



Universidade Eduardo Mondlane

Faculdade de Engenharia

Departamento da Engenharia Mecânica

Licenciatura em Engenharia Mecânica

Tema:

Planificação da Matriz Energética de Moçambique até 2045, baseando-se em
Redes Neurais

Autor:

Muteto, Shaad Enoque

Supervisor:

Prof. Doutor Eng.º Jorge Nhambiu

Maputo, Agosto de 2025



Universidade Eduardo Mondlane

Faculdade de Engenharia

Departamento da Engenharia Mecânica

Licenciatura em Engenharia Mecânica

Tema:

Planificação da Matriz Energética de Moçambique até 2045, baseando-se em
Redes Neurais

Autor:

Muteto, Shaad Enoque

Supervisor:

Prof. Doutor Eng.º Jorge Nhambiu

Maputo, Agosto de 2025



Planificação da Matriz Energética de Moçambique até 2045, baseando-se em Redes Neurais

Muteto, Shaad Enoque



Faculdade de Engenharia
Curso de Engenharia Mecânica
Trabalho de Licenciatura

TERMO DE ENTREGA DE RELATORIO DO TRABALHO DE LICENCIATURA

Declaro que o estudante **Shaad Enoque Muteto** entregou no dia __/__/2025 as __ copias do relatório do seu Trabalho de Licenciatura com a referência: _____ intitulado: **PLANIFICAÇÃO DA MATRIZ ENERGETICA DE MOÇAMBIQUE ATÉ 2045, BASEANDO-SE EM REDES NEURAIIS.**

Maputo, ____ de Agosto de 2025

O/A Chefe da Secretaria

DEDICATÓRIA

Dedico este trabalho à pessoa mais importante da minha vida: à minha mãe, Aiça Mussá Vulgo Laçanian. A mulher mais forte que já conheci, que me deu a vida, me ensinou valores, em sempre me motivou a seguir em frente.

Infelizmente, não poderá ver seu filho realizar este sonho, mas espero que, de onde estiver, esteja orgulhosa.

Muito obrigado por tudo mãe. Que Allah conceda conforto e paz eterna.

Amo-te muito.

AGRADECIMENTOS

Agradeço, primeiramente, aos meus pais, Enoque Muteto e Aiça Laçanian, pelo apoio incondicional e por terem sido o alicerce da minha trajetória académica.

Aos meus irmãos, Sara Bibi, Mohamed Imiran, Maísa Enoque e Chabir Muteto, agradeço pelo apoio e incentivo constante ao longo desses anos.

Ao meu supervisor, o Professor Doutor Jorge Nhambiu, que me auxiliou de forma quase indescritível, pela orientação dedicada, sua paciência e compromisso excepcional, para a superação dos percalços encontrados, sua disponibilidade, rigor académico, incentivo e confiança foram essenciais para que eu encontrasse o caminho certo a seguir.

Aos meus amigos de longa data, que caminham comigo desde o ensino primário e secundário que se tornaram verdadeiros irmãos, deixo minha profunda gratidão: Benildo Morais e Mayer Libombos

Aos colegas da faculdade que se tornaram amigos e irmãos, mito obrigado pela parceria, apoio e motivação nos momentos de dificuldade e dúvida: Cândido Chaves, Casimiro Bimbe, Ednaldo Tembe, Edilson Mavila, Ilídio Ugembe, José Nhacutove, Miguel Manuel, Simião Chiconela, Tiago Cossa, e aos demais.

A todos que, de alguma forma, fizeram parte desta jornada atribulada, meu sincero e eterno agradecimento.

DECLARAÇÃO DE HONRA

Eu, Shaad Enoque Muteto declaro por minha honra que a presente tese é exclusivamente de minha autoria, não constituindo cópia de nenhum trabalho realizado anteriormente e as fontes usadas para a realização do trabalho encontram-se referidas na bibliografia.

RESUMO

Nos últimos anos, a crescente conscientização em relação ao meio ambiente tem impulsionado a busca por alternativas energéticas mais sustentáveis, com destaque para a redução da dependência de combustíveis fósseis e a integração de fontes renováveis na matriz energética para a geração de energia eléctrica. Em Moçambique, país com elevado e diversificado potencial energético, essa transição representa uma oportunidade estratégica para alcançar um sistema energético mais equilibrado e resiliente.

Este trabalho propõe uma abordagem inovadora para o planeamento da matriz energética nacional, fundamentada no uso de técnicas de inteligência artificial. Especificamente, utilizam-se redes neurais artificiais para a previsão da demanda energética, de seguida o mapeamento das capacidades instaladas e a projecção de seu crescimento. Com base nesses dados, realiza-se uma optimização da participação de cada fonte de energia, considerando critérios económicos e ambientais. Os resultados obtidos indicam que o uso de ferramentas de inteligência artificial pode contribuir significativamente para o desenvolvimento de uma matriz energética mais eficiente, sustentável e adaptada às necessidades futuras do país.

Palavras-chaves: Matriz energética, Planeamento energético, Inteligência artificial, Redes neurais artificiais.

ABSTRACT

In recent years, growing awareness of the environment issues has driven the search for more sustainable energy alternatives, emphasizing the reduction of fossil fuel dependency and the integration of renewable energy sources into the energetic matrix for electricity production. In Mozambique, a country with vast and diverse energy potential, this transition represents a strategic opportunity to develop a more balanced and resilient energy system.

This study proposes an innovative approach to national energy matrix planning, utilizing artificial intelligence techniques. Specifically, artificial neural networks are employed to forecast energy demand, followed by mapping installed capacities, and projecting future growth. Based on these projections, an optimization process is conducted to determine the ideal share of each energy source, considering economic and environmental criteria. The results suggest that artificial intelligence tools can significantly contribute to the development of a more efficient, sustainable, and future oriented energy matrix for the country.

Keywords: Energy Matrix, Energy planning, artificial intelligence, artificial neural networks.

Índice

DEDICATÓRIA	III
AGRADECIMENTOS	IV
DECLARAÇÃO DE HONRA	V
RESUMO	VI
ABSTRACT	VII
Índice de Figuras	X
Índice de Gráficos	X
Índice de Tabelas	X
Índice de Quadros	X
Lista de Abreviaturas e Símbolos	XI
1. Introdução	1
1.1. Considerações Preliminares	1
1.2. Objectivos	3
1.2.1. Objectivo Geral	3
1.2.2. Objectivos Específicos	3
1.3. Estrutura do Trabalho	3
2. Estado da Arte	4
2.1. Planeamento Energético em Moçambique	4
2.2. Aplicações de Redes Neurais em Planeamento Energético	8
2.3. Abordagem em Países em Desenvolvimento	9
2.4. Potenciais Oportunidades de Exploração	10
3. Materiais e Métodos	11
3.1. Colecta de Dados	12
3.2. Pré-processamento e Visualização dos dados	12

3.3.	Divisão de Conjunto de Dados	13
3.4.	Construção do Modelo de Redes Neurais.....	13
3.5.	Treinamento e Validação do Modelo.....	19
3.6.	Avaliação de Desempenho	21
3.7.	Geração de Projeções Futuras.....	21
3.8.	Levantamento das Capacidades De Geração.....	21
3.9.	Formulação do Modelo de Optimização.....	22
4.	Resultados e Discussões.....	23
5.	Conclusões e Recomendações	36
5.1.	Conclusões	36
5.2.	Recomendações	37
6.	Bibliografia	39
Anexos		A

Índice de Figuras

Figura 1. Arquitectura interna de uma célula LSTM padrão	15
Figura 2. Arquitectura interna de uma célula GRU padrão	17
Figura 3. Arquitectura da Rede Neural Sequencial LSTM (Fonte: Autor)	18

Índice de Gráficos

Gráfico 1. Potencial Energético dos Países da Africa Subsaariana	5
Gráfico 2. Distribuição do potencial das energias renováveis em Moçambique	6
Gráfico 3. Potencial energético das energias renováveis identificados em Moçambique	7
Gráfico 4. Pontas Máximas de Moçambique	23
Gráfico 5. Variação Anual das Pontas Máximas de Consumo	24
Gráfico 6. Superfície 3D das Pontas Máximas de Consumo	25
Gráfico 7. Decomposição da Série Temporal - Pontas Máximas	27
Gráfico 8. População Moçambicana vs. Tendência das Pontas Máximas	27
Gráfico 9. Desempenho do Modelo nos Dados de Teste	28
Gráfico 10. Avaliação comparativa do desempenho das técnicas usadas em series temporais	29
Gráfico 11. Capacidades Instaladas na Perspectiva de Combustíveis Fósseis	31
Gráfico 12. Capacidades Instaladas na Perspectiva de Energias Nucleares	31
Gráfico 13. Capacidades Instaladas na Perspectiva de Energias Renováveis	32
Gráfico 14. Composição Óptima da Matriz Energética para Combustíveis Fósseis	33
Gráfico 15. Composição Óptima da Matriz Energética para Energias Nucleares	33
Gráfico 16. Composição Óptima da Matriz Energética para Energias Renováveis	34
Gráfico 17. Evolução dos Custos Totais Financeiros	34
Gráfico 18. Evolução dos Custos Ambientais (Emissões de CO ₂ e N ₂ O)	35

Índice de Tabelas

Tabela 1. Resultados da Funções de Activação	26
--	----

Índice de Quadros

Quadro 1. Simbologia das Fontes de Energia	30
--	----

Lista de Abreviaturas e Símbolos

AF – Função de activação

ALER – Associação Lusófona de Energias renováveis

ARENE – Autoridade Reguladora de Energia

bio - Biomassa

carv - Carvão Mineral

CO₂ – Dióxido de Carbono

EDM – Electricidade de Moçambique E.P.

