cidades deste estudo aumentou ao decorrer do tempo, porém a de Alagoas diminuiu. Novamente, será utilizado os fatores correspondentes ao ano 2021, por serem mais recentes, sendo:

- Marechal Deodoro – AL: **5,89%**
- Ipameri – GO: **5,96%**
- Peixe – TO: **6,70%**

Com a definição dos três fatores, pode-se observar a característica de cada uma das cidades, pelo fator total, sendo a multiplicação dos três fatores, resultando em:

- Marechal Deodoro – AL: **0,10%**
- Ipameri – GO: **0,02%**
- Peixe – TO: **0,04%**

A curva horária, para os mesmos dias apresentados anteriormente para os subsistemas, porém considerando o fator para cada cidade, pode ser fornecido conforme indica a Figura 78.

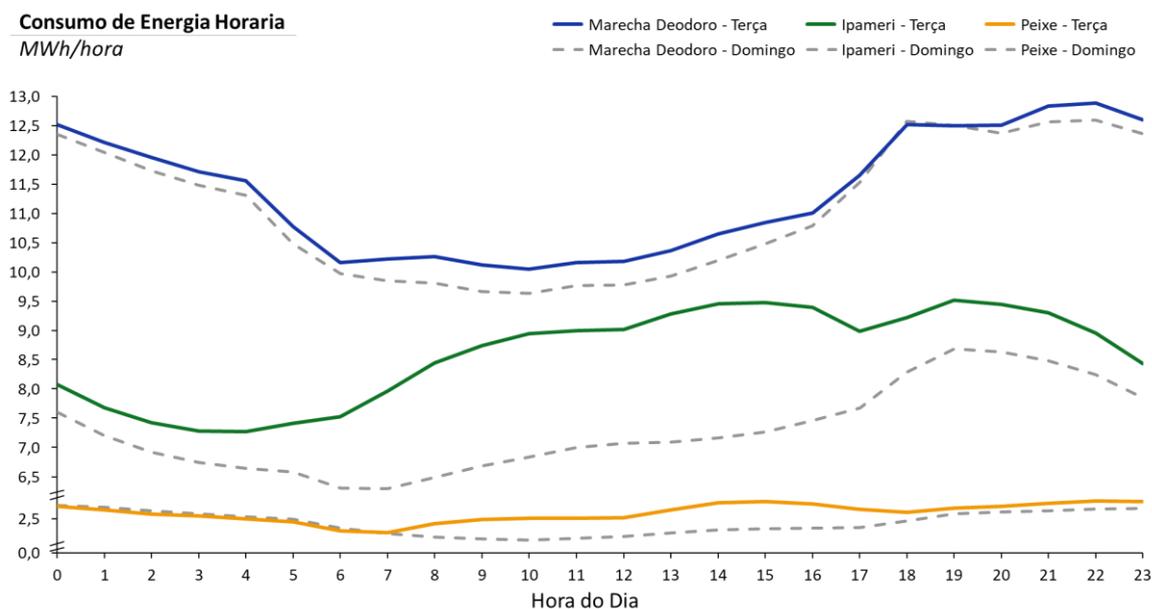


Figura 78 - Consumo de energia horária, aproximado, para cada cidade em estudo

Com isso, é possível desenvolver o projeto realizando a análise e simulação das cidades com base horária coerente.

4.2.2 PRECIFICAÇÃO DE ENERGIA

Conforme explicitado no Capítulo 2, a precificação de energia toma como base o PLD (*Preço Líquido da Diferença*) calculado pela CCEE (*Câmara de Comercialização de Energia Elétrica*). A precificação é um indicativo do preço, em base horária, da energia, dada por R\$/MWh, reais por megawatt hora. Os preços são divididos entre cada sub-mercado brasileiro. Como as cidades em análise possuem sub-mercado diferentes, é interessante observar o comportamento dessas curvas de precificação nos diferentes sub-mercados, sendo:

- Marechal Deodoro – AL: **Sub-mercado Nordeste**
- Ipameri – GO: **Sub-mercado Sudeste / Centro-Oeste**
- Peixe – TO: **Sub-mercado Norte**

O comportamento médio, em cada mês, do PLD do ano de 2021 pode ser observado na Figura 79.

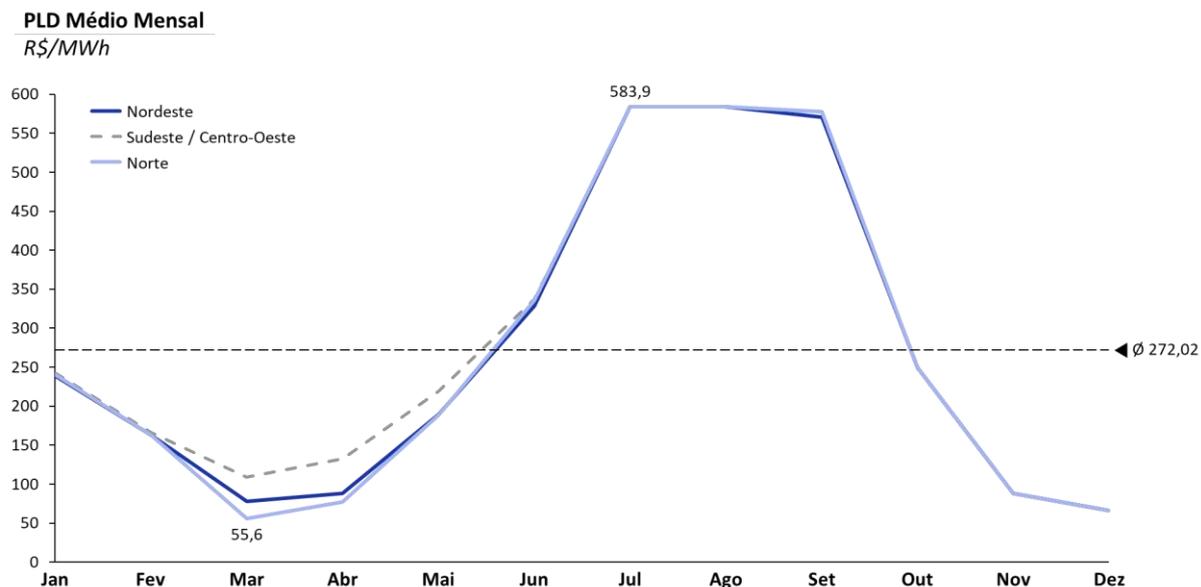


Figura 79 - Comportamento do PLD médio durante o ano de 2021 (CCEE, 2023)

Observa-se claramente que existe um período de alta dos preços de energia, que coincide com o momento de baixo índice pluviométrico no Brasil, e um período de baixa nos preços. A Figura 80, Figura 81 e Figura 82 apresentam o comportamento médio para cada horário, em cada mês, sendo destaque os meses de maior precificação, com linha azul contínua, e de menor precificação, com linha azul pontilhada.

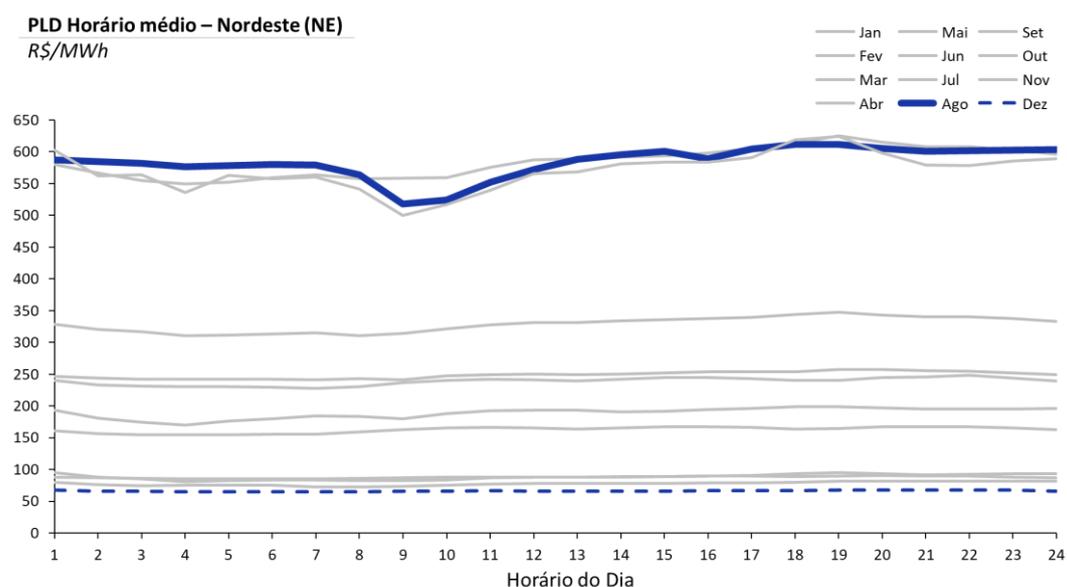


Figura 80 - Preço da Energia Médio em cada mês - Nordeste (CCEE, 2023)

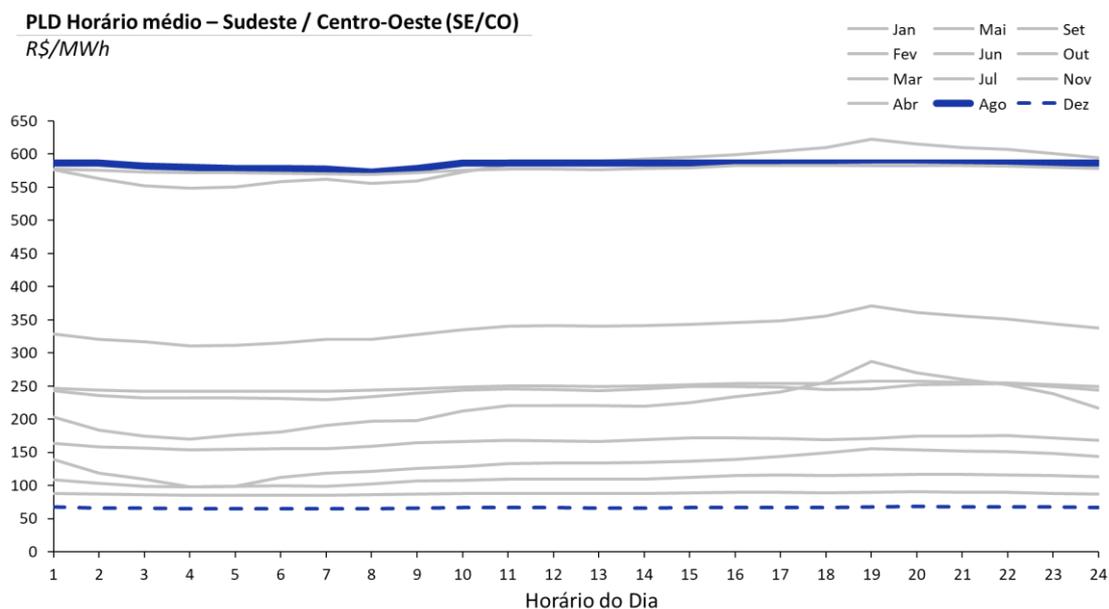


Figura 81 - Preço da Energia Médio em cada mês - Sudeste / Centro-Oeste (CCEE, 2023)

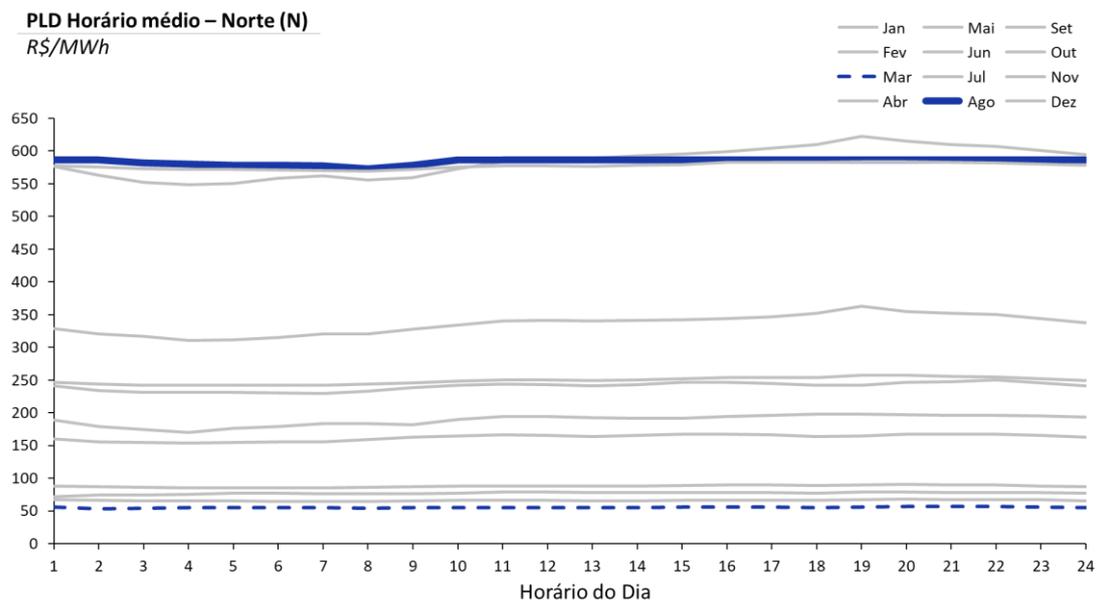


Figura 82 - Preço da Energia Médio em cada mês - Norte (CCEE, 2023)

Com isso, pode-se corroborar com a tese anterior de que os preços são relativamente constantes durante os horários, alterando significativamente nos meses do ano.

Outro ponto interessante, que fará diferença na otimização do projeto, é a variação da precificação de acordo com o dia da semana, tal informação pode ser observada na Figura 83, Figura 84 e Figura 85.