ENE – Estratégia Nacional de Electrificação

FUNAE – Fundo Nacional de Energia

gas_natural - Centrais de Turbinas a Gás a base de GN

GN – Gás Natural

GLP – Gás Liquefeito do Petróleo

GPUs – Graphic Processing Unities (Placas Gráficas)

GRU - Gated Recurrent Unit

GW – Giga Watts

GWh – Giga Watts hora

hidro1 - Centrais Hidroeléctricas de Grande Porte (<200MW)

hidro2 - Centrais Hidroeléctricas de Pequeno Porte

IA – Inteligência artificial

lig1 - Lenhite de Grande Porte (<100MW)

lig2 - Lenhite de Pequeno Porte

LSTM - Long-Short Term Memory

MAE – Erro Médio Absoluto (Mean Absolute Error)

MIREME – Ministério dos Recursos Minerais e Energia

MW – Mega Watts

MWh – Mega Watts hora

N₂O – Oxido Nitroso

nucl - Energia Nuclear

oleo - Centrais de Combustíveis Líquidos Derivados de Petróleo

R² – Coeficiente de Determinação

RMSE – Raiz Quadrática do Erro Médio Quadrático (Root Mean Square Error)

RNA – Rede neural artificial

tur_gas_oleo - Centrais de Turbinas a Gás a base de GLP

1. Introdução

1.1. Considerações Preliminares

A energia é a espinha dorsal da sociedade moderna, ela encontra-se presente em cada aspecto da vida cotidiana, desde a iluminação das casas a operação de indústrias e sistemas de transporte, dependentes de um fornecimento energético confiável e sustentável. No entanto, o mundo enfrenta os desafios de atender uma demanda crescente por energia enquanto reduz impactos ambientais e os custos da geração da mesma.

Nos últimos anos, a transição energética tornou-se um tema central no planeamento global, impulsionada pela necessidade de diversificar as fontes de energia e reduzir a dependência de combustíveis fósseis. Porém, as opiniões acerca da transição energética de combustíveis fósseis para fontes de energia menos poluentes como as renováveis têm sido controversas, pois os custos associados às fontes renováveis são muito mais altos que os associados aos combustíveis fósseis.

Países como Moçambique, com a abundância de recursos naturais possuem uma oportunidade de desenvolver uma matriz energética equilibrada, considerando factores económicos, ambientais e sociais. Moçambique é o país da África Subsaariana com maior potencial energético, sendo grande parte deste proveniente do gás natural e do carvão mineral, seguido da energia hidroeléctrica sendo esta a mais explorada e que constitui a maior parte da matriz energética actual do país, sendo complementada pelos combustíveis fósseis e de forma crescente algumas fontes de energias renováveis.

Silva e Bermann (2002, p. 1), afirmam que: “O planeamento energético é a única ferramenta capaz de identificar as alternativas mais adequadas para atender as demandas da sociedade [...]”. Defendem também que o planeamento energético é de grande importância sendo uma ferramenta auxiliar na tomada de decisões sobre políticas para o atendimento das demandas da população, tendo um grande impacto no âmbito social e económica da mesma.

O planeamento energético apresenta um elevado grau de utilidade. Pelo lado da oferta de energia, ele permite identificar as fontes energéticas mais adequadas em termos tecnológico, económico, social e ambiental para atender as demandas da

sociedade. Pelo lado da demanda, ele permite identificar as tecnologias de uso final capazes de tornar mais eficiente e racional o uso das fontes de energia. Através da construção de cenários futuros sobre o comportamento das demandas, o planeamento energético é de fundamental importância na resolução de conflitos envolvendo oferta e demanda de energia, meio ambiente e desenvolvimento económico. A importância do planeamento energético foi reforçada com o surgimento do conceito de desenvolvimento sustentável, uma vez que a utilização dessa ferramenta pode evitar a degradação prematura dos recursos energéticos não-renováveis e/ou apontar alternativas de substituição de fontes de energia, garantindo a oferta necessária à manutenção do desenvolvimento da sociedade. (Silva & Bermann, 2002, p. 2)

Neste contexto, este trabalho propõe o uso de redes neurais artificiais e optimização multiobjectivo para prever a melhor composição da matriz energética para os próximos anos. O objectivo é encontrar um equilíbrio entre custo, confiabilidade e impacto ambiental, permitindo uma tomada de decisão mais informada e eficiente.

As Redes Neurais Artificiais (RNAs) fazem parte de uma área da inteligência artificial (IA), que é inspirada no processamento de informação e nos de comunicação distribuídos de um sistema biológico. Seu principal objectivo é imitar o cérebro humano de forma aprender padrões complexos.

A busca por um modelo energético ideal não é apenas uma questão de infra-estrutura, mas de qualidade de vida, crescimento económico e preservação ambiental. Portanto, esta pesquisa visa contribuir para um planeamento energético mais sustentável e resiliente, alinhado com as necessidades do futuro.

1.2. Objectivos

1.2.1. Objectivo Geral

Projecção e Optimização da Geração de Energia em Moçambique até 2045 Utilizando Modelos de Redes Neurais.

1.2.2. Objectivos Específicos

1. Identificar as principais fontes que compõem a matriz energética.
2. Identificar as implicações do uso de cada tipo de fonte, em termos económicos e ambientais.
3. Desenvolver e treinar um modelo preditivo baseado em redes neurais.
4. Fazer a projecção da demanda energética a ser atendida
5. Implementar o modelo em uma simulação ou banco de provas para validar sua eficácia.

1.3. Estrutura do Trabalho

Esta tese de Licenciatura é constituída por 5 capítulos incluindo o capítulo introdutório.

O Capítulo 2 apresenta o estudo do estado da arte, onde é feito o estudo sobre trabalhos relevantes que já foram feitos acerca do presente tema, a abordagem usada nos outros países e mais concretamente nos países da Africa Subsariana e a análise do potencial de Moçambique e as lacunas por serem exploradas.

O Capítulo 3 apresenta os materiais e métodos a serem usados no presente trabalho explicando de forma exaustiva como foi conduzida a pesquisa, os métodos e modelos usados.

No Capítulo 4 são apresentados os resultados encontrados de acordo com as etapas realizadas conforme são explicadas no Capítulo 3, e algumas discussões e reflexões são levantadas.

O Capítulo 5 apresenta as conclusões encontradas ao longo do estudo.

2. Estado da Arte

2.1. Planeamento Energético em Moçambique

De acordo com Soares e Cândido (2020, p. 638), “O planeamento energético de um país deve traduzir as directrizes e objectivos de sua política energética e mais que isso, deve reflectir a complexidade e as características do próprio sistema energético [...]”

O planeamento energético é uma ferramenta de elevada importância e utilidade, de forma que esta deverá representar de forma eficiente as diferentes fontes de energia disponíveis que melhor se encaixem nos requisitos de tecnologia, socioeconómicos e de preservação ambiental com vista a um desenvolvimento sustentável suprimindo as necessidades (demanda) da população.

O Planeamento Energético em Moçambique tem sido uma preocupação do Governo. Vários estudos têm sido realizados e directrizes estabelecidas de modo a guiar o país no sector energético. Destes estudos resultaram estratégias com o objectivo do desenvolvimento do acesso à energia em Moçambique, dos quais se destacam: a revisão da lei de electricidade (Lei nº 21/91) a ser implementada pela EDM (Electricidade de Moçambique E.P.) e outras leis estabelecidas relacionadas ao sector, o Plano Director Integrado de Infra-estruturas Eléctricas sendo os organismos de implementação o Governo de Moçambique e a EDM, e a Estratégia Nacional de Electrificação (ENE) sendo os organismos de implementação o Governo de Moçambique, EDM e a ARENE (Autoridade Reguladora de Energia). Estas estratégias são fundamentadas e sustentadas pelos relatórios da EDM, FUNAE (Fundo Nacional de Energia), ALER (Associação Lusófona de Energias Renováveis), MIREME (Ministério de Recursos Minerais e Energia) e da ARENE.

Estes estudos destacam a necessidade da garantia do acesso à energia em todo o país de modo ao atendimento da demanda, e a diversificação da matriz energética nacional com um foco para a integração das energias renováveis na rede, para que seus objectivos sejam alcançados salientam a necessidade do investimento em novas infra-estruturas e novas tecnologias, que esteja de acordo com requisitos para o crescimento sustentável e a garantia da qualidade e acessibilidade da electricidade.

Estes documentos destacam o grande potencial energético de Moçambique, com fontes de energia diversificadas e não exploradas, estabelecem metas para o futuro e destacam os projectos prioritários.

O Potencial energético de Moçambique pode ser notado nos gráficos que se seguem.