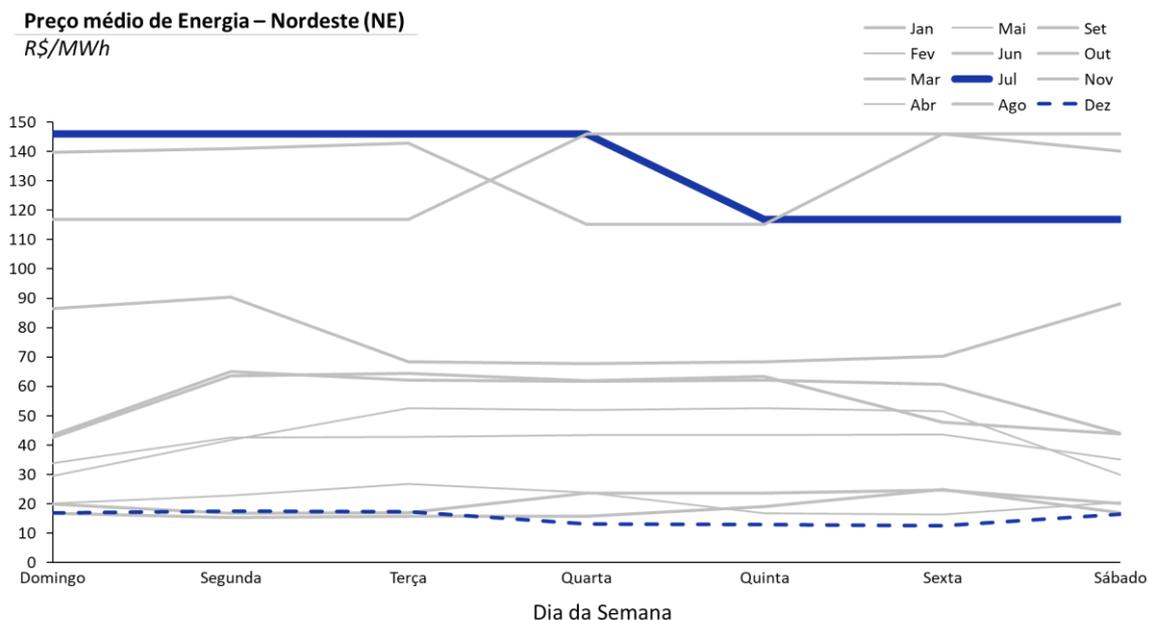


Figura 83 - Preço médio de energia por dia da semana - Nordeste (CCEE, 2023)

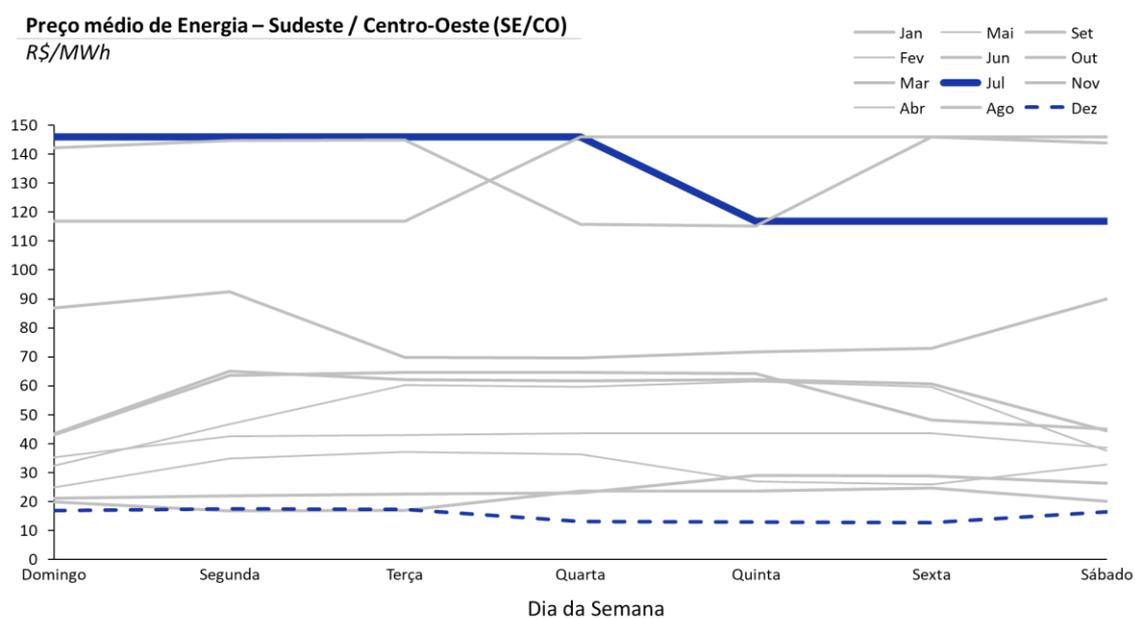


Figura 84 - Preço médio de energia por dia da semana - Sudeste / Centro-Oeste (CCEE, 2023)

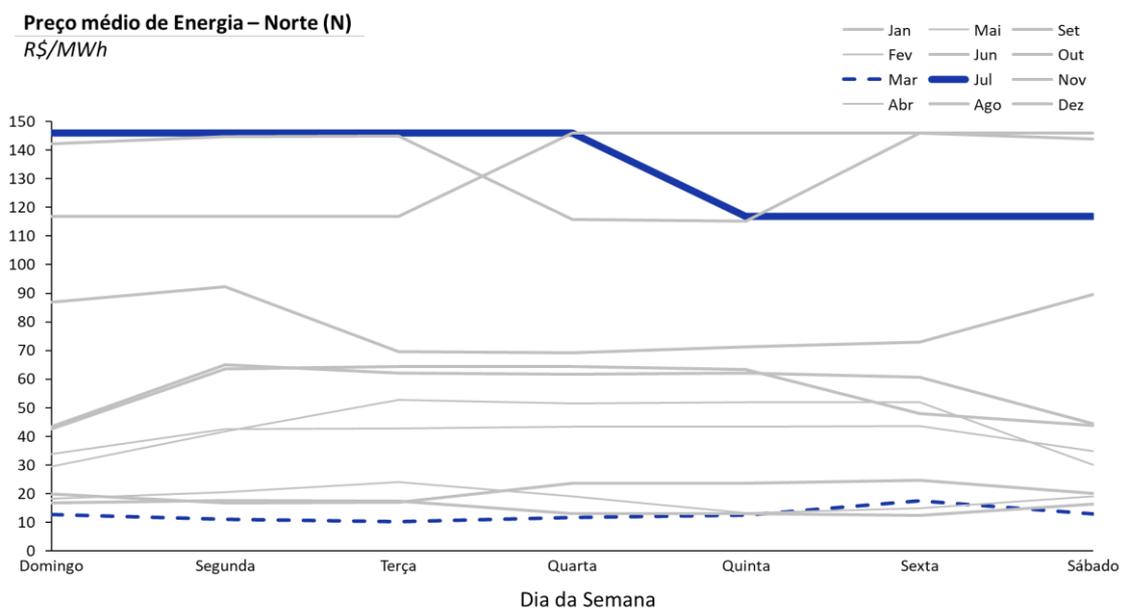


Figura 85 - Preço médio de energia por dia da semana - Norte (CCEE, 2023)

Observa-se que cada mês possui um comportamento diferente em relação aos dias da semana, sendo um fator interessante para a avaliação e otimização dos cenários energéticos em cada um dos municípios.

Por fim, é interessante observar a relação horário do preço, dentro de dois dias distintos em 2021, para os três cenários, considerando um domingo e uma sexta-feira. Tal informação pode ser observado na Figura 86.

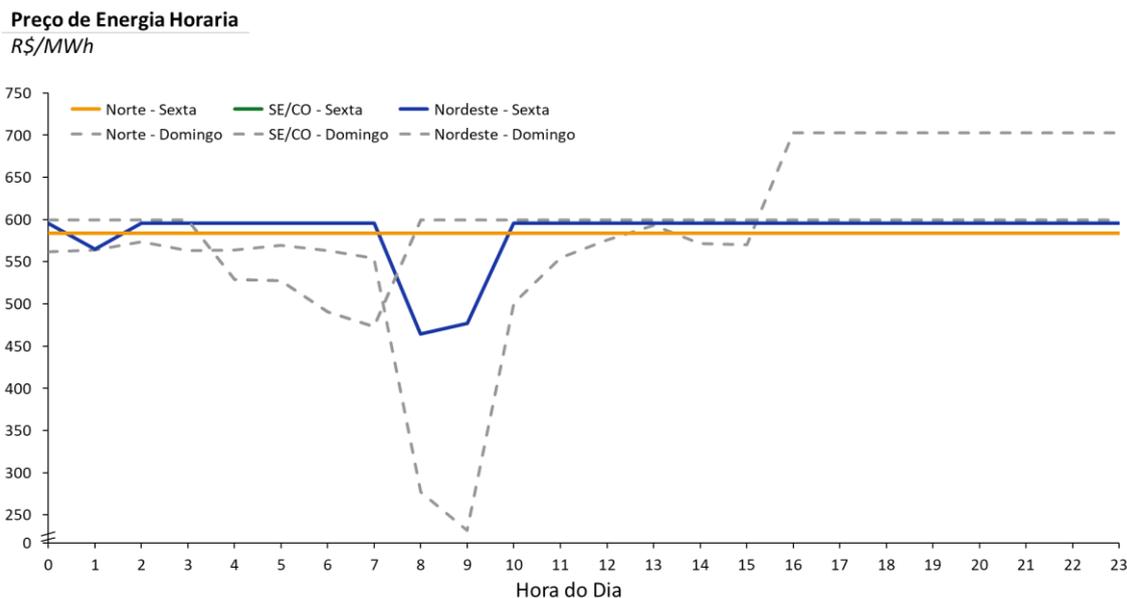


Figura 86 - Preço da energia em um domingo e uma sexta-feira de agosto/2021 (ONS, 2023)

Por fim, é importante indicar que como apresentado na revisão bibliográfica no Capítulo 2, o armazenamento dos reservatórios hídricos, junto com indicativos do índice pluviométrico, são bons fatores para realizar a aproximação do preço de energia, quando tais dados não são de fácil acesso.

4.2.3 ÍNDICES DOS FATORES NATURAIS

Como terceira etapa, é necessário levantar os dados de recursos naturais utilizados para a geração de energia híbrida, no caso desse projeto a irradiação solar e a velocidade de vento. Inicialmente, será apresentado os dados de **Irradiação Solar** para os municípios em estudo. O fator importante de ser observado é a **Irradiação Global Horizontal**, que é dada pela soma dos seguintes componentes:

- Irradiação Direta Normal: Indica a irradiação incidente na superfície terrestre, sem ser absorvida por outros meios atmosféricos;
- Irradiação Difusa: Indica a parcela da irradiação que passou por absorções na atmosfera, mas atinge a superfície terrestre.

A Figura 87 apresenta a variação anual do potencial solar dos municípios estudados (LABREN, 2017).

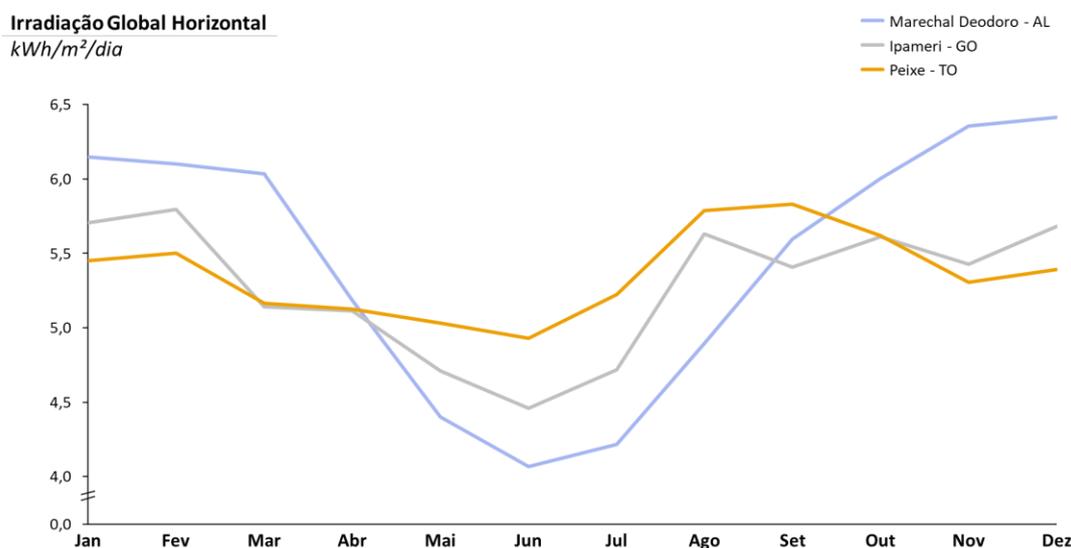


Figura 87 - Irradiação Solar Global Horizontal ao longo dos meses do ano

Observa-se o comportamento sazonal que ocorre no país inteiro, com alta incidência solar nos meses de verão, e baixas nos meses de inverno. Porém tal variabilidade de geração é muito menor no Tocantins, do que em Alagoas, isso devido à proximidade com o Equador que gera incidências maiores. Vale observar as médias e coeficientes de variação das cidades em análise, para verificar tal ponto:

- Marechal Deodoro – AL: **5,45 ± 15,2% kWh/m²/dia**
- Ipameri – GO: **5,25 ± 8,2% kWh/m²/dia**
- Peixe – TO: **5,36 ± 5,1% kWh/m²/dia**

Para este estudo é importante considerar a geração horária para os municípios avaliados, dessa forma, será utilizada técnica similar ao apresentado para a geração, observando-se o comportamento diário e horário, com base em um percentual da energia total produzida, podendo, assim, obter as curvas com a mesma proporção apresentada anteriormente.

Para a obtenção da variação horária das cidades, foi estimado a geração horária média em cada mês, utilizando as informações do Instituto Nacional de Pesquisas Espaciais (INPE) e da ONS (2023), referentes às localidades:

- Marechal Deodoro – AL: Referência da geração de energia em Pernambuco – PE
- Ipameri – GO: Referência da irradiação solar no Distrito Federal
- Peixe – TO: Referência da irradiação solar em Palmas – TO

Com isso, as médias mensais para os estados estão apresentadas na Figura 88, Figura 89 e Figura 90, respectivamente.