Gráfico 1. Potencial Energético dos Países da Africa Subsaariana

Fonte: Adaptado de Castellano, Kendall, Niomarov, e Swemmer (2015)

Como se vê Moçambique lidera o potencial energético dos países da Africa Subsaariana, sendo grande parte de seu potencial proveniente do Gás Natural e do carvão mineral, seguido do potencial hídrico.

Demonstra-se o grande potencial energético de Moçambique na perspectiva de energias renováveis no gráfico abaixo.




Gráfico 2. Distribuição do potencial das energias renováveis em Moçambique

Fonte: Adaptado do Atlas das Energias Renováveis de Moçambique - Recursos e Projectos para Produção de Electricidade (2013)

Pode se observar que a província de Tete lidera em termos de potencial energético em energias renováveis.

O Potencial total das fontes de energias renováveis de Moçambique apresenta-se no gráfico a seguir.

POTENCIAL RENOVÁVEL IDENTIFICADO
IDENTIFIED RENEWABLE POTENTIAL




Gráfico 3. Potencial energético das energias renováveis identificados em Moçambique

Fonte: Atlas das Energias Renováveis de Moçambique - Recursos e Projectos para Produção de Electricidade (2013)

Fica claro que grande parte do potencial de Moçambique é proveniente da energia solar, seguido da hídrica, sendo estas as principais fontes a serem exploradas, os potências em biomassa e geotérmicos são muito baixos e menos relevantes.

Apesar destes planos serem de crucial importância para o futuro energético do país, o comportamento dinâmico e o surgimento de novas técnicas e tecnologias, acarretam a necessidade do emprego de novas abordagens, que vençam as limitações impostas pelas estratégias empregues nesses estudos maioritariamente estatísticos e determinísticos, de forma a tornar o planeamento mais dinâmico e de maior transigência às alterações rápidas e as imprevisibilidades dos sistemas energéticos, dando mais versatilidade e adaptabilidade ao planeamento.

Desta forma, a sofisticação dos modelos usados é pertinente, usando técnicas avançadas e inovadoras das novas ferramentas disponíveis e actualmente difundidas, como o caso das ferramentas já comprovadas muito poderosas das

Inteligências Artificiais. Esses modelos fornecem resultados que apoiam a criação de políticas e decisões assertivas, essenciais diante de momentos de falta de clareza sobre o futuro.

2.2. Aplicações de Redes Neurais em Planeamento Energético

As Redes Neurais Artificiais (RNAs) são algoritmos computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes tentando emular em máquinas (computadores) o funcionamento do cérebro humano, ainda que de maneira simplificada. Assim como o cérebro humano, a RNA é capaz de aprender e tomar decisões baseadas em seu próprio aprendizado. Desta forma, a RNA pode ser interpretada como um esquema de processamento capaz de armazenar conhecimento baseado em aprendizagem (experiência) e disponibilizar este conhecimento para a aplicação em questão. As RNAs são amplamente utilizadas a solução de problemas complexos, onde o comportamento das variáveis não é rigorosamente conhecido. São utilizadas nas mais diversas áreas do conhecimento, principalmente em aplicações que envolvam reconhecimento de padrões, assim como, análise de séries temporais, diagnósticos médicos, previsões no mercado financeiro, etc. Diante do exposto, a RNA é capaz de reconhecer padrões, ou seja, possui a capacidade de aprender por meio de exemplos e de generalizar a informação aprendida, gerando um modelo não-linear, o que torna a sua aplicação na análise espacial bastante eficiente. (Spörl, Castro, & Luchiari, 2011, p. 116).

As RNAs possuem diversas vantagens, nota-se que esta constitui uma ferramenta poderosa e inovadora com muita versatilidade podendo ser usada para diversas aplicações, incluindo a planificação energética, porém é preciso não esquecer de factores cruciais como o processo de colecta de dados que deve ser muito cuidadoso, devido á elevada sensibilidades destes modelos aos dados e a necessidades de dados abundantes o suficiente para garantir a robustez do modelo e esforços para tornar melhor a interpretação dos resultados do modelo. Já foram feitos outros estudos usando estes, como na pesquisa de Nhambiu e Chichango (2024b), em que estes foram usados para fazer a previsão do consumo de energia. Fiorin, Martins, Schuch, e Pereira (2011) usam redes neurais para a previsão da disponibilidade de energia solar, mostrando que as redes neurais podem fornecer estimativas com a

confiabilidade necessária e com melhor desempenho que outras técnicas estatísticas usadas em seu estudo.

As IAs têm emergido como uma força transformadora na otimização da gestão de energias renováveis, provendo soluções inovadoras que melhoram a geração, distribuição, e eficiência do consumo de energia. Uma das aplicações mais significativas da IA no sector energético é a previsão da demanda, que torna possíveis planos de suprimento precisos e a alocação desses recursos. (Muraina, Ainbamiwa, Abiola, & Charles, 2025)

E Muitos outros estudos foram realizados usando redes neurais para a previsão da demanda energética e consumo, foram também usados na modelagem de sistemas híbridos de energia renovável para a otimização da produção devido a sazonalidade destas fontes, usadas para a gestão inteligente de sistemas de geração integrados, como também na gestão e armazenamento de energia.

2.3. Abordagem em Países em Desenvolvimento

Vários estudos têm sido realizados em Africa e nos países em desenvolvimento com a aplicação de redes renováveis, como o artigo (Fadare, Irimisose, Oni, & Falana, 2010) no qual discutem a viabilidade dos modelos baseados em RNA para a previsão do potencial de energia solar em África, e o artigo (Muraina, Ainbamiwa, Abiola, & Charles, 2025) que fazem estudo de casos em países como Nigéria, Quênia e Africa do Sul, onde as IAs são usadas em mini-redes para a otimização da geração e armazenamento de energia. A pesquisa e implementação da IA na Africa Subsaariana ainda está em desenvolvimento, mas há um número crescente de trabalhos, estudos e implementações a emergir.

Em Moçambique, mesmo com o uso limitado de IA no sector energético, a integração de Redes Neurais Artificiais (RNAs) no Programa Nacional de Energia para Todos pode catalisar a modernização da infra-estrutura, impulsionar o desenvolvimento sustentável e expandir drasticamente o acesso à energia, melhorando a vida das comunidades.

2.4. Potenciais Oportunidades de Exploração

Apesar do avanço global, a aplicação de redes neurais para o planeamento de longo prazo da matriz energética em Moçambique é incipiente. Há um potencial inexplorado na integração eficiente de variáveis económicas, demográficas e climáticas em modelos preditivos robustos, essenciais para simular cenários até 2045.

Este trabalho propõe-se a desenvolver esse potencial com um modelo inovador baseado em redes neurais, treinado com dados nacionais e regionais. Este modelo permitirá simular o impacto de políticas públicas e da inovação tecnológica na matriz energética moçambicana, promovendo um planeamento mais eficaz e sustentável que atenda as necessidades e explore o potencial energético local tendo em conta o equilíbrio entre a preservação ambiental e o impacto socioeconómico.

3. Materiais e Métodos

Diante das crescentes adversidades associadas a transição energética, a busca de soluções que aliem eficiência, sustentabilidade e previsibilidade torna-se cada vez mais urgente. Neste contexto, o uso de redes neurais artificiais destaca-se como uma promissora abordagem para a modelação de sistemas energéticos complexos e altamente dinâmicos. Este capítulo descreve detalhadamente os procedimentos adotados para a construção, treinamento e validação de modelos de redes neurais voltados à previsão e otimização da matriz energética. São apresentados os dados utilizados, os critérios de pré-processamento, a arquitectura das redes, os parâmetros de treinamento e as métricas de avaliação, de forma a garantir reprodutibilidade e transparência nos resultados obtidos.

A implementação das redes neurais é feita através da programação em Python, que é uma linguagem de programação das mais populares e poderosas devido a sua simplicidade, vasta comunidade e bibliotecas especializadas em ciência de dados. Esta linguagem possui uma sintaxe simples e legível, que facilita o aprendizado e implementação de algoritmos robustos, e facilidade de integração com outras tecnologias e bancos de dados.

A implementação de redes neurais complexas requer acesso a recursos computacionais robustos, como máquinas com alto desempenho e placas gráficas (GPUs), que são essenciais para processar grandes volumes de dados e treinar modelos de forma eficiente. Para isso, é necessário utilizar um ambiente de desenvolvimento compatível com a linguagem de programação escolhida. Caso o utilizador não disponha desses recursos localmente, uma alternativa viável é o Google Colab, uma plataforma *online* gratuita que oferece um ambiente de desenvolvimento com suporte a diversas linguagens e acesso a máquinas virtuais com GPUs fornecidas pela Google.

Foi também necessário o uso do Excel para a gestão de dados e compilação da base de dados usados neste presente trabalho

3.1. Colecta de Dados

Esta fase é de crucial importância, devido a já mencionada sensibilidade das redes neurais aos dados. Uma vez que os modelos aprendem através de dados históricos padrões, e destes dados extraem informações que podem ser valiosas ao estudo, é essencial se ter cuidado durante este processo de modo a não influenciar os resultados, e causar a obtenção de resultados tendenciosos.

Os dados usados foram obtidos dos relatórios anuais estatísticos da EDM, desde o ano de 2006 a 2023, onde foram extraídos para uma base de dados as pontas máximas anuais de Moçambique, que representam os pontos ou níveis mais altos da demanda energética de um sistema durante períodos específicos, dos quais foram agrupados por zonas de produção, tendo: pontas máximas de todo o sistema interligado, pontas máximas do sistema Norte-Centro e Tete, pontas máximas do sistema Centro (constituído por Mavuzi, Chicamba e Chibata) e pontas máximas do sistema sul, para os dias dos meses correspondentes de cada ano.

Nota: Dos dados obtidos da EDM, não foram encontrados os relatórios com os dados referentes aos anos de 2016, 2017, 2018 e 2022.

3.2. Pré-processamento e Visualização dos dados

Nesta fase, também crucial ao processo a base de dados obtida da colecta, é inicialmente trabalhada e faz-se a visualização de modo a auferir a integridade da base de dados, verificar-se a existência de pontos ruidosos, a correlação de variáveis se existente de modo a ver a viabilidade a aplicação de um modelo preditivo (pois para dados sem correlações nenhuma e nem aparentes é virtualmente impossível prever nada a partir dos mesmos), verificar a existência de valores nulos ou não correspondentes ao tipo a qual este pertence.

É muitas vezes empregue o uso de ferramentas visuais de modo a facilitar a interpretação dos dados, dos quais podem ser formuladas hipóteses iniciais sobre os mesmos.

Nesta fase é definido o escopo da análise, isto é, são definidos os objectivos que deverão ser as saídas do modelo, e as variáveis que são importantes e relevantes para a previsão, e são descartadas todas as variáveis que não sejam relevantes e fazem-se as simplificações que forem possíveis.

Desta etapa resulta uma base de dados mais coesa, que passa pela eliminação ou saneamento de defeitos, dependendo das técnicas aplicadas. Essa base de dados é composta de variáveis relevantes, contendo dados íntegros e não tendenciosos, além das variáveis de interesse que serão utilizadas para o treinamento do modelo. No caso em questão os dados colectados ao longo dos diversos anos são agregados em uma única base de dados, de forma ordenada cronologicamente.

3.3. Divisão de Conjunto de Dados

Nesta fase os dados são divididos em duas partes distintas, sendo 80% para o treinamento do modelo, que são os dados que alimentam o modelo durante a aprendizagem, ou por outra, são os dados dos quais o modelo aprende o comportamento e padrões existentes, e os restantes 20% são os dados usados para teste e validação do modelo, dados estes que servem para avaliar a performance do modelo.

3.4. Construção do Modelo de Redes Neurais

A ideia básica por detrás das redes neurais é a construção de um modelo composto por uma grande quantidade de pequenas unidades de processamento simples denominadas neurónios agrupados em *layers* ou camadas, com um grande número de conexões entre eles, a informação processada nos neurónios e transmitida através dessas conexões denominadas sinapses ou pesos sinápticos (Santos, Seixas, & Pereira, 2005).

Em termos de topologia, para implementar-se uma rede neural deve-se determinar as seguintes variáveis: (a) o número de nós na camada de entrada, (b) o número de camadas escondidas e o número de neurónios a serem colocados nessas camadas, (c) o número de neurónios na camada de saída. Estes parâmetros afectam o desempenho da RNA, devendo ser cuidadosamente escolhidos. O número de nós na camada de entrada corresponde ao número de variáveis que serão usadas para alimentar a rede neural. Frequentemente são as variáveis mais relevantes para o problema em estudo (Santos, Seixas, & Pereira, 2005, p. 121).

Explicam em seu artigo Machado e Fonseca (2013, p. 230), que “As entradas são propagadas através da topologia da RNA, sendo transformadas pelos pesos sinápticos e pela função de activação (AF) dos neurónios. [...]”.

A função de activação, também chamada por função de transferência, pode ser definida segundo Santos, Seixas, & Pereira (2005, p. 121) como: “uma função matemática que, aplica a combinação linear entre as variáveis de entrada e pesos que chegam a determinado neurónio, retorna ao seu valor de saída”. Existem diversas funções matemáticas que são usadas como função de activação. Neste trabalho emprega-se várias dessas funções para analisar os resultados e identificar qual delas apresenta melhor desempenho para os dados.

As funções de activação usadas foram: relu, leakyrelu, elu e tanh. (Activation Functions, 2025)

- × **ELU** – Exponential linear Unit, é uma função que tende a convergir o custo a zero rápido e produzir resultados mais precisos. Diferente das outras funções de activação, ELU possui uma constante extra alfa que deve ser um número positivo.

$$R(z) = \begin{cases} z, & z > 0 \\ \alpha(e^z - 1), & z \leq 0 \end{cases} \quad (1)$$

- × **ReLU** – Rectified Linear Units. Apesar de sua fórmula se simplesmente $\max(0, z)$, ela não é linear e tem a capacidade de aprender funções não lineares com boa performance.

$$R(z) = \begin{cases} z, & z > 0 \\ 0, & z \leq 0 \end{cases} \quad (2)$$

- × **LeakyReLU** - é uma variante do ReLU. Ao invés de ser 0 quando $z < 0$, a leaky ReLU permite pequenos, não-nulos, gradientes contantes alfa (normalmente, $\alpha = 0.01$)

$$R(z) = \begin{cases} z, & z > 0 \\ \alpha z, & z \leq 0 \end{cases} \quad (3)$$

- × **Tanh** – tanh comprime um número de valor real no intervalo de $[-1, 1]$. É não-linear e sua saída é centrada em zero

$$\tanh(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}} \quad (4)$$

A rede neural mais usada é a LSTM (Long-Short Term Memory), é um tipo de rede neural recorrente recomendado para a previsão de series temporais devido a sua capacidade de capturar dependências de longo prazo e padrões em dados sequenciados, existem também as redes GRU (Gated Recurrent Unit), que são

similares as LSTM, apresentadas como modificação da célula LSTM, que complementa a capacidade de prever dependências de longo prazo com a melhoria da integração de informações de curto prazo. Apesar do menor número de parâmetros nas células GRU, nenhuma vantagem substancial pode ser identificada para além do menor tempo de computação. Além disso, pode ver-se que o sistema de portas da LSTM contribui na filtragem de informações irrelevantes e alcançar maior precisão na modelagem de comportamentos que variam com o tempo. (Lindemann et al., 2021)

A LSTM é constituída por três portas: porta de entrada (*input gate*), porta de esquecimento (*forget gate*) e a porta de saída (*output gate*). Cada porta executa uma função específica no controlo do fluxo de informações. A porta de entrada decide como actualizar o estado interno baseado na entrada actual e no estado interno prévio. A porta de esquecimento determina o quanto do estado interno prévio deve ser esquecido. E por fim, a porta de saída regula a influência do estado interno no sistema. (Shiri, Perumal, Mustapha, & Mohamed, 2024)

A arquitectura interna de uma célula ou módulo LSTM padrão é demonstrada a seguir:




Figura 1. Arquitectura interna de uma célula LSTM padrão

Fonte: Shiri, Perumal, Mustapha, e Mohamed (2024)

As equações de uma LSTM são mostradas a seguir:

$$h^{(t)} = g_0^{(t)} f_h(s^{(t)}) \quad (5)$$

$$s^{(t)} = g_f^{(t)} s^{(t-1)} + g_i^{(t)} f_s(wh^{(t-1)}) + uX^{(t)} + b \quad (6)$$

$$g_i^{(t)} = \text{sigmoid}(w_i h^{(t-1)} + u_i X^{(t)} + b_i) \quad (7)$$

$$g_f^{(t)} = \text{sigmoid}(w_f h^{(t-1)} + u_f X^{(t)} + b_f) \quad (8)$$

$$g_0^{(t)} = \text{sigmoid}(w_0 h^{(t-1)} + u_0 X^{(t)} + b_0) \quad (9)$$

Onde:

$h^{(t)}$ - Representa a saída (dados ou informação processada)

$X^{(t)}$ - Representa o vector de entrada (dados ou informações de entrada)

$s^{(t)}$ - Representa o estado do sistema (*system state*)

w, u – Representam as matrizes de pesos ajustáveis do estado oculto

b – Representa o termo de folga (*bias term*)

t – Representa o período actual

$t-1$ – Representa o período anterior

f_h e f_s Representam as funções de activação do estado do sistema e do estado interno respectivamente

As subscrições i , o e f correspondem a porta de entrada (*input gate*), porta de saída (*output gate*) e porta de esquecimento (*forget gate*)

O operador de portas denominado g é um retro alimentador da rede neural com uma função de activação sigmóide, assegurando que as saídas estejam num intervalo de 0 e 1, as quais são interpretados como um conjunto de pesos

A GRU combina as portas de entrada e a de esquecimento de um LSTM em uma única porta de actualização (*update gate*), resultando em um *design* mais simplificado. Ela é constituída por três portas principais: uma porta de actualização, uma porta de *reset* (*reset gate*) e a de memória de conteúdo actual (*current memory content*). Essas portas permitem a GRU actualizar de forma selectiva e utilizar informação de períodos

prévios, permitindo capturar dependências de longo prazo em sequências. (Shiri, Perumal, Mustapha, & Mohamed, 2024)

A estrutura interna de uma célula ou módulo GRU padrão é demonstrada a seguir:




Figura 2. Arquitetura interna de uma célula GRU padrão

Fonte: Shiri, Perumal, Mustapha, e Mohamed (2024)

As equações de uma GRU são apresentadas a seguir:

$$z_t = \text{sigmoid}(W_z[h_{t-1}, x_t] + b_z) \quad (10)$$

$$r_t = \text{sigmoid}(W_r[h_{t-1}, x_t] + b_r) \quad (11)$$

$$\bar{h}_t = f(W_h[r_t h_{t-1}, x_t]) \quad (12)$$

$$h_t = (1 - z_t)h_{t-1} + z_t \bar{h}_t \quad (13)$$

$$o_t = \sigma_0(W_0 h_t + b_0) \quad (14)$$

Onde:

z – Representa a porta de actualização (*update gate*) que determina o quanto de informação passada deve ser retida e combinada com a entrada actual em um período específico

h_{t-1} - Representa o estado oculto prévio

b – Representa o termo de folga

x_t - Representa a entrada actual (dados ou informações de entrada)

r – Representa a porta de reset (*reset gate*)

W – Representa a matriz de pesos ajustáveis do estado oculto

f – Representa a função de activação

h_t - Representa o estado final da memória ou saída

o – Representa a porta opcional adicional de saída, que pode ser introduzida para controlar o fluxo de informação entre o estado de memória actual e a saída.