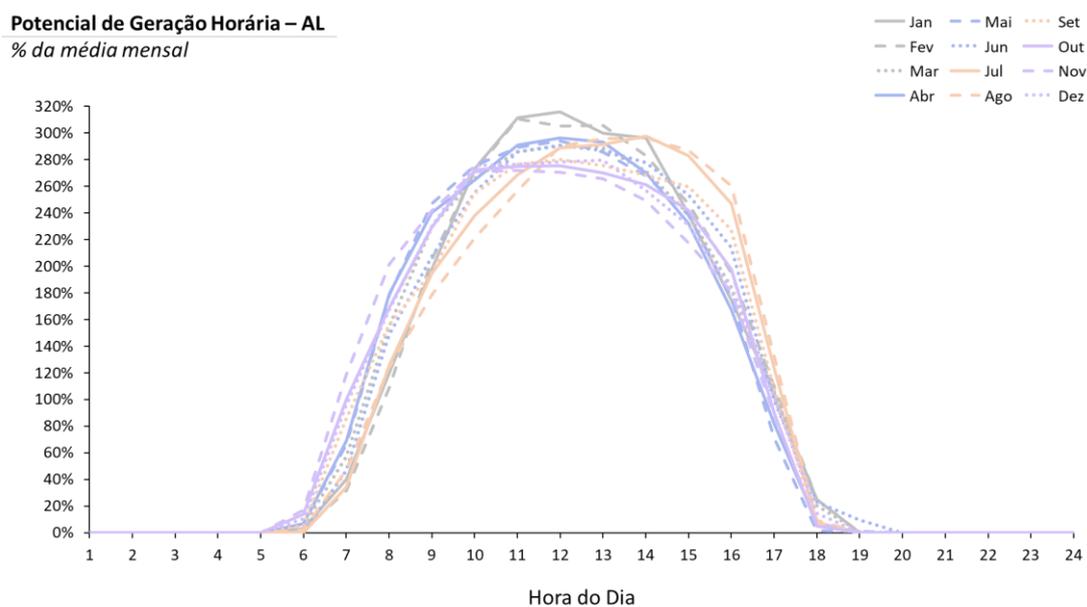


Figura 88 - Incidência solar horária média para referência de Alagoas

Potencial de Geração Horária – GO
% da média mensal

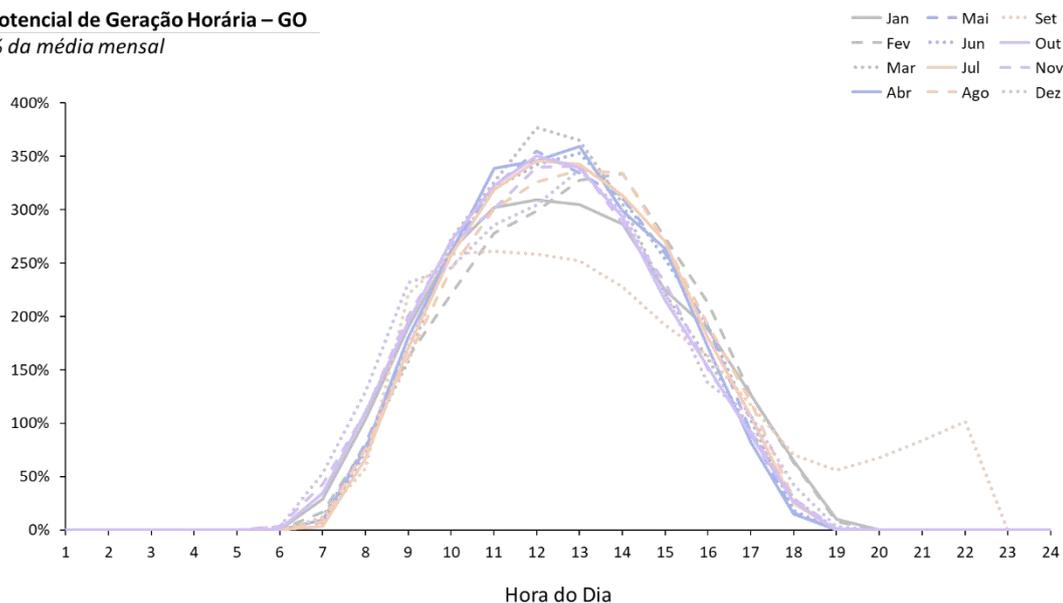


Figura 89 - Incidência solar média horária para referência de Goiás

Potencial de Geração Horária – TO
% da média mensal

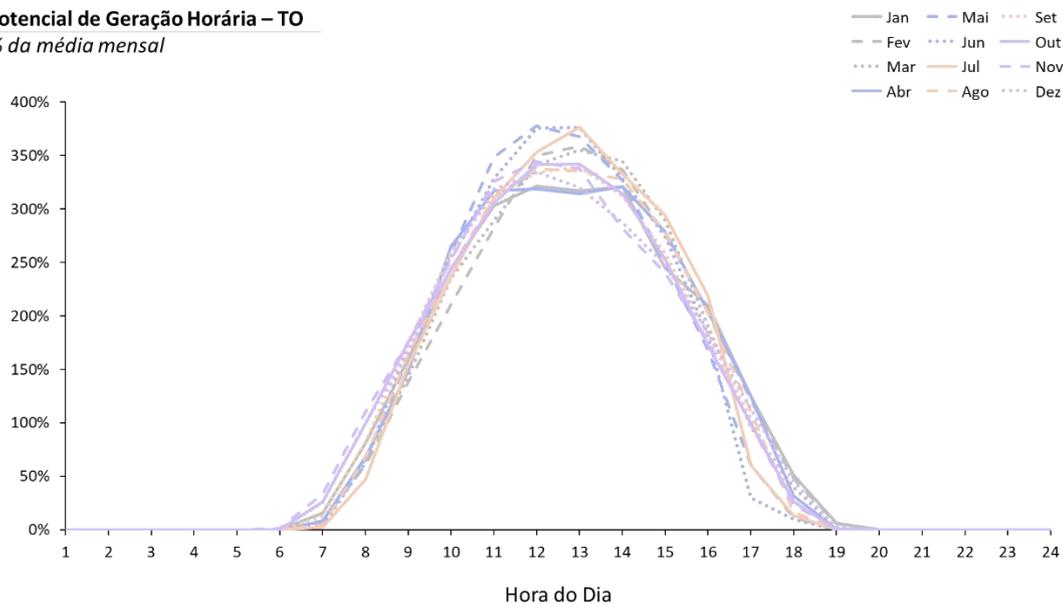


Figura 90 - Incidência solar horária média para referência de Tocantins

Observa-se que apesar do padrão de incidência, o Nordeste demonstra um potencial mais constante de geração. Além disso, dados fora da normalidade serão eliminados da simulação, como setembro em Goiás.

Como segunda etapa deve-se observar para essas mesmas localidades a **Velocidade do Vento**. Seguindo a mesma metodologia apresentada anteriormente, inicialmente pode-se observar a velocidade média para os municípios analisados nesse estudo, apresentando a variação observada no decorrer de um ano (CEPEL, 2013), tal informação está presente na Figura 91.

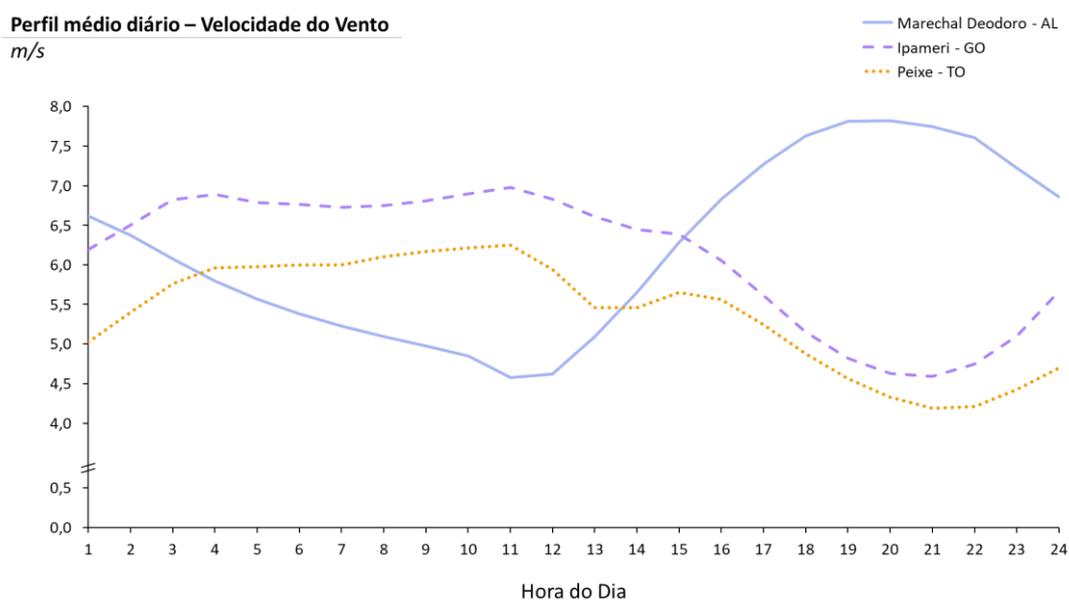


Figura 91 - Perfil médio horário de velocidade do vento

A Figura 92 apresenta o comportamento mensal para os municípios analisados, os dados foram obtidos por aproximação de municípios próximos, para Ipameri e Marechal Deodoro (INPE). Para o município Peixe – TO os valores foram obtidos de uma base mensal histórica de 10 anos de Fundação ABC (2022).

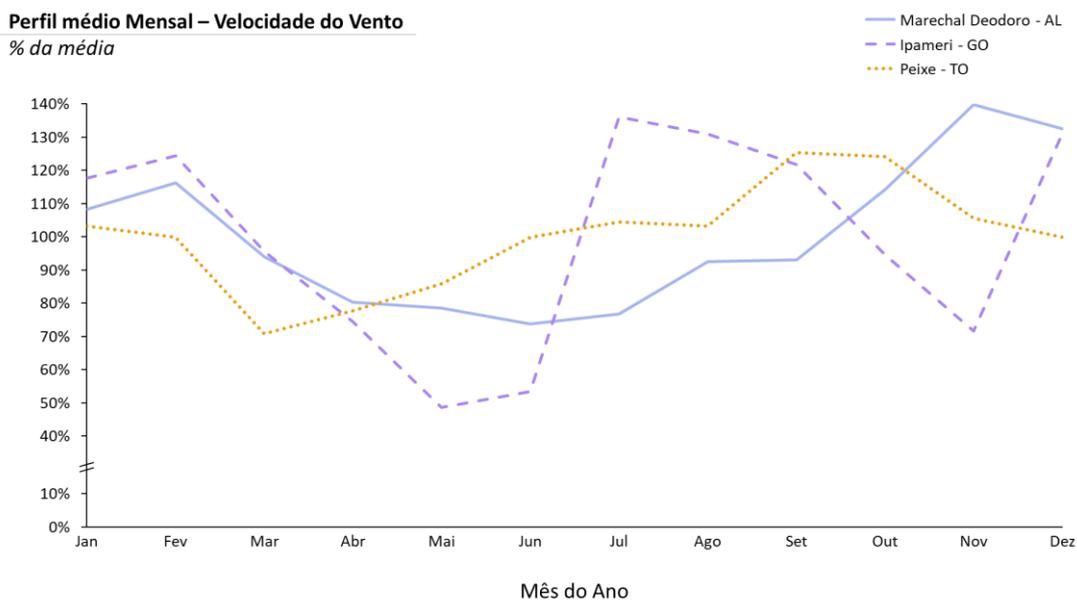


Figura 92 - Variação de velocidade do vento mensal

Para a obtenção horária das curvas de vento para cada município serão obtidas seguindo a seguinte ordem:

- Velocidade média anual à 100m (CEPEL, 2013):
 - Marechal Deodoro – AL: **5,83031 m/s**
 - Ipameri – GO: **6,10749 m/s**
 - Peixe – TO: **4,44972 m/s**
- Aplicação da curva mensal para obter a geração mês a mês
- Aplicação da aproximação de que todos os dias possuem a mesma proporção de geração e mesma curva, considerando a média do mês obtida anteriormente.

Com isso, pode-se obter as informações necessárias tanto para geração de energia solar como eólica.

4.3 ESTUDO DA IMPLEMENTAÇÃO

Com base nos dados obtidos no Capítulo 4.2 é possível realizar o dimensionamento e estudo de toda implementação do sistema de geração híbrida, incluindo seu controle e atores principais.

Os atores do sistema que devem ser definidos, prioritariamente são os seguintes:

- **Consumo anual de energia**

Define-se qual o consumo dos municípios em um ano, esse valor é a base para o dimensionamento de todo o sistema remanescente.

- **Parque híbrido – Eólico e Solar**

Indica o melhor dimensionamento do parque híbrido, considerando a melhor proporção entre geração eólica e solar, para determinados municípios, com o objetivo de otimizar o custo de geração total.

- **Sistema de Baterias**

O sistema de baterias deve prover energia para suportar a demanda nos períodos de baixa geração e alto consumo, sendo uma parte complementar do sistema.

- **Inteligência Artificial e Controlador**

Visa realizar a tomada de decisão do sistema, visando o aprimoramento do carregamento e descarregamento das baterias com base nas informações disponíveis do sistema e aprendizado de máquina.

4.3.1 DIMENSIONAMENTO DO SISTEMA DE ENERGIA

Para o dimensionamento do sistema deve-se observar o consumo que será suportado, neste estudo, para fins de simplificação, a avaliação é com base no consumo diário, em um mês e dia de maior demanda de energia nos municípios em análise, nesse caso são os seguintes:

- Marechal Deodoro – AL: 14/10/2021 – *Quinta-feira*
- Ipameri – GO: 04/03/2021 – *Quinta-feira*
- Peixe – TO: 15/09/2021 – *Quarta-feira*

A Figura 93, apresenta a geração nesses dias indicados.

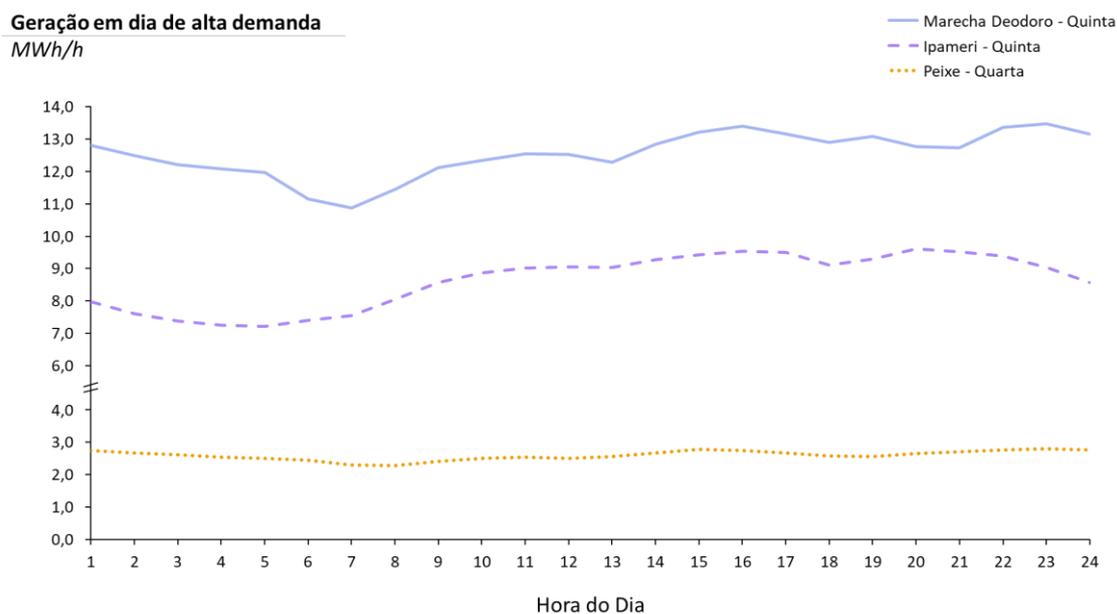


Figura 93 - Consumo horário em um dia de alta demanda de energia

Assim, o consumo diário máximo é dado por:

- Marechal Deodoro – AL: **300,94 MWh**
- Ipameri – GO: **207,21 MWh**
- Peixe – TO: **62,27 MWh**

Segundo EPE (2023) o LCOE médio do Brasil é dado por:

- Energia Solar = 172,50 R\$/MWh
- Energia Eólica = 142,50 R\$/MWh

Para obter os valores aproximados para os municípios analisados, foi utilizada uma ponderação da Irradiação Global Horizontal de cada município, comparada com a média do Brasil, e a velocidade do vento a 100 metros de cada município com a média do Brasil, para a energia solar e eólica, respectivamente, obtendo os seguintes resultados:

- Marechal Deodoro – AL
 - Energia Solar = 166,96 R\$/MWh
 - Energia Eólica = 104,07 R\$/MWh
- Ipameri – GO
 - Energia Solar = 172,27 R\$/MWh
 - Energia Eólica = 99,35 R\$/MWh
- Peixe – TO
 - Energia Solar = 169,67 R\$/MWh
 - Energia Eólica = 136,36 R\$/MWh

A planta ótima, pelo requisito financeiro, é a que possui o LCOE otimizado, buscando a intersecção da curva da geração eólica pela solar, conforme apresentado na Figura 94, Figura 95 e Figura 96 para os municípios em estudo.