A arquitectura da rede neural base usada é demonstrada na figura que se segue:

Arquitetura da Rede Neural Sequencial com LSTM




Figura 3. Arquitetura da Rede Neural Sequencial LSTM (Fonte: Autor)

3.5. Treinamento e Validação do Modelo

Nesta fase, ocorre a verdadeira “mágica”: a rede é alimentada pelos dados, ao longo do número pré-determinado de épocas definido na fase anterior, ela aprende a partir desses dados, conforme a taxa de aprendizagem e otimizador escolhido.

O aprendizado em redes neurais ocorre criando conexões e ajustando os pesos das conexões entre os neurónios por meio de um processo chamado treinamento. Isso envolve alimentar os grandes conjuntos de dados da rede, que são usados para refinar os pesos e minimizar erros entre as previsões e os valores reais. Esse processo é semelhante à forma como os humanos aprendem, em que a exposição repetida ajuda a reconhecer padrões. Uma técnica chamada retropropagação facilita esse ajuste de peso. A retropropagação calcula o erro na saída e propaga-o de volta pela rede, ajustando iterativamente os pesos até que um nível de acurácia desejado seja alcançado. Depois de treinada, a rede pode fazer previsões sobre novos dados, como identificar gatos em imagens. (Google Cloud, 2025)

São feitos teste para analisar a performance do modelo, caso os resultados ainda não sejam satisfatórios, hiperparâmetros são modificados, alterados os processos de regularização, a arquitectura da rede, introduzidos critérios de paragem para o treinamento para evitar o *overfitting*, alterada a função de activação ou de perdas, e ou até o ritmo de aprendizagem ou otimizador, de modo que estes parâmetros todos se adequem à natureza dos dados e melhor se enquadrem.

Graças a actual capacidade computacional e o uso de placas gráficas redes complexas podem ser treinadas em minutos ou horas, sendo estas mesmas redes usando capacidades computacionais convencionais poderá levar de dias, meses e até anos a dar resultados.

Há várias métricas que podem ser usadas para analisar o desempenho dos modelos, das quais as mais usadas, e as escolhidas neste trabalho são:

- **Erro Médio Absoluto (*MAE - Mean Absolute Error*)**

$$MAE = \frac{\sum_{i=1}^n |y_i - x_i|}{n} \quad (15)$$

- **Raiz Quadrada do Erro Médio Quadrático (*RMSE – Root Mean Square Error*)**

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=0}^n (y_i - x_i)^2} \quad (16)$$

- **Coefficiente de Determinação (R^2)**

$$R^2 = 1 - \frac{\sum_{i=0}^n (x_i - y_i)^2}{\sum_{i=0}^n (x_i - \bar{x})^2} \quad (17)$$

Onde:

x_i - Representa o valor real

y_i - Representa o valor previsto

$\bar{x}$ - Representa a media dos valores de x

n – Representa o número de amostras ou de previsões

3.6. Avaliação de Desempenho

Após a concepção, treinamento e validação do modelo, suas métricas de desempenho são analisadas e comparadas com as de modelos tradicionais ou preexistentes na mesma área. Esse processo visa determinar se o modelo proposto apresenta ganhos significativos ou se seu desempenho é equivalente ao dos modelos convencionais, sem agregar valor substancial.

Esse processo é fundamental para garantir a eficácia e utilidade do modelo desenvolvido. A avaliação das métricas de desempenho em comparação com modelos tradicionais ou existentes permite verificar se há melhorias significativas, como maior precisão, eficiência computacional ou capacidade de generalização. Além disso, essa análise fornece embasamento para decisões sobre a adoção do novo modelo, justificando seu uso em aplicações reais. Sem essa etapa, não seria possível determinar se o modelo realmente traz inovação ou se apenas replica abordagens já conhecidas sem avanço substancial.

3.7. Geração de Projeções Futuras

Após o modelo demonstrar sua capacidade de apresentar ganhos significativos, ele é aplicado ao propósito para o qual foi concebido, no caso, faz-se a projecção das pontas máximas de demanda futuras, de modo a analisar o seu comportamento, de modo a melhor planejar-se a matriz energética nacional para suprir as necessidades futuras.

3.8. Levantamento das Capacidades De Geração

Nesta fase faz-se o levantamento das capacidades Instaladas actuais de acordo com o tipo de fonte, sejam elas renováveis ou fósseis.

Para além das capacidades já instaladas faz-se o mapeamento dos projectos futuros e a previsão de sua entrada de funcionamento e as capacidades que estas possuirão.

Faz-se o levantamento dos custos inerentes a operação e ou de investimento para sua implantação. De modo a se ter o custo económico por cada unidade de energia produzida.

Não só os custos económicos são tomados em conta, mas também deverão ser estimados os custos ambientais, e devido a inconsistência de algumas fontes é necessário analisar alguns indicadores de eficiência.

Dados estes obtidos de (Energy, 2020) e de (Gómez, et al., 2006)

3.9. Formulação do Modelo de Optimização

A optimização é feita através de um *framework* denominado *PyMOO*, que é uma estrutura conceitual de busca de soluções óptimas que permite a optimização multiobjectivo. Os objectivos ou funções objectivos da optimização deste problema são: minimização de custos capitas, da emissão de carbono, emissão de óxido nitroso e como restrição que a capacidade total usada seja igual ou superior a ponta máxima de demanda do ano em questão, cujas equações são apresentadas a seguir.

$$\min C_{ust}(t) = \sum_i C_{ust_{fix},i} * Cap_i + \sum_i Op\&Man_i * x_i * 8760 \quad (18)$$

$$\min CO_2(t) = \sum_i CO_{2,i} * x_i * 8760 \quad (19)$$

$$\min N_2O(t) = \sum_i N_2O_i * x_i * 8760 \quad (20)$$

$$P_{max}(t) \leq \sum_i x_i \quad (21)$$

Onde:

C_{ust} – Representa o custo total em milhões de dólares

t – Representa o ano em análise

i – Representa as fontes disponíveis

Cap – Representa a capacidade total instalada da fonte usada

$C_{ust_{fix}}$ – Representa o custo fixo para a operação de cada tipo de fonte de energia, que são custos directamente relacionados com *design* de equipamentos, materiais, serviços contratados, e custos administrativos e custos gerais.

$Op\&Man$ – Representa os custos de operação e manutenção de cada tipo de fonte, que são custos directamente relacionados com a produção de energia eléctrica da planta, tais como: consumo de água, desperdícios, lubrificantes consumíveis, etc.

CO_2 – Representa as quantidades de dióxido de carbono emitidos em toneladas

N_2O – Representa as quantidades de óxido nitroso emitidos em toneladas

P_{max} – Representa o maior pico de demanda do ano em análise

x_i – Representa a capacidade usada de cada tipo de fonte que varia de 0 à 80% da sua capacidade máxima.

4. Resultados e Discussões

Neste capítulo, são apresentados e analisados os resultados obtidos com a aplicação das técnicas descritas no capítulo de Materiais e Métodos, abrangendo desde a fase de colecta e preparação dos dados até a geração de projecções futuras, modelagem e optimização do sistema energético.

A análise inicia-se com os dados históricos de carga eléctrica, pontas máximas de consumo diário de Moçambique, obtidos nos Relatórios Anuais Estatísticos da EDM, compilados em folhas do Excel, depois processadas de modo a se integrar os diversos dados de anos diferentes, em uma única, mantendo a coesão dos dados e a sequência das datas. Dos quais se obteve os dados que são mostrados no gráfico que se segue.




Gráfico 4. Pontas Máximas de Moçambique

Fonte: Autor (Dados extraídos e compilados da EDM)

Nota-se do gráfico que a tendência da demanda é crescente, apesar de alguns pontos apresentarem algumas quedas, e também notarem-se os dados que estão em falta equivalentes aos anos de 2016 à 2018 e de 2022.

Sobrepondo os diferentes anos, no mesmo gráfico para os mesmos períodos do ano nota-se um comportamento sazonal demonstrado no gráfico que se segue.