Custo de Geração – Marechal Deodoro (AL)
R\$/MWh

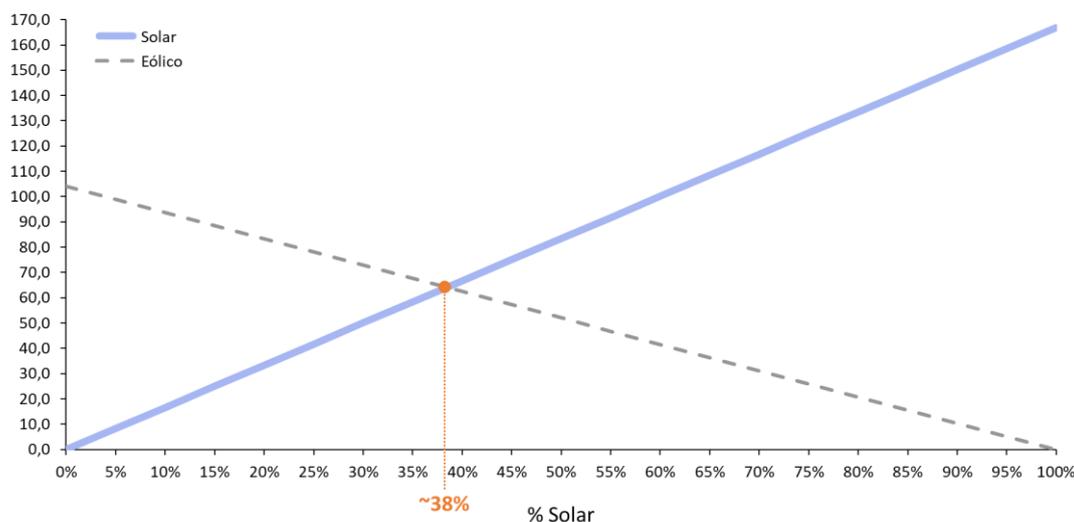


Figura 94 - Curva de LCOE para cada percentual de fonte - Marechal Deodoro (AL)

Custo de Geração – Ipameri (GO)

R\$/MWh

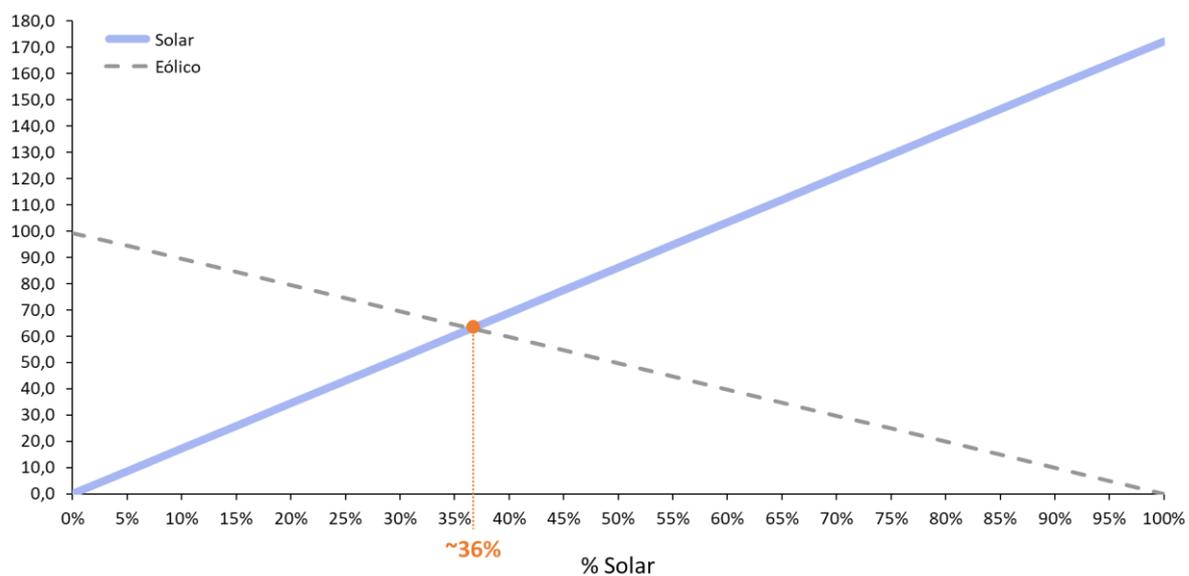


Figura 95 - Curva de LCOE para cada percentual de fonte - Ipameri (GO)

Custo de Geração – Peixe (TO)

R\$/MWh

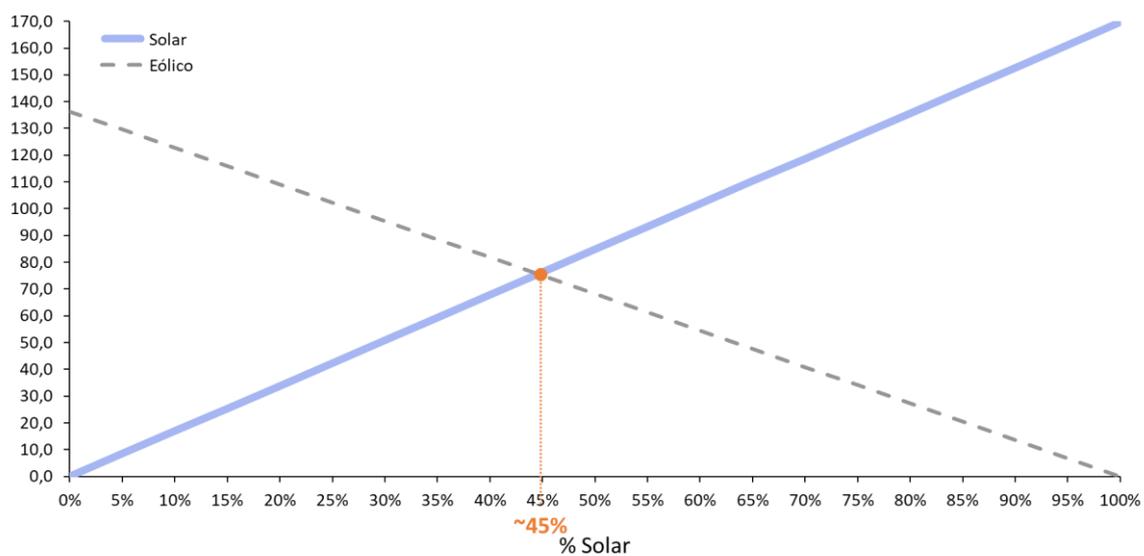


Figura 96 - Curva de LCOE para cada percentual de fonte - Peixe (TO)

Assim, os percentuais obtidos para cada localização foi a seguinte:

- Marechal Deodoro – AL
 - Energia Solar/Eólica = 38% / 62%
- Ipameri – GO
 - Energia Solar/Eólica = 36% / 64%
- Peixe – TO
 - Energia Solar/Eólica = 45% / 55%

A conversão de energia, considerando fator de capacidade, é de:

- **Energia Solar**
 - 545Wp / placa fotovoltaica (Dados de mercado, 2023)
 - 4,404 kWh/kWp – média brasileira (Global Solar Atlas, 2022)
 - 5,276 kWh/m² - Irradiação Global Horizontal média brasileira
- **Energia Eólica**
 - 1,5 MW / turbina (Fuhrländer FL MD 77)
 - 40,42% - Fator de capacidade médio (ONS, 2022)
 - 4,258 m/s – Velocidade média no Brasil do vento a 100 metros

Assim, o dimensionamento das usinas híbridas para cada município é dado como uma relação das médias brasileiras, sendo:

- **Marechal Deodoro – AL**
 - Consumo diário = **300,94 MWh**
 - **Solar** = 300,94 MWh x 38% = **114,36 MWh**
 - Irradiação média = **5,451 kWh/m²**
 - Fator de geração = **4,550 kWh/kWp/dia**
 - Potência pico = 114,36 / 4,550 = **25.134.066 Wp**
 - Placas Solares = **46.117** -> Potência de **25,13 MWp** = 114,358 MWh
 - **Eólico** = 300,94 – 114,36 = **186,58 MWh**
 - Velocidade do Vento média = 5,83 m/s
 - Fator de capacidade eólico = **55,35%**

- Potência = $186,58 / 55,35\% / 24 \text{ horas} = 14,05 \text{ MW}$
 - Aerogeradores = **9** -> Potência de **13,5 MW** = 179,33 MWh
 - Geração média diária = **293,68 MWh**
-
- **Ipameri – GO**
 - Consumo diário = **207,21 MWh**
 - **Solar** = $207,21 \text{ MWh} \times 36\% = 74,60 \text{ MWh}$
 - Irradiação média = **5,283 kWh/m²**
 - Fator de geração = **4,410 kWh/kWp/dia**
 - Potência pico = $74,60 / 4,410 = 16.916.350 \text{ Wp}$
 - Placas Solares = **31.039** -> Potência de **16,92 MWp** = 74,60 MWh
 - **Eólico** = $207,21 - 74,60 = 132,62 \text{ MWh}$
 - Velocidade do Vento média = 6,11 m/s
 - Fator de capacidade eólico = **57,98%**
 - Potência = $132,62 / 57,98\% / 24 \text{ horas} = 9,53 \text{ MW}$
 - Aerogeradores = **6** -> Potência de **9,0 MW** = 125,23 MWh
 - Geração média diária = **199,83 MWh**
-
- **Peixe – TO**
 - Consumo diário = **62,27 MWh**
 - **Solar** = $62,27 \text{ MWh} \times 45\% = 28,02 \text{ MWh}$
 - Irradiação média = **5,364 kWh/m²**
 - Fator de geração = **4,477 kWh/kWp/dia**
 - Potência pico = $28,02 / 4,477 = 6.285.840 \text{ Wp}$
 - Placas Solares = **11.484** -> Potência de **6,26 MWp** = 28,02 MWh
 - **Eólico** = $62,27 - 28,02 = 34,25 \text{ MWh}$
 - Velocidade do Vento média = 4,45 m/s
 - Fator de capacidade eólico = **42,24%**
 - Potência = $34,25 / 42,24\% / 24 \text{ horas} = 3,38 \text{ MW}$

- Aerogeradores = 2 -> Potência de **3,0 MW** = 30,41 MWh
- Geração média diária = **58,44 MWh**

Após esta etapa, realiza-se um ajuste fino com a adição de placas solares com o objetivo de atingir a potência desejada, já que os aerogeradores são maiores e não podem ser utilizados para tal ajuste fino. Os resultados para cada cidade são os seguintes:

- **Marechal Deodoro – AL**
 - Placas adicionais: 2.900
 - **Geração Total diária = 300,87 MWh**
 - 40% Solar
 - 60% Eólica
- **Ipameri – GO**
 - Placas adicionais: 3.000
 - **Geração Total diária = 207,04 MWh**
 - 40% Solar
 - 60% Eólica
- **Peixe – TO**
 - Placas adicionais: 1.500
 - **Geração Total diária = 62,10 MWh**
 - 51% Solar
 - 49% Eólica

Com isso, o sistema final fica dimensionado buscando otimizações com as limitações técnicas apresentadas.

4.3.2 DIMENSIONAMENTO DO SISTEMA DE BATERIAS

O sistema de armazenamento do sistema deve ser dimensionado para suportar momentos de baixa geração e alta demanda, em que se pode obter falta elétrica. Para este estudo, considera-se uma demanda de 10% acima do convencional para cada município, e uma geração 10% abaixo para cada sistema, eólico e solar.

Para manter o padrão de dimensionamento, os mesmos dias utilizados para dimensionar o sistema no capítulo 4.3.1 são utilizados para dimensionar o sistema de baterias conforme proposto anteriormente.

Assim, pode-se avaliar o impacto da geração horária versus o consumo horário de cada município na *Figura 97*.

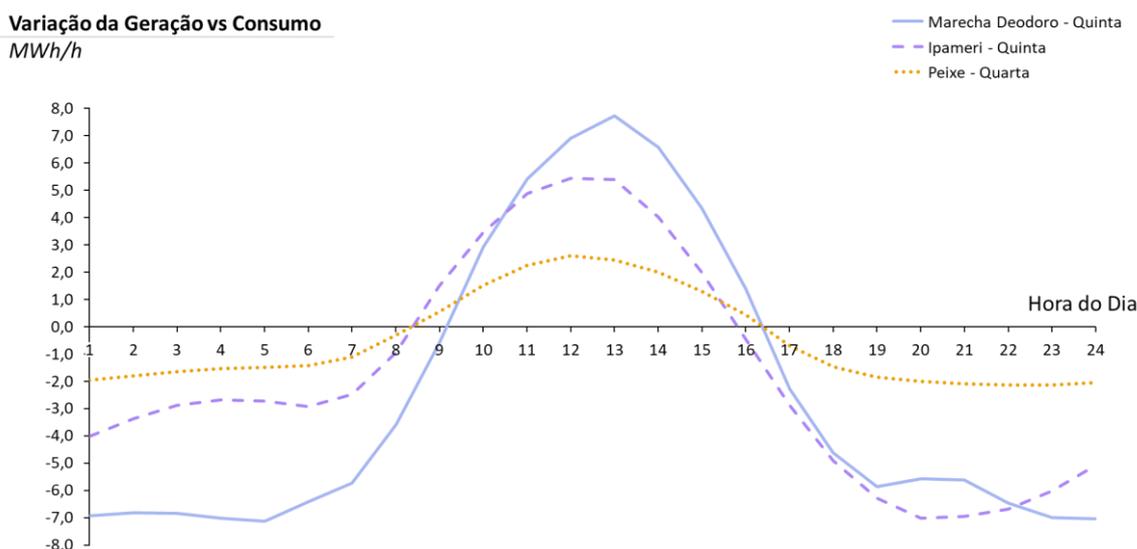


Figura 97 - Variação do Consumo de Energia vs Geração Híbrida

Para o dimensionamento da necessidade de energia do sistema é a somatória dos valores negativos apresentados para cada município, gerando a seguinte necessidade:

- Marechal Deodoro – AL: **95,52 MWh**
- Ipameri – GO: **68,28 MWh**
- Peixe – TO: **25,70 MWh**

Utilizando as mesmas baterias de Mora Montañes (2020) de chumbo-ácido, e considerando uma voltagem do sistema de 11.200 V, pode-se obter a corrente necessária para cada conjunto de baterias com a equação (21):

$$C_{ne} = \frac{\frac{E_{lack} \times F_{seg}}{P_{DeepMax}}}{V_{Batt}} \quad (21)$$

Sendo:

- C_{ne} = Corrente hora necessária para as baterias
- E_{lack} = Energia necessária
- F_{seg} = Fator de segurança, arbitrário, considerado em 1,7
- $P_{DeepMax}$ = Profundidade máxima de descarregamento, dada por 60%
- V_{Batt} = Tensão necessária para as baterias

Assim, as necessidades obtidas foram as seguintes:

- Marechal Deodoro – AL: **24.164 Ah**
- Ipameri – GO: **17.273 Ah**
- Peixe – TO: **6.502 Ah**

Cada bateria possui uma potência nominal de 2V e 3.000 Ah, fornecendo assim a seguinte quantidade total de baterias para cada município, sendo sempre 5.600 em série para fornecer a tensão de 11.200 V:

- Marechal Deodoro – AL: **45.106** baterias
- Ipameri – GO: **32.243** baterias
- Peixe – TO: **12.138** baterias

Ficando, assim, definido o dimensionamento do sistema de baterias para os municípios em estudo.

4.3.3 APLICAÇÃO DA INTELIGÊNCIA ARTIFICIAL E CONTROLE

Realizados os dimensionamentos anteriores, é possível avaliar, em simulação, quais seriam os resultados da implementação de uma inteligência artificial dentro do sistema de geração híbrida de energia.

A primeira etapa da inteligência artificial é o **Aprendizado de Máquina**. Nessa etapa utiliza-se os dados levantados anteriormente para ensinar a máquina a prever quais possíveis resultados são esperados, de acordo com os dados passados. Nesse sentido, os seguintes dados serão utilizados para teste:

- Velocidade do Vento -> Geração de Energia Eólica
- Irradiação Global Horizontal -> Geração de Energia Solar
- Consumo de Energia passado -> Consumo de Energia Futuro
- Preço de Energia passado -> Preço de energia futuro

Então, como segunda etapa deve-se implementar a lógica da **Inteligência Artificial**, seguindo o modelo proposto por Caceres (2020), neste trabalho é utilizado o algoritmo NFQI - *Neural Fitted Q Iteration*. Este modelo utiliza visa a otimização de uma função Q, via aprendizado por reforço. Adicionalmente é implementado algoritmo neural para aumentar ou diminuir o reforço com base na passagem das camadas para então, por fim, aplicar o resultado final indicando o próximo estado do sistema. A função Q, indicada, é a dada pela equação (22) (Caceres, 2020):

$$Q(s_t, a_t) = (1 - \eta) Q(s_t, a_t) + \eta \left(r + \gamma \max_{a_{t+1}} Q(s_{t+1}, a_{t+1}) \right) \quad (22)$$

Em que:

- s_t = estado no tempo atual t
- a_t = ação no tempo atual t
- η = taxa de aprendizado que deve ser maior que 0 e menor que 1
- r = recompensa obtida após executar a ação a_t
- γ = fator de desconto da recompensa futura, sendo maior que 0 e menor que 1

No caso do algoritmo *Fitted* o valor de $Q(s_t, a_t)$ pode ser aproximado.

A *Figura 98* apresenta o esquemático da implementação da inteligência artificial e seus estados de decisão.