Gráfico 5. Variação Anual das Pontas Máximas de Consumo

Fonte: Autor (Dados extraídos e compilados da EDM)

Essas informações que se observa destes dados são fundamentais demonstrando que realmente existem padrões de comportamento nos dados que podem ser captados e usados no treinamento das redes neurais, melhor pode ser visto combinando os dois gráficos anteriores em um gráfico 3d que se segue.

Superfície 3D das Pontas Maximas de Consumo




Gráfico 6. Superfície 3D das Pontas Máximas de Consumo

Fonte: Autor (Dados extraídos e compilados da EDM)

Inicialmente, ignorou-se os buracos nos dados e foi treinada uma rede neural LSTM com estes dados, que tiveram resultados razoáveis para as diferentes activações de acordo com os dados da tabela que se segue, porem as GRU tiveram resultados melhores.

Tabela 1. Resultados da Funções de Activação

Tipo de Rede	Activação	RMSE	MAE	R2
LSTM	elu	40,49	29,01	0,5
	tanh	42,03	33,99	0,54
	relu	43,73	35,58	0,5
	leakyrelu	40,09	31,15	0,58
GRU	leakyrelu	34,14	24,13	0,69

Vê-se que as redes GRU possuem melhor desempenho devido à integração de informações de curto prazo, e a função de activação *Leakyrelu* possuir melhor desempenho. É importante salientar que estes comportamentos estão directamente relacionados com a natureza destes dados, não podendo assumir-se no geral que um tipo de rede ou activação seja melhor que a outra.

Os gráficos de previsões dos dados de teste encontram-se apresentados nos anexos.

Apesar de diversas alterações e modificações, melhores desempenhos não foram possíveis encontrar para estes dados, que indicam que o modelo já tenha atingindo o limite de aprendizado para os mesmos.

De modo a se obter melhor desempenho, recorre-se a uma técnica diferente que envolve a decomposição dos dados em três componentes que são a tendência, a sazonalidade e o ruído, que pode ver-se no gráfico que se segue.

Decomposição da Série Temporal - Pontas Máximas




Gráfico 7. Decomposição da Série Temporal - Pontas Máximas

Fonte: Autor

Estes gráficos demonstram de forma clara que as pontas máximas de demanda têm uma tendência de crescimento, e um comportamento sazonal fixo ao longo do ano.

Diversos factores podem influenciar a Tendência de crescimento das pontas máximas, tais como o crescimento populacional, que pode se ver no gráfico que se segue:




Gráfico 8. População Moçambicana vs. Tendência das Pontas Máximas

Fonte: Autor [Dados obtidos da EDM e de microtrends (2025)]

Deste modo criou-se dois modelos para prever a tendência e outro para o ruído, apesar do ruído ser difícil de prever devido ao seu comportamento aleatório, e como é notável que a sazonalidade é um comportamento repetitivo e constante, para as previsões basta simplesmente saber para que período do ano que se pretende prever para saber o valor da sazonalidade através dos dados históricos.

Mesmo com esta técnica os desempenhos não melhoraram e as previsões futuras tiveram um comportamento decadente que não condiz com o que se pode observar da tendência, muito disto se devia as grandes lacunas nos dados.

De forma a tratar as lacunas de dados históricos, técnicas de interpolação foram usadas, sendo as de interpolação linear não favoráveis e de pouca acurácia principalmente devido ao comportamento cíclico dos dados. Deste modo recorreu-se ao uso apenas da sequência de dados contínuos sem lacunas de 2007 à 2015 para construir um modelo e através de suas previsões reconstruir os dados em falta entre 2016 à 2018, e integrá-los nos dados existentes. De modo a construir um modelo com dados sem lacunas e de melhor desempenho.

Com a base de dados continua e sem lacunas treinou-se o modelo final que teve o desempenho que se segue e as previsões dos dados de teste mostradas no gráfico a seguir.




Gráfico 9. Desempenho do Modelo nos Dados de Teste

Quanto a análise do desempenho deste modelo, este apresentou resultados melhores que as outras técnicas existentes e usadas em series temporais como pode ser visto no gráfico que se segue.




Gráfico 10. Avaliação comparativa do desempenho das técnicas usadas em series temporais

Fonte: Autor

Torna-se evidente a notável superioridade da abordagem adoptada em relação a estas outras técnicas tradicionais.

Com o modelo final fizeram-se as previsões para os próximos anos. Estas previsões demonstram a perspectiva do crescimento da demanda energética, deste modo torna-se possível fazer a optimização da matriz energética, alocando os recursos necessários, e a possibilidade de se ter uma matriz energética equilibrada podendo explorar diferentes cenários.

De modo a fazer a gestão óptima de recursos, é necessário saber quais os recursos que se encontram disponíveis e perspectivar o seu crescimento e possíveis melhorias. Os dados respeitantes às capacidades instaladas e as suas perspectivas de crescimento foram divididos em três cenários possíveis: um cenário focado nas condições actuais e na contínua utilização dos combustíveis fósseis; o segundo cenário perspectivando a introdução de centrais nucleares modulares compostas por módulos com capacidades de 50 MW por módulo, cujo equipamento é muito menor

que as plantas nucleares tradicionais; e o ultimo cenário focando na integração das energias renováveis na matriz energética.

Nestes cenários as energias foram agrupadas nos tipos de combustível ou fonte de acordo com o quadro que se segue.

Quadro 1. Simbologia das Fontes de Energia

Simbologia	Denominação
nucl	Energia Nuclear
lig1	Lenhite de Grande Porte (<100MW)
lig2	Lenhite de Pequeno Porte
carv	Carvão Mineral
oleo	Centrais de Combustíveis Líquidos Derivados de Petróleo
tur_gas_oleo	Centrais de Turbinas a Gás a base de GLP
gas_natural	Centrais de Turbinas a Gás a base de GN
eólica	Parques de Energia Eólica (Aerogeradores)
solar	Energia solar (Painéis Solares)
bio	Biomassa
hidro1	Centrais Hidroelétricas de Grande Porte (<200MW)
hidro2	Centrais Hidroelétricas de Pequeno Porte

Desta forma se teve os cenários demonstrados nos gráficos que se mostra a seguir baseados nas perspectivas do plano director integrados e dos projectos prioritários e em via de mobilização de recurso segundo o atlas de energias renováveis, dados estes compilados por Nhambiu e Chichango (2024b).




Gráfico 11. Capacidades Instaladas na Perspectiva de Combustíveis Fósseis




Gráfico 12. Capacidades Instaladas na Perspectiva de Energias Nucleares




Gráfico 13. Capacidades Instaladas na Perspectiva de Energias Renováveis

Com os dados anteriores, é possível otimizar a matriz energética nacional, como para este processo de optimização se têm 3 objectivos, surge a questão de qual destes objectivos é prioritário em relação ao outro, pois existem soluções óptimas possíveis diferentes, pois a solução de custo mínimo não é exactamente a solução de emissão de CO₂ mínima e o mesmo acontece para o N₂O, desta forma, considerou-se prioritário os custos e de seguida as emissões de CO₂ já que as emissões de CO₂ e de N₂O são directamente proporcionais.

O resultado do processo de otimização da matriz energética nacional é mostrado nos gráficos que se seguem.




Gráfico 14. Composição Ótima da Matriz Energética para Combustíveis Fósseis




Gráfico 15. Composição Ótima da Matriz Energética para Energias Nucleares




Gráfico 16. Composição Ótima da Matriz Energética para Energias Renováveis

Esses dados demonstram a produção ideal em MWh por ano de acordo com a demanda, de modo a se obter os mínimos custos financeiros e ambientais.

E demonstrado a seguir através dos gráficos os custos relacionados as soluções encontradas pelas diferentes perspectivas.




Gráfico 17. Evolução dos Custos Totais Financeiros




Gráfico 18. Evolução dos Custos Ambientais (Emissões de CO₂ e N₂O)

Esses gráficos demonstram a evolução dos custos, tendo em conta que estes custos estão apenas relacionados com a operação dessas centrais, resultados estes que contrariam as premissas referentes aos custos das energias renováveis serem mais dispendiosas, sendo demonstrado que pelo contrário estas são as menos dispendiosas e menos poluentes nesse contexto.

5. Conclusões e Recomendações

5.1. Conclusões

O presente trabalho teve como objectivo a determinação de um modelo ideal para a projecção da matriz de geração de energia eléctrica em Moçambique até 2045, com base em técnicas de inteligência artificial, mais concretamente as redes neurais. A abordagem adoptada combinou a análise dos dados históricos e produção energética com o desenvolvimento de modelos preditivos orientados por inteligência artificial.

Inicialmente, foram identificadas as principais fontes que compõem a matriz energética nacional, com destaque para a hidroelectricidade, seguida por fontes térmicas (combustíveis fósseis) e em menor escala fontes renováveis emergentes, e as principais potencialidades do país. A caracterização dessas fontes permitiu avaliar suas implicações técnicas, económicas e ambientais, destacando-se o elevado impacto ambiental das fontes fósseis.

De seguida, foram desenvolvidos modelos de previsão baseados em redes neurais recorrentes, em particular o modelo GRU, que demonstrou alta capacidade de modelar séries temporais com componentes sazonais e tendência de longo prazo. A modelagem foi precedida por uma decomposição da série temporal em tendência, sazonalidade e resíduos, permitindo uma abordagem modular e mais robusta da previsão.