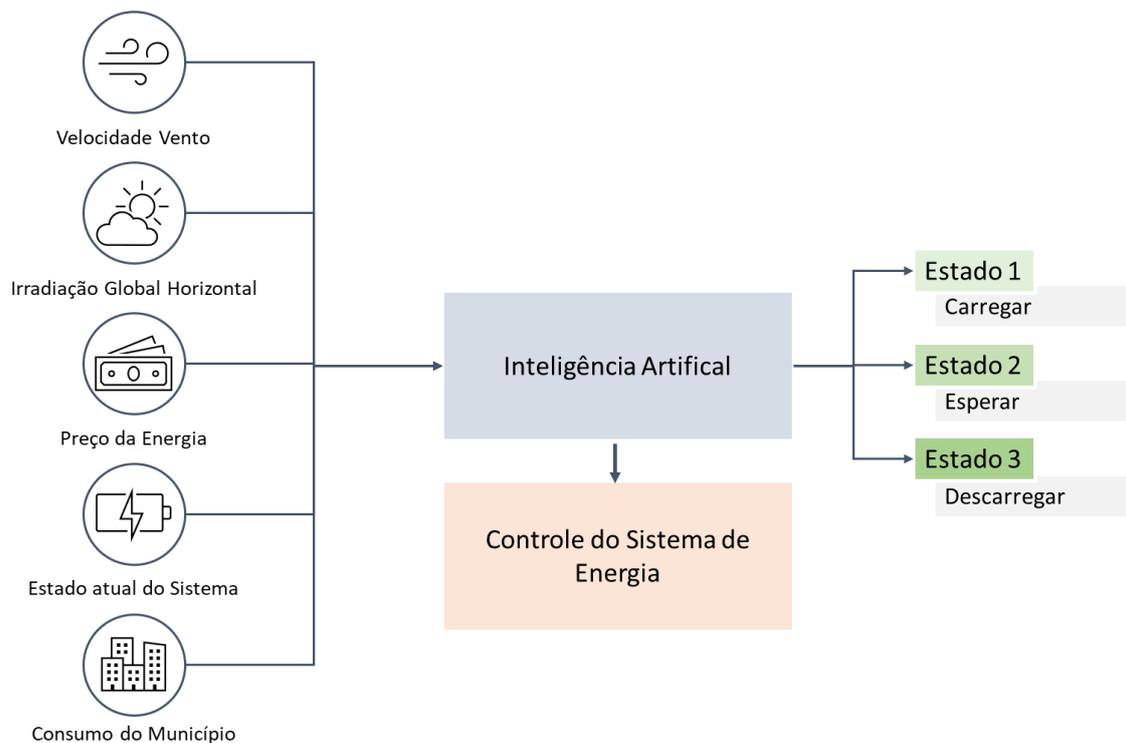


Figura 98 - Esquemático da implementação da Inteligência Artificial

A inteligência artificial, com base no sistema de aprendizado por recompensa, poderá tomar três decisões de estado futuro para o sistema, gerando o controle apenas das baterias do sistema. O controle será dado por:

- **Estado 1** – Carregar: momento em que o sistema deve carregar as baterias, sempre buscando que elas nunca estejam abaixo de 40% de carga;
- **Estado 2** – Esperar: o sistema de armazenamento se mantém estático, não carregando e nem descarregando;
- **Estado 3** – Descarregar: utiliza-se a carga do sistema de armazenamento para inserção no sistema de energia.

O interessante nesse aspecto é a inclusão da precificação da energia, com ela a inteligência artificial pode buscar a otimização dos custos versus receitas. Assim, quando a inteligência artificial der o comando do sistema, o controlador realizará a seguinte escolha:

- **Carregar**
 - $\text{Demanda} \geq \text{Geração}$: carrega o sistema de baterias com energia da rede elétrica
 - $\text{Demanda} < \text{Geração}$: carrega o sistema de baterias com a energia do sistema híbrido de geração
- **Descarregar**
 - $\text{Demanda} \leq \text{Geração}$: descarrega as baterias na rede de energia, buscando a venda dessa energia no mercado livre
 - $\text{Demanda} > \text{Geração}$: descarrega as baterias na rede do município para utilização própria

Dessa forma, o elemento financeiro consegue entrar dentro da lógica de inteligência de gestão da energia das baterias.

Por fim, os direcionadores de otimização serão os seguintes:

- **Custo de Energia**
 - Visa a ampliação das receitas com venda de energia no mercado livre e redução dos custos de compra de energia
- **Redução de CO₂**
 - Busca a redução do consumo de energia da rede, indicando um menor uso de fontes não renováveis de energia

Dessa forma, foram avaliados os cenários de implementação do projeto, selecionados os três municípios participantes localizados em diferentes partes do país e com diferentes tamanhos populacionais e de consumo de energia, sendo Marechal Deodoro – Alagoas, Ipameri – Goiás e Peixe – Tocantins. Com isso, foram levantados os dados necessários para a aplicação do sistema e tratados conforme necessidade. Por fim, apresentou-se a técnica de inteligência artificial e otimização que será aplicada no sistema. No próximo capítulo serão apresentados os modelos implementados, seus resultados e possíveis melhorias, além de propostas para projetos futuros.

5 VALIDAÇÃO COM A UTILIZAÇÃO DE MATLAB/SIMULINK

Todo o desenvolvimento da simulação foi realizado com a utilização do software Matlab-Simulink, com a aplicação da biblioteca de Aprendizagem por Reforço (*Reinforcement Learning App*). O sistema completo pode ser na *Figura 99*.

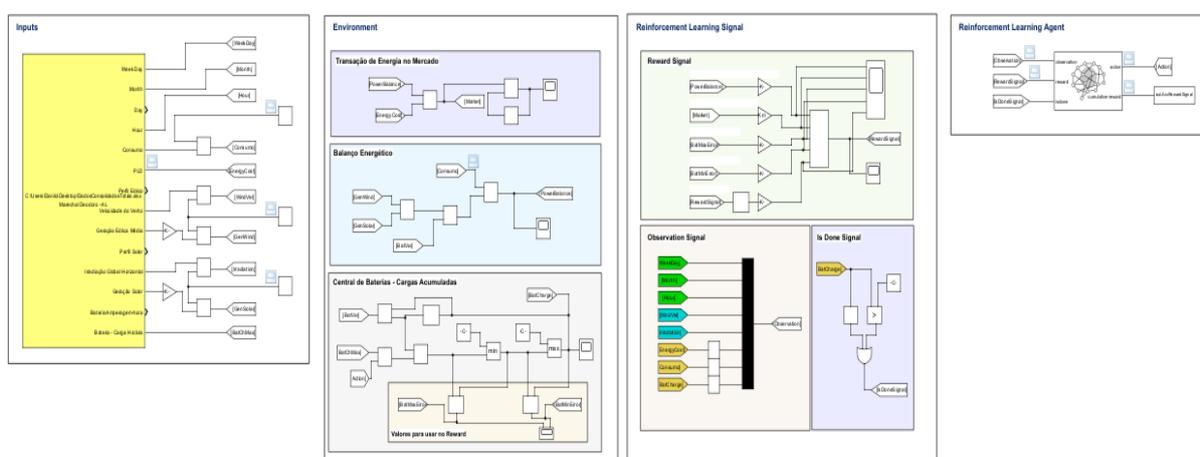


Figura 99 - Ambiente virtual desenvolvimento para a aplicação do Aprendizado por Reforço

O ambiente desenvolvido foi separado em quatro diferentes blocos, seguindo a lógica apresentada anteriormente para a aplicação de inteligência artificial via aprendizagem por reforço, contanto do o Ambiente (*Environment*), Agente (*Agent*) e Sinais de Recompensa e Observação (*Reward Signal and Observation Signal*). Para uma melhor apresentação e discussão cada bloco será apresentado separadamente.

Bloco de Inputs

O primeiro bloco abordado é referente aos inputs fornecidos ao sistema. Esses inputs são referentes aos dados levantados durante este trabalho para as três cidades em estudo. Os dados são todos referentes ao ano de 2021, em base horário, contendo assim mais de 9.500 dados de cada tipo para cada município. O bloco pode ser observado em maiores detalhes na *Figura 100*.

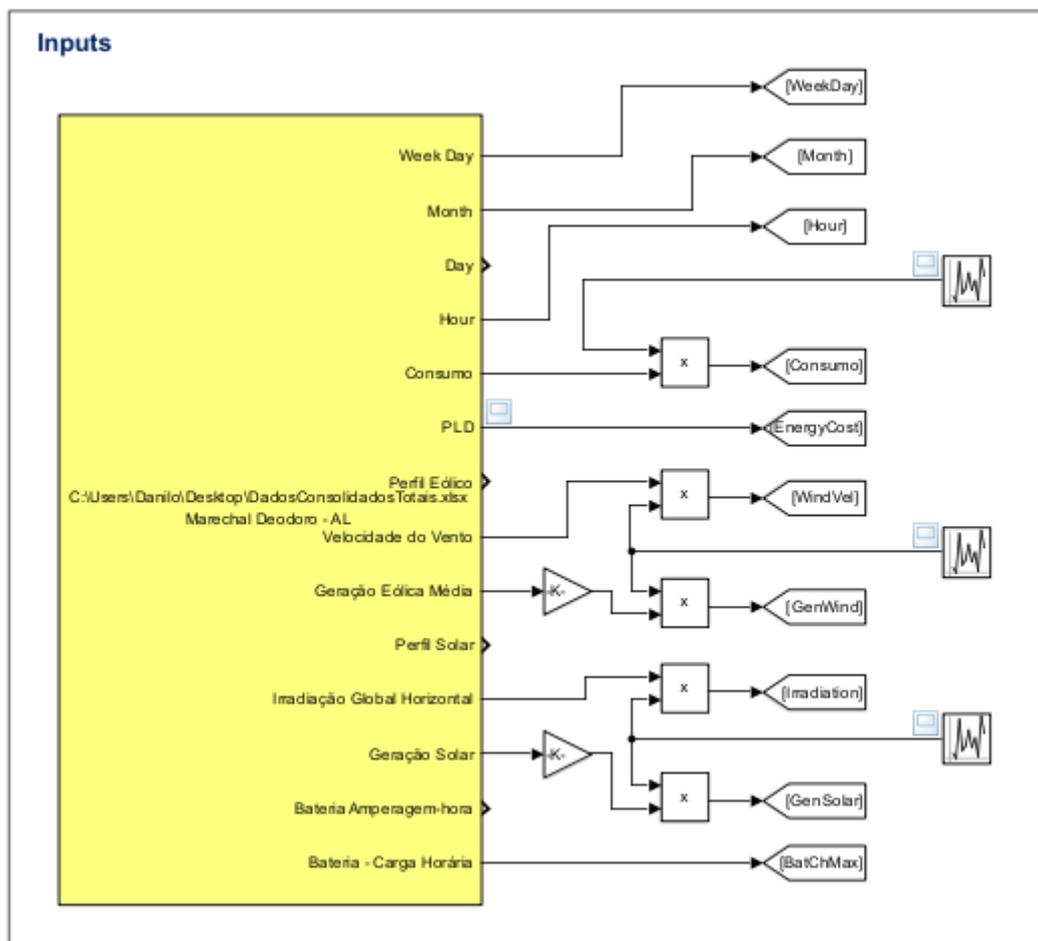


Figura 100 - Bloco referente aos dados levantados para Estudo

As informações levantadas são muito importantes para a avaliação do sistema de inteligência artificial e treinamento do agente, elas podem ser separadas em 3 grandes grupos, sendo:

- **Informações referenciais de tempo**

Nesse grupo estão presentes os 4 primeiros *outputs* do bloco, contendo as informações de:

- **Dia da semana** (*Week Day*): Variando de 0 a 6, sendo 0 sábado e 6 domingo;
- **Mês e Dia** (*Month, Day*): Indicando o mês e dia do ano, sempre em valores numéricos;
- **Horario** (*Hour*): Informação do horário do dia, variando de 0 a 23 horas.

Tais informações são importantes pela variação de geração e consumo de energia de acordo com a estação ou horário do dia, conforme constatado e observado nos

capítulos anteriores. A variável dia não é tão relevante já que o dia da semana e mês em questão fazem mais sentido para a utilização do agente na otimização.

- **Informações de Mercado e Baterias**

As duas variáveis seguintes, junto com as duas últimas contém as informações de Mercado e Baterias, respectivamente, sendo:

- **Consumo:** consta as informações de consumo horária do município em análise, as informações estão em MWh (*Megawatt-hora*);
- **PLD:** Preço Líquido das Diferenças, informa o valor horário da energia no mercado livre de energia, local em que o município pode comprar e vender energia, variável muito importante para a avaliação financeira do projeto. As informações estão em R\$/MWh (*reais por megawatt-hora*);
- **Bateria Amperagem-hora:** Informação referente ao valor de amperagem horário que a bateria pode fornecer, esse valor varia de acordo com o tamanho dimensionado das baterias para cada município, e é um valor constante dado em Ampére-hora;
- **Bateria – Carga Horária:** Valor de carga que a bateria recebe/cede no período de simulação, em uma hora, sendo carregada ou descarrega nesse montante.

As informações de amperagem da bateria não são consideradas no projeto pois apenas a carga adicional da bateria é relevante para análise, em função de simplificação. É interessante observar que tanto a carga como a descarga da bateria não são lineares, porém para a análise de viabilidade do projeto foi realizada uma simplificação, mas com possibilidade de melhorias em projetos futuros.

As informações de **consumo** possuem, ainda, um **ruído** atrelado. O objetivo desse ruído é fornecer variações no sistema para que tanto na etapa de treinamento como na de testes os valores sejam diferentes em cada rodada, esse ruído varia de mais 20% (multiplicador de 1,2) até menos 20% (multiplicador de 0,8) de forma aleatória.

- **Informações de Geração de Energia**

Este bloco contém as informações de geração de energia do sistema, tanto solar como eólica, já que a energia necessária do mercado é considerada infinita tanto para venda como para compra. Sendo:

- **Perfil Eólico / Solar:** Contém a perfil horário da geração eólica / solar em % da média diária;
- **Velocidade do Vento:** Dado em metros por segundo (m/s), indicada a velocidade do vento observada no horário correspondente;
- **Irradiação Global Horizontal:** Indica a irradiação recebida horizontalmente para a geração de energia solar, dada em quilowatt-hora por metro quadrado por dia (kWh/m²/dia);
- **Geração Eólica Média:** Apresenta a geração eólica horária, dada em megawatt-hora por hora (MWh/h). O ganho multiplicando reduz a geração de acordo com uma premissa de perdas, considerada nesse estudo em 20%;
- **Geração Solar:** Apresenta a geração solar horária, dada em megawatt-hora por hora (MWh/h). O ganho também é considerado para as perdas do sistema, sendo utilizado o valor de 20% nesse estudo.

Adicionalmente, dois **ruídos** são implementados nas informações extraídas da tabela, com o objetivo de gerar diferentes cenários para o agente realizar o aprendizado e testes. O primeiro é referente ao sinal de geração eólica, aplicado igualmente na velocidade do vento e na geração de energia eólica. O segundo é aplicado diretamente à geração solar, sendo aplicado igualmente na irradiação global horizontal e na geração solar.

Bloco *Environment* – Ambiente desenvolvido para o Aprendizado por Reforço

Este segundo bloco apresenta a modelagem do sistema que interage diretamente com o Agente, fornecendo as observações e recompensas de acordo com as ações tomadas pelo agente em cada etapa da simulação. O bloco pode ser observado em detalhes na Figura 101.