As projecções indicam um crescimento contínuo da demanda energética, impulsionado pelo aumento populacional, industrialização e expansão da infraestrutura. Os modelos desenvolvidos foram validados com métricas estatísticas (R^2 , MAE, RSME), apresentando bom desempenho preditivo, com coeficientes de determinação superiores a 0,9 na modelagem da tendência e sazonalidade e desempenho razoável na previsão dos resíduos, e um coeficiente global de 0,86.

Por fim, a implementação do modelo permitiu testar diferentes cenários de geração, considerando restrições económicas e ambientais. Os resultados indicam que uma matriz energética baseada maioritariamente em fontes renováveis, com reforço da capacidade instalada hidroeléctrica e expansão solar e eólica, é tecnicamente viável e ambientalmente desejável, desde que acompanhada de investimentos estratégicos.

5.2. Recomendações

Com base nos resultados obtidos e nas limitações identificadas durante o desenvolvimento deste estudo, apresentam-se as seguintes recomendações para aprofundamentos futuros:

1. Avaliação Ambiental mais Abrangente

A análise dos impactos ambientais realizada neste trabalho considerou, primordialmente, os efeitos gerados durante a fase de operação das unidades de geração. No entanto, é fundamental expandir essa avaliação para incluir os impactos associados às fases de **implantação e construção** das infra-estruturas energéticas. A construção de centrais hidroelétricas, torres de aerogeradores e o processamento de silício para painéis solares, por exemplo, são processos com elevado consumo energético, emissão de gases poluentes e efeitos colaterais sobre ecossistemas locais. Uma abordagem mais completa deve considerar o **ciclo de vida completo** das tecnologias energéticas.

2. Aprimoramento da Modelagem de Custos

Os custos utilizados neste trabalho reflectem estimativas estáticas. Recomenda-se a **integração de componentes dinâmicas**, como a **inflação energética**, custos marginais de operação, manutenção, depreciação de activos, e custos relacionados ao investimento inicial e sua recuperação. A inclusão desses elementos pode fornecer estimativas financeiras mais realistas e uteis para formulação de políticas públicas e análise de viabilidade.

3. Ampliação do Modelo Preditivo

Embora o modelo GRU tenha apresentado bons resultados, seu desempenho pode ser incrementado com a introdução de **variáveis exógenas** relevantes, como temperatura média, crescimento populacional, expansão industrial e políticas energéticas. A inclusão desses factores pode refinar a acurácia do modelo e melhorara sua capacidade de antecipar mudanças estruturais na demanda.

4. Enriquecimento da Base Histórica de Dados

A qualidade da previsão está directamente relacionada à abordagem da base histórica utilizada. É recomendável ampliar o conjunto de dados, tanto em termos temporais quanto espaciais, incluindo series regionais, sub-regionais e variáveis socioeconómicas correlatas.

5. Actualização Continua do Modelo

Uma das vantagens das redes neurais é sua capacidade de serem recalibradas de forma contínua. Recomenda-se o re-treinamento periódico do modelo, incorporando novos dados à medida que se tornam disponíveis. Esta prática assegura maior robustez preditiva ao longo do tempo e permite que o modelo se adapte a novos padrões de consumo e geração.

Estas recomendações visam não apenas a melhoria técnica do modelo proposto, mas também sua utilidade prática como ferramenta de apoio à tomada de decisão no planeamento energético de Moçambique a longo prazo.

6. Bibliografia

- [1] *Activation Functions*. (Junho de 2025). Obtido de ML Glossary: https://ml-cheatsheet.readthedocs.io/en/latest/activation_functions.html
- [2] Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., . . . Farhan, L. (31 de Março de 2021). Review of deep learning: concepts, CNN. *Jornal of Big Data*. doi:10.1186/s40537-021-00444-8
- [3] Ambrósio, P. E. (2002). *Redes neurais artificiais no apoio ao diagnóstico diferencial de lesões intersticiais*. Dissertação de Mestrado, Universidade de São Paulo, Faculdade de Filosofia, Ciências e Letras de Ribeirão Preto, Ribeirão Preto. Obtido em Fevereiro de 2025, de <https://www.teses.usp.br/teses/disponiveis/59/59135/tde-26102002-155559/publico/Dissertacao.pdf>
- [4] *Atlas das Energias Renováveis de Moçambique - Recursos e Projectos para Produção de Electricidade* (1ª ed.). (2013). Moçambique: Gesto-Energia, S.A.
- [5] Batsana, M. E. (2003). *Energia factor de Desenvolvimento*. Universidade Eduardo Mondlane, Faculdade de Economia, Maputo.
- [6] Caldas, R. C., Diz, J. B., & Lopes, C. A. (2023). Energia Nuclear e Consciência Ambiental: Por Uma Governança Global Regulatória Concertada. *Revista Electronica do Curso de Direito da UFSM*. doi:10.5902/1981369443082
- [7] Carola, G. A. (2024). *APLICAÇÕES DE INTELIGÊNCIA ARTIFICIAL EM SISTEMAS DE CONTROLE*. ESCOLA POLITÉCNICA E DE ARTES. Goiania: PONTIFÍCIA UNIVERSIDADE CATÓLICA DE GOIÁS.
- [8] Castellano, A., Kendall, A., Niomarov, M., & Swemmer, T. (2015). *Brigther Africa - The growth potencial of the sub-Saharan electricite sector (Electric Power & Gas)*. Nova York: McKinsey & Company.
- [9] Energy, U. D. (2020). Capital Cost and Performance Characteristic Estimates for Utility Scale Electric Power Generating Technologies . *U.S. Energy Information Administration*.
- [10] *EnergyPedia*. (25 de Maio de 2023). Obtido em Maio de 2025, de https://energypedia.info/wiki/Enquadramento_Pol%C3%ADtico_e_Estrat%C3

%A9gias_de_Acesso_%C3%A0_Energia_em_Mo%C3%A7ambique#cite_not
e-:0-7


- [11] Estêvão, T. E. (2008). *O Hidrogénio como combustível*. Dissertação de Mestrado, Faculdade de Engenharia da Universidade do Porto, Porto, Portugal.
- [12] Fadare, D. A., Irimisose, I., Oni, A., & Falana, A. (2010). *Modeling of solar energy potential in Africa using an artificial neural networ*. Nigeria: AMERICAN JOURNAL OF SCIENTIFIC AND INDUSTRIAL RESEARCH. doi:10.5251/ajsir.2010.1.2.144.157
- [13] Fiorin, D. V., Martins, F. R., Schuch, N. J., & Pereira, E. B. (2011). Aplicações de redes neurais e previsoes de disponibilidade de recursos energéticos solares. *Revista Brasileira de Ensino de Física*, 33(1309). doi:10.1590/S1806-11172011000100009
- [14] Fleck, L., Tavares, M. H., Eyng, E., Helmann, A. C., & Andrade, M. A. (2016). REDES NEURAIAS ARTIFICIAIS: PRINCÍPIOS BÁSICOS. *Revista Eletrônica Científica Inovação e Tecnologia*, 1, 47-57.
- [15] Fortes, A. G., Mutenda, F. M., & Raimundo, B. (2019). *Energias Renovaveis em Moçambique: Disponibilidade, Geração, Uso e Tendências Futuras*. Revista Brasileira Multidisciplinar. doi:10.25061/2527-2675/ReBraM/2020.v23i1.681
- [16] Gómez, D. R., Watterson, J. D., Americano, B. B., Ha, C., Marland, G., Matsika, E., . . . Treanton, K. (2006). *2006 IPCC Guidelines for National Greenhouse Gas Inventories* (Vol. 2).
- [17] *Google Cloud*. (Junho de 2025). Obtido de Google Cloud: <https://cloud.google.com/discover/what-is-a-neural-network?hl=pt-BR>
- [18] Guidião, E. E. (2012). *Formas de Energias Renovaveis em Moçambique e suas Potencialidade*. Exame de Estado, Universidade Eduardo Mondlane - Faculdade de Ciencias, Departamento de Fisica, Maputo.
- [19] Haykin, S. (2001). *Redes neurais: princípios e prática* (2ª ed.). (P. M. Engel, Trad.) Porto Alegre: Bookman.