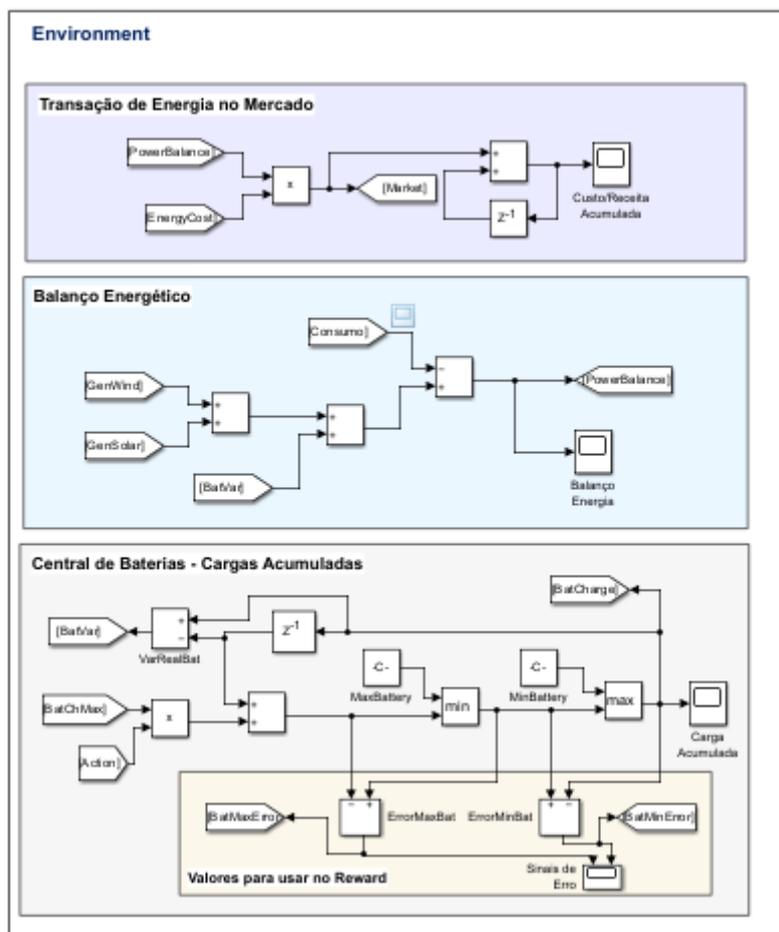


Figura 101 - Bloco de modelagem do Ambiente de interação com o Agente

O bloco é dividido em três subsistemas que interagem entre si e fornecem informações relevantes tanto para a observação como para as recompensas para o Agente. A forma mais lógica de visualização do ambiente é de baixo para cima, com as seguintes informações:

- **Central de Baterias – Carga Acumulada** (Figura 102)

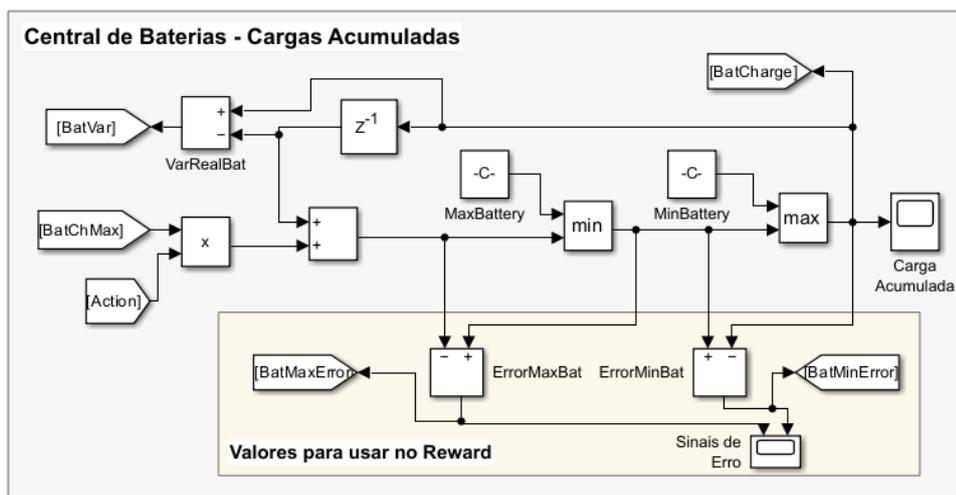


Figura 102 - Subsistema da Central de Baterias no Ambiente simulado

O sistema recebe a ação gerada pelo Agente que pode ser: (i) -1 para descarregar a bateria; (ii) 0 para não fazer nenhuma ação em relação à bateria e; (iii) +1 para carregar a bateria.

O sinal recebido é multiplicado pela carga horaria da bateria e então somado à carga anterior, gerando, dessa forma, a carga acumulada na bateria.

Existem dois limitantes para a carga da bateria, sendo a carga máxima, que representa 100% da capacidade, e a carga mínima, que representa 60% da capacidade. Caso a bateria ultrapasse esses valores, a diferença é enviada para o sinal de erro e posteriormente para o cálculo da recompensa.

- **Balanco Energético** (Figura 103)

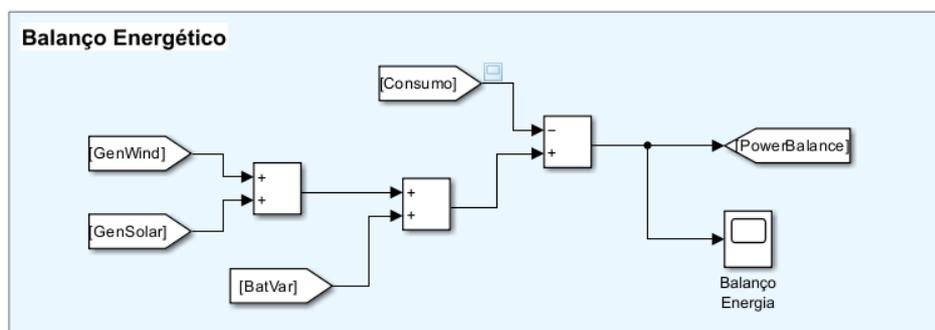


Figura 103 - Subsistema de Balanço Energética do Ambiente simulado

O subsistema de balanço energético recebe as informações de geração interna tanto do sistema eólico como solar e gera, assim, a energia total do sistema. Adicionalmente é incluída a energia da central de baterias, que pode ser negativa, em caso de carregamento, ou positiva, em caso de descarregamento.

Por fim, desconta-se o consumo horário da localidade gerando então o balanço energético de mercado, podendo ser um valor positivo, representando a venda de energia para o sistema, ou negativo, representando a compra de energia para o sistema.

- **Transação de Energia no Mercado** (Figura 104)

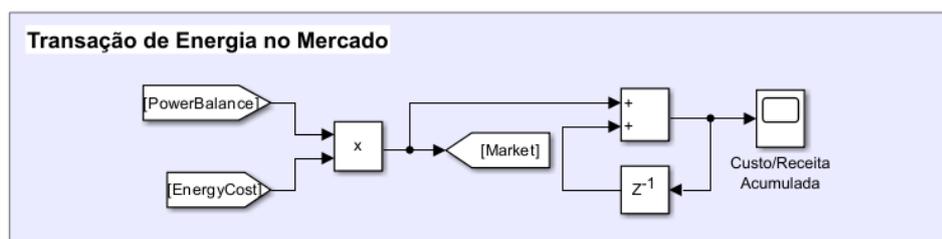


Figura 104 - Subsistema de Transação de Energia no Mercado para o Ambiente Simulado

Este bloco corresponde à transformação do balanço energético de energia em reais, avaliando o custo dessa energia no horário correspondente e convertendo a energia interna do sistema em venda ou compra, o valor é dado diretamente em reais.

Bloco Reinforcement Learning Signals

Este bloco foca na construção dos sinais que são enviados para o Agente a partir da relação da ação com o ambiente, conforme apresentado na Figura 105. A seguir serão descritos cada um dos três subsistemas presentes nesse bloco.

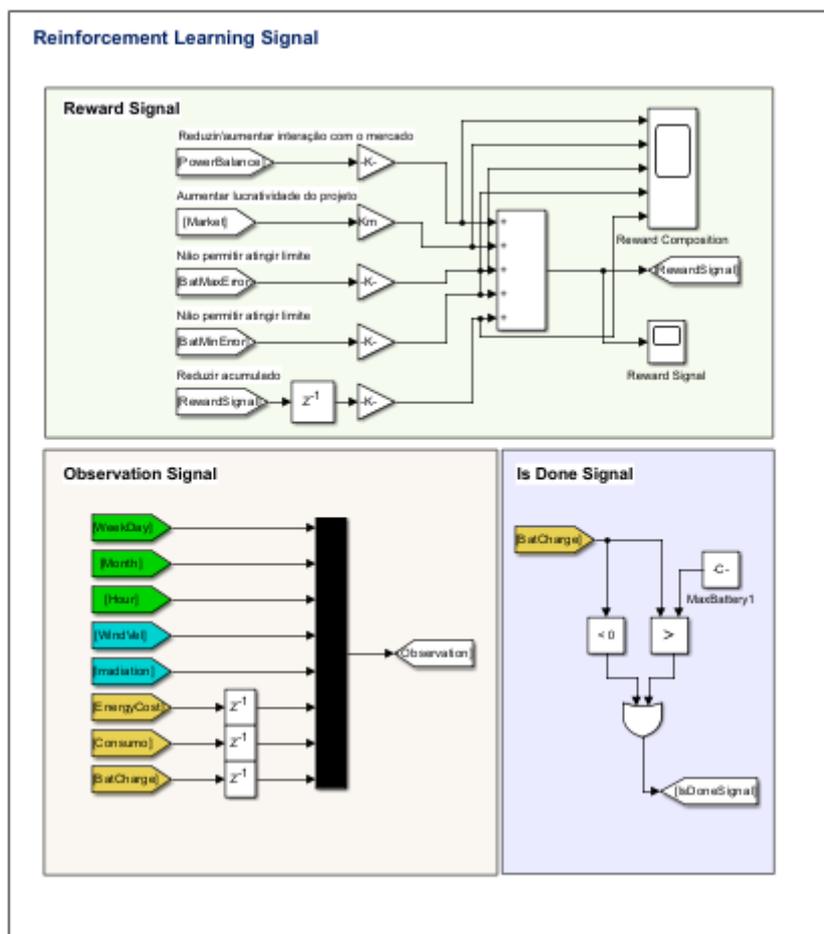


Figura 105 - Bloco de Sinais para o Aprendizado por Reforço

- **Reward Signal** – Sinal de recompensa

O sinal de recompensa é composto por cinco fatores, sendo:

- **Balanco energético** (*Power Balance*): Visa incentivar o agente á produzir um sistema mais autônomo, sem muita interação com o ambiente externo. Apesar de reduzir o ganho financeiro potencial, aumenta a autonomia das cidades e consequentemente a capilaridade da aplicação em outras localidades;
- **Lucratividade / Prejuízo** (*Market*): Busca a lucratividade do sistema incentivando o Agente a vender a energia quando estiver cara, e comprar quando estiver barata, utilizando a central de baterias como um *buffer*;

- **Erro Máximo da Bateria:** Desincentiva que o Agente carregue a bateria quando ela está totalmente ou quase totalmente carregada, evitando assim, perda de energia;
- **Erro Mínimo da Bateria:** Desincentiva o Agente a descarregar a bateria em caso de baixa carga, evitando problemas de fornecimento de energia e falta de planejamento energético;
- **Sinal de Reforço passado (*Reward Signal*):** Auxilia o Agente a buscar o aumento global do sinal de reforço.

Cada sinal possui um multiplicador que é alterado de acordo com o objetivo de otimização de cada projeto, aumentando a flexibilidade do sistema.

- **Sinal de Observação (*Observation Signal*)**

O sinal de observação apresenta para o Agente as informações disponíveis no início da etapa de simulação, para que ele possa tomar as decisões de acordo com tais informações e, posteriormente, consiga observar o resultado via sinal de reforço. Esse sinal é formado por três partes, sendo:

- **Parte temporal:** composto pelas informações de dia da semana (*Week Day*), mês (*Month*) e horário (*Hour*);
- **Variáveis naturais para geração de energia:** composto pelas informações de velocidade do vento e irradiação global horizontal;
- **Variáveis históricas:** Composto pela última informação do preço de energia (*Energy Cost*), Consumo e Carga da Bateria.

- **Sinal de Finalização do Episódio (*Is Done*)**

Este sinal é utilizado pelo agente para a finalização da simulação. Ele é muito utilizado em caso de sistemas que buscam atingir um *setpoint* ou realizar o controle de algum sistema, assim quando tal controle é obtido ou atingido por determinado tempo, a simulação pode ser parada.

No caso desse projeto, o motivo de parada deve ocorrer se a bateria atingir mais que 100% de carga ou menos que o mínimo, algo que não ocorre devido às restrições de controle já estabelecidas.

Bloco do Agente de Aprendizado por Reforço (*Reinforcement Learning Agent*)

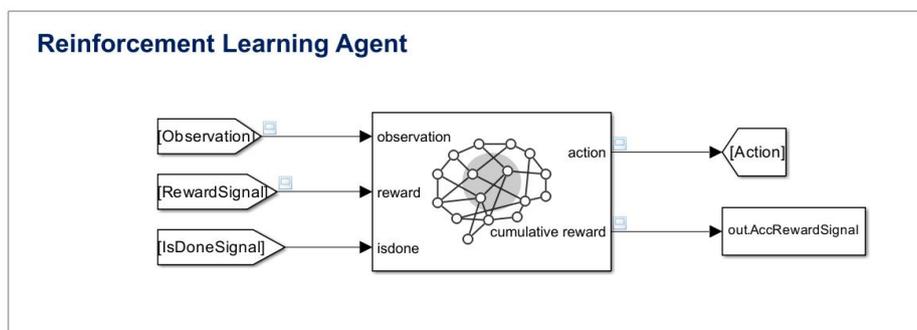


Figura 106 - Bloco para o Agente do Aprendizado por Reforço

O bloco apresentado pela Figura 106 apresenta o agente de aprendizado por reforço da biblioteca do Matlab/Simulink. Esse bloco recebe as informações do sinal de Observação (contínuo), do sinal de reforço (variável escalar) e do sinal *Is Done* (binário).

Dentro do bloco existem mais dois blocos que são os responsáveis pela política de escolha das ações do agente e o crítico, que realiza um estudo prévio para estimar o sinal de recompensa final do episódio. Assim, geram-se os sinais de ação (discreto, variando entre -1, 0 e +1) e o sinal acumulado de recompensa.

Nesse estudo foi aplicado o Agente já descrito anteriormente, chamado de DQN (*Deep Q-Network*) que utiliza redes neurais para estimar o retorno do agente, dadas as informações do sinal de observação, e assim busca a ação que otimiza o retorno total. Por padrão, são utilizadas 256 camadas internas da rede neural e o treinamento é realizado com a *Toolbox Reinforcement Learning Design* do Matlab, com a inclusão do ambiente apresentado anteriormente.

É interessante observar que no caso em que apenas são aplicadas as fontes renováveis planejadas, mas sem a utilização de uma inteligência artificial com o atributo de um buffer, representado pela central de baterias, os municípios apresentam altas perdas financeiras no decorrer de um ano, conforme apresentado na Figura 107.

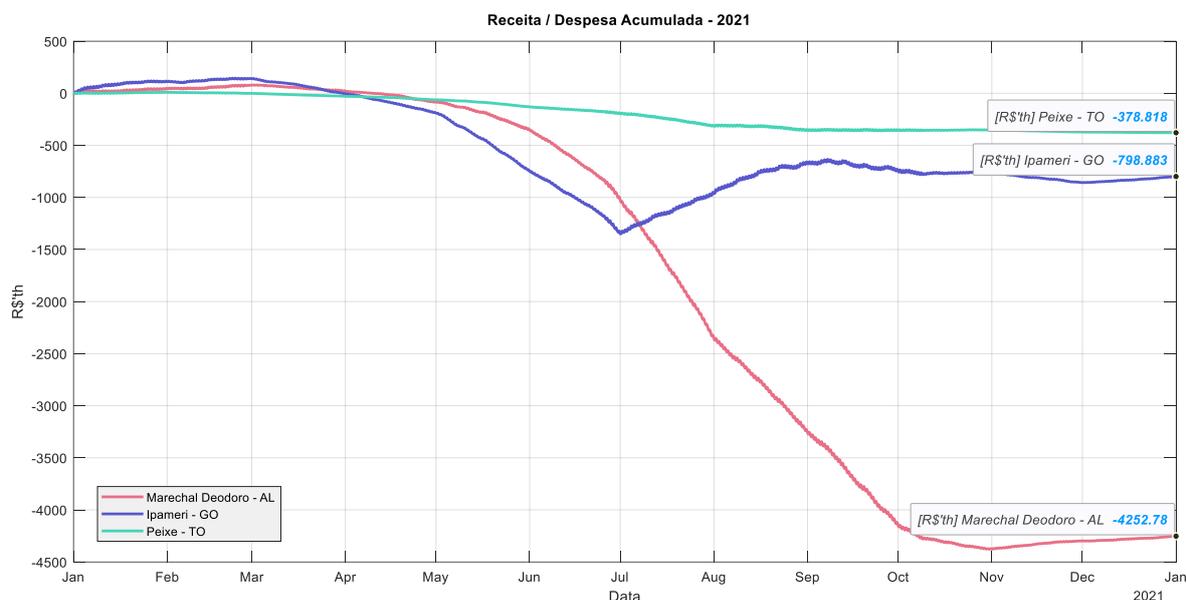


Figura 107 - Avaliação das despesas em um ano para cada município sem a IA

As cidades atingiriam as seguintes despesas acumuladas ao longo de um ano, nesse caso o ano de 2021:

- Marechal Deodoro – AL: R\$ 4.252,78 mil
- Ipameri – GO: R\$ 798,88 mil
- Peixe – TO: R\$ 378,82 mil

Somando-se um prejuízo de aproximadamente 5,1 milhões de reais por ano aos cofres públicos.

Adicionalmente, nesse mesmo cenário, pode-se observar o potencial aumento de consumo de CO_2 pelo uso de energia da rede comum, já que essa energia não possui procedência garantida e pode vir de usinas térmicas, principalmente, conforme visto nos capítulos anteriores, quando o preço da energia está maior. Alguns dados interessantes de serem observados nesse período de um ano:

- **Marechal Deodoro – AL**
 - Tempo utilizando energia da rede: **61,7%**
 - Quantidade de energia utilizada da rede no total do município: **61,4%**
- **Ipameri – GO**
 - Tempo utilizando energia da rede: **63,0%**
 - Quantidade de energia utilizada da rede no total do município: **57,6%**

- **Peixe – TO**

- Tempo utilizando energia da rede: **64,2%**
- Quantidade de energia utilizada da rede no total do município: **58,0%**

Tais valores indicam o uso excessivo da rede externa de energia e forte dependência dessa, o que não garante as metas de receita e nem de geração limpa sustentável.

Com a implementação da inteligência artificial, aliada à central de baterias, que funciona como um buffer de energia para o sistema, é visível a melhora no uso dos recursos naturais e autonomia dos municípios analisados.

A Figura 108 apresenta a evolução da receita acumulada para todas as cidades no período de um ano, considerado dados reais de 2021 conforme levantado anteriormente. Nesses cenários foram observados um controle conservador, em que não é considerada a compra de energia no sistema e sim o carregamento da bateria no momento de baixo consumo e alta geração e a utilização dele no momento de alto consumo e baixa geração, com a consequente venda da energia sobressalente no mercado à preços horários, sem o comprometimento da central de baterias.

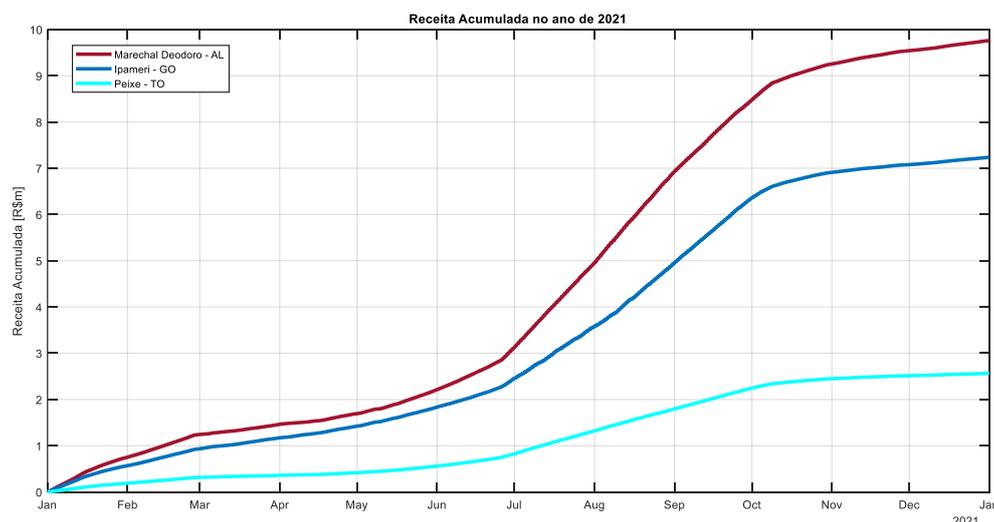


Figura 108 - Receita acumulada com o uso de baterias

Gerando as seguintes receitas:

- Marechal Deodoro – AL: R\$ 9.762,24 mil
- Ipameri – GO: R\$ 7.236,68 mil

- Peixe – TO: R\$ 2.565,10 mil

Porém, esses valores são atingidos considerando apenas o uso da central de baterias no decorrer de um ano, o que implica que a central inicia com o carregamento máximo, e finaliza o ano com cerca de 55% de sua carga, sendo um problema para o uso no ano seguinte, conforme apresentado na Figura 109.

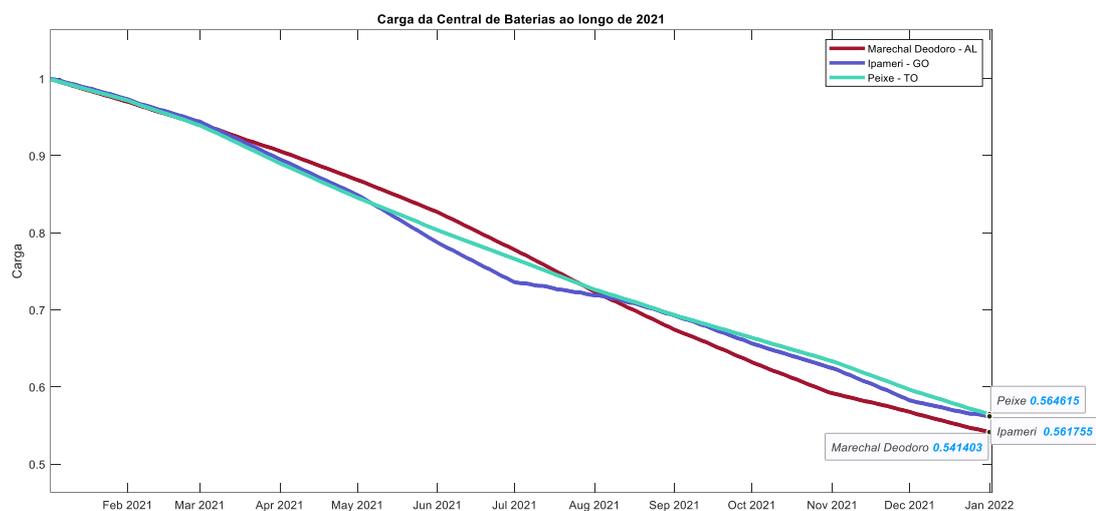


Figura 109 - Carga acumulada na Central de Baterias em 2021

Utilizando a otimização para que sempre que for possível a central de baterias seja recarregada, é possível melhorar muito a condição vista anteriormente para um cenário em que o carregamento ao final do ano da central seja acima de 70%, conforme apresentado na Figura 110.

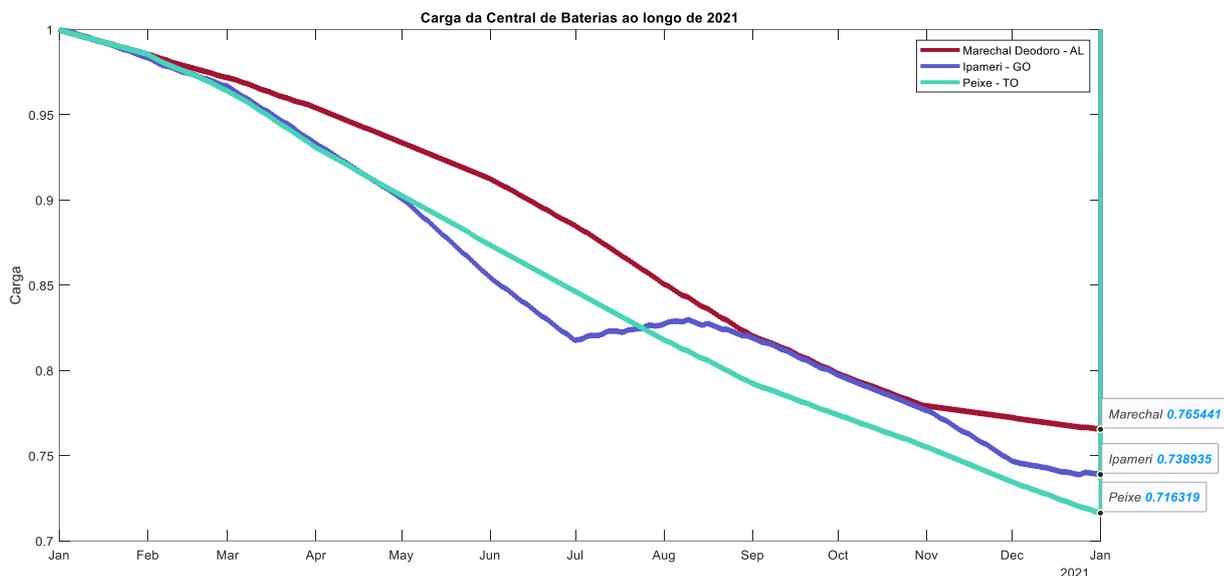


Figura 110 - Carregamento da Central de Baterias Otimizado

Com isso, as receitas acumuladas dos municípios são reduzidas, porém ainda atingindo valores significativos. Para compensar o delta final de carregamento da central de baterias, é considerada uma compra adicional de energia no mercado, correspondente ao preço médio do último mês de operação, nesse caso em dezembro de 2021, conforme apresentado na Figura 111.

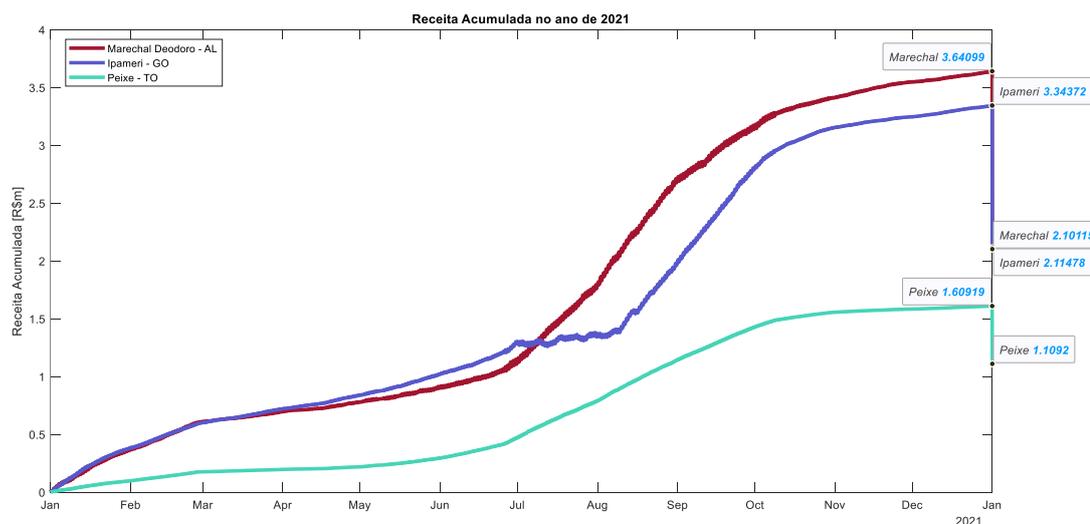


Figura 111 - Receita acumulada durante o ano de 2021 com compra de energia remanescente

Gerando, assim, os seguintes valores finais para cada município:

- Marechal Deodoro – AL: R\$ 2.101,15 mil
- Ipameri – GO: R\$ 2.114,78 mil
- Peixe – TO: R\$ 1.109,20 mil

Adicionalmente, o outro objetivo buscado que era a redução na emissão de gases de efeito estufa com o menor uso de energia da rede comum também foi atingido, conseguindo obter valores próximos de 33% do uso da rede no total de energia consumida, sendo:

- Marechal Deodoro – AL: 33,5%
- Ipameri – GO: 33,1%
- Peixe – TO: 38,0%

O agente para fazer as escolhas horárias necessários apresentou as seguintes relações de tempo entre carga e descarga para cada um dos cenários observados:

- Marechal Deodoro – AL
 - Carga: 38,3%
 - Descarga: 61,7%
- Ipameri – GO
 - Carga: 62,9%
 - Descarga: 37,1%
- Peixe – TO
 - Carga: 64,2%
 - Descarga: 35,8%

Mostrando que no município mais populacional o sistema de baterias é mais utilizado, devido às variações e condições de consumo e geração dessa localidade.

Por fim, pode-se avaliar a possibilidade máxima de gasto para a implementação do sistema elétrico nos municípios, de acordo com a receita acumulado e utilizando a fórmula de valor presente com a taxa de retorno de 9,25% (taxa de juros básica, Selic, de janeiro de 2021), sendo:

- Marechal Deodoro – AL: R\$ 2,07 milhões
- Ipameri – GO: R\$ 2,07 milhões
- Peixe – TO: R\$ 1,08 milhões

6 CONCLUSÕES

Para as conclusões, as análises serão divididas em duas partes, sendo a primeira referente às conclusões do trabalho e a segunda referente às perspectivas futuras observadas.

Conclusões do trabalho

O projeto demonstrou um alto potencial de otimização da geração de energia híbrida renovável para todos os tamanhos populacionais, necessitando de investimentos maiores ou menores para cada caso de acordo com a estrutura das usinas implementadas.

A implementação do sistema histórico com a utilização de software computacional tornou mais clara e visual a aplicação da Inteligência Artificial na indústria de energia, além de demonstrar a validação das premissas utilizadas e levantadas durante todo o processo. O impacto das variáveis naturais como Velocidade do Vento e Irradiação Global Horizontal em conjunto com as variações do mercado livre de energia tornaram o projeto viável de ser implementado nas mais diversos localidades que integram o Sistema Integrado Nacional de energia, abrindo, dessa forma, a possibilidade de uma maior migração das cidades para a energia limpa e autonomia energética.

O banco de baterias apresentou resultados muito interessantes para o desenvolvimento do projeto, proporcionando a otimização da geração e interpolação com o mercado, conseguindo atingir reduções da utilização da rede externa em até 55% (caso de Marechal Deodoro – AL) e aumento significativo nas receitas que, sem a implementação, geravam prejuízos na ordem de milhões e passaram a gerar lucros na mesma ordem.

É importante observar que tal possibilidade de interação com o mercado livre de energia faz com que tais projetos sejam viáveis para os municípios, apresentando valores altos para a implementação do projeto com resultados de *payback* em até um ano, conforme apresentado anteriormente, sendo:

- Marechal Deodoro – AL: R\$ 2,07 milhões
- Ipameri – GO: R\$ 2,07 milhões
- Peixe – TO: R\$ 1,08 milhões

O projeto demonstra um grande avanço no setor energético brasileiro, dado o aumento da necessidade de energia e a variação da demanda cada vez mais imprevisível pelos avanços tecnológicas como a Indústria 4.0, Veículos Autônomos e Elétricos, 5G, etc., nota-se o potencial ganho com a aplicação de inteligência nos sistemas elétricos e no uso de energia, preservando recursos naturais e reduzindo gastos desnecessários.

Observa-se que a aplicação em *Matlab/Simulink* apresenta grande apelo visual e didático, porém necessita de alto tempo de processamento para o treinamento dos agentes de inteligência artificial, com durações que variaram de 2 a 12 horas para atingir a convergência. Nesse sentido, visando uma otimização de tempo, torna-se interessante a aplicação de software matemáticos de programação, como o *python*.

Perspectivas Futuras

Apesar do grande potencial observado com o estudo, é possível ainda implementar melhorias futuras para a obtenção de novos resultados, como:

- **Treinamento de longo prazo da inteligência artificial**

Pode-se realizar treinamento mais longos e por períodos maiores com a inteligência artificial com o objetivo de obter um sistema mais robusto que faça aquisição de energia em momentos de baixo preço e venda em momentos de alto preço. Tal previsibilidade é possível graças a forma como o planejamento de precificação é realizado no Brasil, sendo via softwares que se baseiam na previsão pluviométrica para cada período;

- **Implementação de previsão dos dados**

Com a utilização de técnicas de *Machine Learning* pode-se implementar a previsão dos dados futuros, fazendo com que o sistema de inteligência artificial trabalhe de forma mais robusta e gerando melhores resultados;

- **Autonomia das cidades**

É possível obter autonomia das cidades, se esse for o objetivo de algum município devido ao não acesso ao sistema único de energia, com a implementação de sistemas complementares ao solar e eólico, que possibilitem a geração de energia excedente, sem necessitar de rede externa;

- **Obtenção de dados reais por períodos maiores**

A dificuldade no acesso aos dados de cada região faz com que o treinamento do agente de inteligência artificial não seja ótimo, assim com a utilização de dados reais confiáveis e por longos períodos pode-se gerar agentes mais bem treinados.

Por fim, existem diversos temas que desdobram desse trabalho e podem partir dos resultados dele, como sugestão estão os seguintes:

- **Implementação de outras fontes de energia**

Os estudos de fontes de geração diversas estão evoluindo cada vez mais, e com isso novas tecnologias surgem a todo o momento. Seria interessante observar os impactos da implementação de demais fontes de geração, incluindo as de geração distribuída (Solar e Eólica), em que o gasto inicial do município seria menor, já que cada residência teria sua própria fonte de energia.

- **Estudo da aplicação da inteligência artificial na geração de Hidrogênio Verde**

O Hidrogênio verde é resultado da implementação de plantas de produção de hidrogênio, a partir da hidrólise da água, com o uso exclusivo de fontes renováveis de energia. Esse tema possui diversos desdobramentos, pois com o Hidrogênio é possível exportar energia, estocar e utilizar como combustíveis de alto rendimento.

- **Aplicação das técnicas avançadas de controle de sistemas junto com a inteligência artificial**

Existem diversas técnicas de controle de sistemas que podem ser utilizados em conjunto com a inteligência artificial para a evolução do sistema proposto. Os controladores são dimensionados para tratar distúrbios no sistema e variações

imprevistas de componentes de forma automática, o que pode auxiliar na filtragem das informações vistas pela IA.

Pode-se, então, observar que os temas de Geração de Energia e Inteligência Artificial são complementares e podem ser trabalhados em diversas frentes com alto potencial para projetos futuros, considerando os resultados já obtidos até esse momento que demonstram que a intersecção dos temas apresenta alta correlação e benefícios perceptíveis.

REFERÊNCIAS

Alagoas em Dados e Informações – Secretaria do Estado de Planejamento, Gestão e Patrimônio – Governo de Alagoas. Maceió – AL. Acesso em: 12/01/2023. Disponível em: <https://dados.al.gov.br/catalogo/dataset/dados-de-infraestrutura-perfil-municipal/resource/752068b9-fb1e-47f6-a597-074fa260af71>

Ali, Md Jishan; Ashim Mondal; Pallav, Dutta. "Intelligent Monitoring and Control of Wind Turbine Prototype Using Internet of Things (IoT)." 2022 IEEE International IOT, Electronics and Mechatronics Conference (IEMTRONICS). IEEE, 2022.

ALMALAQ, Abdulaziz; ZHANG, Jun Jason. Deep learning application: Load forecasting in big data of smart grids. In: Studies in Computational Intelligence. [s.l.]: Springer Verlag, 2020. v. 865p. 103–128. DOI: 10.1007/978-3-030-31760-7_4.

BACCI, Tiziano; CONTE, Stefano; MATERA, Domenico; MATTIA, Sara; VENTURA, Paolo. A New Software System for Optimizing the Operations at a Container Terminal. In: DELL'AMICO, Mauro; GAUDIOSO, Manlio; STECCA, Giuseppe (org.). A View of Operations Research Applications in Italy, 2018. Cham: Springer International Publishing, 2019. p. 41–50. DOI: 10.1007/978-3-030-25842-9_4.

BUÉ, Martin; CATTARUZZA, Diego; OGIER, Maxime; SEMET, Frédéric. A Two-Phase Approach for an Integrated Order Batching and Picker Routing Problem. In: DELL'AMICO, Mauro; GAUDIOSO, Manlio; STECCA, Giuseppe (org.). A View of Operations Research Applications in Italy, 2018. Cham: Springer International Publishing, 2019. p. 3–18. DOI: 10.1007/978-3-030-25842-9_1. Disponível em: http://link.springer.com/10.1007/978-3-030-25842-9_1.

Caceres Florez, Camilo Andres. Proposta metodológica de otimização baseada em IA, ciência de dados e indústria 4.0. estudo de casos: serviços de emergência em e-hospital e sistema de gerenciamento de energias híbridas. – Campinas, SP: [s.n.], 2020.

CARVALHO, Iasmim Mayara Libório; RUZENE, Denise S.; SILVA, Daniel Pereira. Análise dos Impactos da Energia Eólica. VIII Simprod, Sergipe. 2016. Disponível em: <https://ri.ufs.br/bitstream/riufs/7726/2/AnaliseImpactosEnergiaEolica.pdf>. Acesso em: 02 de maio de 2023.

CCEE, Câmara de Comercialização de Energia Elétrica. Disponível em: <https://www.ccee.org.br/>. 2022

CEPEL. Atlas Eólico Brasileiro: Simulações 2013. Rio de Janeiro: Centro de Pesquisa de Energia Elétrica, 2013. Disponível em: <http://novoatlas.cepel.br/>.

Churchman, Charles W.; Ackoff, Russell L.; Arnoff, E. Leonard. Introduction to Operations Research. 645p. Wiley, 1957.

CONCOLATO, Claude E.; CHEN, Li M. Data Science: A New Paradigm in the Age of Big-Data Science and Analytics. *New Mathematics and Natural Computation*, [S. l.], v. 13, n. 2, p. 119–143, 2017. DOI: 10.1142/S1793005717400038.

Elsayed, A. M., & Farghaly, M. B.. Theoretical and numerical analysis of vortex bladeless wind turbines. *Wind Engineering*, 0309524X221080468. 2022.

ENGELBRECHT, Andries P. Computational intelligence: an introduction. [s.l.] : John Wiley & Sons, 2007.

EPE, ANUÁRIO ESTATÍSTICO DE ENERGIA ELÉTRICA 2020. Disponível em: <https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-160/topico-168/EPEFactSheetAnuario.pdf>., 2020.

Fundação ABC. SMA: Sistema de Monitoramento Agrometeorológico. 2022. Acesso em: 25/01/2023. Disponível em: <https://sma.fundacaoabc.org/monitoramento/grafico/mensal>

GENTILI, M.; GERBER, E.; GUE, K. From Pallets to Puppies: Using Insights from Logistics to Save Animals. In: DELL'AMICO, Mauro; GAUDIOSO, Manlio; STECCA, Giuseppe (org.). *A View of Operations Research Applications in Italy*, 2018. Cham: Springer International Publishing, 2019. p. 133–140. DOI: 10.1007/978-3-030-25842-9_10.

HASSANI, Hossein; SILVA, Emmanuel Sirimal. Forecasting with Big Data: A Review. *Annals of Data Science*, [S. l.], v. 2, n. 1, p. 5–19, 2015. DOI: 10.1007/s40745-015-0029-9.

HUGGINS, Robert A. *Energy Storage: Fundamentals, Materials and Applications*. 2ed. Springer, Stanford, CA, USA, 2016

IEA, *Electricity Information 2022*, IEA, Paris. Disponível em: <https://www.iea.org/fuels-and-technologies/electricity>. 2022.

IEA, *Global share of total energy supply by source*, IEA, Paris. Disponível em: <https://www.iea.org/data-and-statistics/charts/global-share-of-total-energy-supply-by-source-2019>. 2019.

IMB - Instituto Mauro Borges de Estatísticas e Estudos Socioeconômicos / Secretária-geral da Governadoria / Governo de Goiás. Goiânia – GO. Acesso em: 12/01/2023. Disponível em: https://www.imb.go.gov.br/bde/imp.php?page=consulta&action=var_list&busca=Energia

IPCC – Ottmar Edenhofer, Ramón Pichs-Madruga, Youba Sokona, Kristin Seyboth, Patrick Matschoss, Susanne Kadner, Timm Zwickel, Patrick Eickemeier, Gerrit Hansen, Steffen Schloemer, Christoph von Stechow (Eds.) Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, 1075 pp. Available from Cambridge University Press, The Edinburgh Building Shaftesbury Road, Cambridge CB2 2RU ENGLAND. 2011.

IRENE. *Renewable Power Generation Costs in 2020*, International Renewable Energy Agency, Abu Dhabi. Disponível em: <https://www.irena.org/Data/View-data-by-topic/Costs/Global-Trends>. 2021.

J.A. Cornuéjols, L. Miclet, Y. Kodratoff : Apprentissage artificiel : concepts et algorithmes, Eyrolles, 2002.

KONRAD, Renata A.; TRAPP, Andrew C.; PALMBACH, Timothy M.; BLOM, Jeffrey S. Overcoming human trafficking via operations research and analytics: Opportunities for methods, models, and applications. *European Journal of Operational Research*, [S. l.], v. 259, n. 2, p. 733–745, 2017. DOI: 10.1016/j.ejor.2016.10.049.

LEVY, Maria Carolina P. Mercados de Energia Elétrica: questões conceituais e modelos de precificação nodal e zonal – uma análise do mercado brasileiro. Itajubá – MG. 2007.

MATLAB, Reinforcement Learning Toolbox: Design and train policies using reinforcement learning. Disponível em: <https://www.mathworks.com/products/reinforcement-learning.html>. Acesso em: 02 de abril de 2023, 2023.

MAUAD, Frederico F.; FERREIRA, Luciana C.; TRINDADE, Tatiana C. G. Energia Renovável no Brasil: Análise das principais fontes energéticas renováveis brasileiras. São Carlos, EESC/USP, 2017.

MESQUITA, Daniel; Principais problemas encontrados em módulos fotovoltaicos. Disponível em: <https://canalsolar.com.br/principais-problemas-encontrados-em-modulos-fotovoltaicos/>. Acesso em: 02 de maio de 2023. 2020.

Miranda, António Manuel, “Tecnologias de Armazenamento de Energia – Identificação do Potencial e Aplicações”, Dissertação de Mestrado em Engenharia Eletrotécnica e de Computadores, FEUP, 2011.

MME, Conheça as instituições do setor elétrico brasileiro e as competências de cada uma. Disponível em: <https://www.gov.br/mme/pt-br/assuntos/noticias/conheca-as-instituicoes-do-setor-eletrico-brasileiro-e-as-competencias-de-cada-uma>. Acesso em: 10 de dezembro de 2022. 2021.

MOMOH, James A. Electric power system applications of optimization. 2. ed. [s.l.] : CRC Press, 2017. DOI: 10.1201/9781315218953.

NILSSON, Nils J. The Quest for Artificial Intelligence: a history of ideas and achievements. Cambridge, United States: Cambridge University Press, 2009

ONS, Operador Nacional do Sistema Elétrica. Disponível em: <https://www.ons.org.br/>. 2022.

PARRIANI, Tiziano; POZZI, Matteo; VIGO, Daniele; CRUIJSSEN, Frans. Creation of Optimal Service Zones for the Delivery of Express Packages. In: DELL'AMICO, Mauro; GAUDIOSO, Manlio; STECCA, Giuseppe (org.). A View of Operations Research Applications in Italy, 2018. Cham: Springer International Publishing, 2019. p. 19–28. DOI: 10.1007/978-3-030-25842-9_2.

PEREIRA, E. B.; MARTINS, F. R.; GONÇALVES, A. R.; COSTA, R. S.; LIMA, F. J. L.; RÜTHER, R.; ABREU, S. L.; TIEPOLO, G. M.; PEREIRA, S. V.; SOUZA, J. G. Atlas brasileiro de energia solar. São José dos Campos: INPE, 2017. 88 p. ISBN 978-85-17-00090-4. IBI: <8JMKD3MGP3W34P/3PERDJE>. Disponível em: <<http://urlib.net/ibi/8JMKD3MGP3W34P/3PERDJE>>.

PORTAL SOLAR, Energia Solar: Desvantagens. Disponível em: <https://www.portalsolar.com.br/energia-solar-desvantagens>. Acesso em: 02 de maio de 2023.

PORTO, Talita. Mercado Livre de Energia: cenário atual, perspectivas e oportunidades. Disponível em: https://www.ccee.org.br/documents/80415/919440/20221013_Mercado%20Livre_LIDE.pdf/b6c0473d-02eb-a4fc-fd14-ff30ad650805. 2022.

ROSARIO, J.M.: Machine Learning for Engineer – Notes – ESILV – École Supérieure d'IngénieurLeonard de Vinci, France, 2020.

ROSARIO, J.M.: Princípios da Mecatrônica, Editoria Prentice-Hall, 2001.

RUSSELL, Stuart; NORVIG, Peter. Artificial intelligence: a modern approach. 3. ed. Harlow, England: Pearson, 2009.

Secretaria do Planejamento e Orçamento / Governo do Estado Tocantins. Perfil Socioeconômico Municipal – Peixe, 2021. Palmas – TO. Acesso em: 12/01/2023. Disponível em: <https://central.to.gov.br/download/285175>

SONG, Il-Yeol; ZHU, Yongjun. Big Data and Data Science: Opportunities and Challenges of iSchools. Journal of Data and Information Science, [S. l.], v. 2, n. 3, p. 1–18, 2017. DOI: 10.1515/jdis-2017-0011. Disponível em: <http://content.sciendo.com/view/journals/jdis/2/3/article-p1.xml>.

Thomas Mitchell, Machine Learning, McGraw-Hill, Science/Engineering/Math, 1997.

VERMEULEN, Andreas François. Industrial Machine Learning. Berkeley, CA: Apress, 2020. DOI: 10.1007/978-1-4842-5316-8. Disponível em: <http://link.springer.com/10.1007/978-1-4842-5316-8>.

WEYANT, John P. Energy policy applications of operations research Handbooks in Operations Research and Management Science, 1994. DOI: 10.1016/S0927-0507(05)80089-1.

WWF, Efeito Estufa e Mudanças Climáticas. Disponível em: https://www.wwf.org.br/nossosconteudos/educacaoambiental/conceitos/efeitoestufa_e_mudancasclimaticas/. Acesso em: 08 de dezembro de 2022.