- [20] (2023). *Indicadores Basicos de Energia, Gás e Petróleo*. Maputo: Instituto Nacional de Estatística.
- [21] Lindemann, B., Müller, T., Vietz, H., Jazdi, N., & Weyrich, M. (2021). A survey on long short-term memory networks for time series prediction. *Procedia CIRP*, 99. doi.org/10.1016/j.procir.2021.03.088
- [22] Machado, W. C., & Fonseca Júnior, E. S. (2013). Redes Neurais Artificiais aplicadas na previsão do VTEC no Brasil. *Boletim de Ciências Geodesicas*, 19, 227-246. doi:10.1590/S1982-21702013000200005
- [23] macrotrends. (2025). *macrotrends*. Obtido de <https://www.macrotrends.net/global-metrics/countries/moz/mozambique/population>
- [24] Muraina, S. A., Ainbamiwa, B. P., Abiola, D. S., & Charles, S. I. (2025). *Artificial intelligence-Driven Renewable Energy Solutions for Rural Electrification in Africa*. International Institute of Academic Research and Development . doi:10.56201/ijemt.vol.11.no3. 2025.pg81.102
- [25] Nhambiu, J. (Outubro de 2023). Aulas Sistemas energeticos. Cidade de Maputo, Moçambique. Obtido de <https://nhambiu.uem.mz/aulas-de-sistemas-energeticos/>
- [26] Nhambiu, J., & Chichango, F. (2024a). Comprehensive Analysis of the Energy Transition in Mozambique: Opportunities and Challenges for Achieving the Established Global Goals. *Jornal of Energy Technologies and Policy*, 4. doi: 10.7176/JETP/14-2-04
- [28] Nhambiu, J., & Chichango, F. (2024b). Forecasting energy consumption in Mozambique: A comparative analysis of advanced machine learning models from 2025 to 2045. *Research, Society and Development*. doi:10.33448/rsd-v13i9.46830
- [29] Oliveira, H. N., & Silva, K. I. (2024). Fontes de Energia No Brasil. *Revista Contribuciones A Las Ciencias Sociales*, 01-10.
- [30] (2022). *Projectos Prioritarios 2021-2030*. Cidade de Maputo: Electricidade de Moçambique E.P.


- [31] Quaschnig, V. (2016). *Understanding Renewable Energy Systems* (2ª ed.). Londres: Routledge.
- [32] Santos, A. M., Seixas, J. M., & Pereira, B. B. (2005). Usando Redes Neurais Artificiais e Regressão Logística na predição da Hepatite A. *Revista Brasileira de Epidemiologia*, 8, 117-126. doi:10.1590/S1415-790X2005000200004
- [33] Shiri, F. M., Perumal, T., Mustapha, N., & Mohamed, R. (2024). A Comprehensive Overview and Comparative Analysis on Deep Learning Models: CNN, RNN, LSTM, GRU. *Jornal on Artificial Intelligence*, 301-360. doi:10.32604/jai.2024.054314
- [34] Silva, M. V., & Bermann, C. (2002). O planejamento energético como ferramenta de auxílio às tomadas de decisão sobre a oferta de energia na zona rural. *AGRENER 4º Encontro de Energia no Meio Rural*. Campinas. Obtido de http://www.proceedings.scielo.br/scielo.php?script=sci_arttext&pid=MSC000000022002000200034&lng=en&nrm=iso
- [35] Soares, J. A., & Cândido, G. A. (2020). Planejamento Energetico No Brasil: A Caminho De Uma Política Energética De Inserção Da Matriz Nos Moldes Da Sustentabilidade. *Revista de Gestão e Sustentabilidade Ambiental*, 9, 637-662. doi:10.19177/rgsa.v9e32020637-662
- [36] Spörl, C., Castro, E., & Luchiari, A. (2011). APLICAÇÃO DE REDES NEURAIIS ARTIFICIAIS NA CONSTRUÇÃO DE MODELOS DE FRAGILIDADE AMBIENTAL. *Revista Do Departamento De Geografia*, 113-135. doi:10.7154/RDG.2011.0021.0006

Anexos


Anexo A. Desempenho Do Modelo LSTM Com Activação ELU




Anexo B. Desempenho Do Modelo LSTM Com Activação Relu




Anexo C. Desempenho Do Modelo LSTM Com Activação Tanh




Anexo D. Desempenho Do Modelo LSTM Com Activação Leakyrelu



Anexo E. Desempenho Do Modelo GRU Com Activação Leakyrelu



Anexo F. Projecção Futura Das Pontas Máximas (2026-2045)



Anexo G. Resultado Óptimo Na Perspectiva de Combustíveis Fosseis

Ano	Solução	Custo_total	Emissão_CO2	Emissão_N2O	nucl	lig1	lig2	carv	oleo	tur_gas_oleo	gas_natural	eolica	solar	bio	hidro1	hidro2	Pmax	Demanda
2027	2	1412929,56480	1331164,42895	2,47506	0,0	0,0	0,0	0,00088	0,0	60678,94081	6511079,99338	0,00000	490535,85949	0,0	4029577,23212	833949,08090	1361,33118	11925261,14326
2028	3	1606081,52689	1497715,17211	2,66973	0,0	0,0	0,0	0,00000	0,0	0,93391	7415898,81251	0,00000	489998,71313	0,0	4029571,81195	833924,65728	1456,43059	12758331,99584
2029	4	1981754,79556	1853948,06067	3,30987	0,0	0,0	0,0	0,00000	0,0	3059,57395	9175737,22621	0,00000	490530,08952	0,0	4029439,85010	833921,98283	1657,87801	14523011,34193
2030	1	861144,01123	768111,97618	1,36918	0,0	0,0	0,0	0,00000	0,0	0,03279	3803287,62154	0,00000	490375,68717	0,0	9985462,88920	1184115,33446	1764,09279	15453452,82427
2031	98	95105,48700	0,00000	0,00000	0,0	0,0	0,0	0,00000	0,0	0,00000	0,00000	0,00000	448503,02752	0,0	20423616,26101	1146684,19056	2028,46250	17769331,51990
2032	8	133161,40200	0,00000	0,00000	0,0	0,0	0,0	0,00000	0,0	0,00000	0,00000	0,00000	297881,21260	0,0	28643445,43619	1002999,87536	2164,99363	18965344,21835
2033	85	133161,40200	0,00000	0,00000	0,0	0,0	0,0	0,00000	0,0	0,00000	0,00000	0,00000	334887,79051	0,0	29164509,52912	341397,02703	2408,79922	21101081,17730
2034	8	133161,40200	0,00000	0,00000	0,0	0,0	0,0	0,00000	0,0	0,00000	0,00000	0,00000	440259,76738	0,0	29180272,30644	934772,93385	2652,21153	23233372,96708
2035	93	133161,40200	0,00000	0,00000	0,0	0,0	0,0	0,00000	0,0	0,00000	0,00000	0,00000	215036,93539	0,0	29151557,76625	428454,64677	2975,48101	26065213,63849
2036	55	133161,40200	0,00000	0,00000	0,0	0,0	0,0	0,00000	0,0	0,00000	0,00000	0,00000	457043,15143	0,0	29190980,66755	810851,83416	3208,48156	28106298,42399
2037	97	133161,40200	0,00000	0,00000	0,0	0,0	0,0	0,00000	0,0	0,00000	0,00000	0,00000	486033,59097	0,0	29204796,88623	1153974,74893	3481,54381	30498323,79941
2038	1	741118,49835	575176,04926	1,02527	0,0	0,0	0,0	0,00000	0,0	0,00002	2847970,14119	0,00000	490520,94134	0,0	29223265,74180	1184219,46973	3852,12831	33744644,00036
2039	2	1548989,38072	1339486,53334	2,38768	0,0	0,0	0,0	0,00010	0,0	0,00122	6632434,80913	0,00000	485802,70107	0,0	29220283,88980	1184132,94333	4281,22615	37503541,03523
2040	1	2006650,49215	1770876,73445	3,17397	0,0	0,0	0,0	0,00000	0,0	10286,40563	8754865,98486	0,00000	472644,94983	0,0	30273227,84505	1183174,35305	4641,15882	40656551,30338
2040	3	2006650,49215	1770876,73445	3,17397	0,0	0,0	0,0	0,00000	0,0	10286,40563	8754865,98486	0,00000	472644,94983	0,0	30273227,84505	1183174,35305	5091,76833	44603890,58122
2041	1	2839274,19586	2556932,21885	4,56457	0,0	0,0	0,0	0,00000	0,0	4014,29369	12655285,04611	0,00000	490083,52250	0,0	30274528,19521	1184140,67380	5707,86717	50000916,37720
2041	2	2839274,19586	2556932,21885	4,56457	0,0	0,0	0,0	0,00000	0,0	4014,29369	12655285,04611	0,00000	490505,60546	0,0	30274528,19521	1184140,67380	6329,19310	55443731,53477
2042	4	3992085,27534	3646642,15926	6,50107	0,0	0,0	0,0	0,00000	0,0	484,66109	18055619,30080	0,00000	488693,32742	0,0	30274548,53893	1184349,28013	7191,84145	63000531,10276
2043	2	5135999,40594	4750192,22117	8,60278	0,0	0,0	0,0	0,00015	0,0	80390,87692	23414275,86941	0,00000	490548,61213	0,0	30274553,06161	1184320,39359	7307,16735	64010786,02355

Anexo H. Resultado Óptimo Na Perspectiva De Energias Nucleares

Ano	Solução	Custo_total	Emissão_CO2	Emissão_N2O	nucl	lig1	lig2	carv	oleo	tur_gas_oleo	gas_natural	eolica	solar	bio	hidro1	hidro2	Pmax	Demanda
2027	2	1576425,83740	1108669,49482	2,03707	1109585,88942	0,00000	0,00000	0,00604	0,00000	36114,67015	5441847,61459	0,00000	490041,54826	0,00000	4025390,33341	830116,51881	1361,33118	11925261,14326
2028	1	1647340,56394	1451534,36096	2,58741	228698,19621	0,00000	0,00000	0,07413	0,00000	0,78212	7187235,73099	0,00000	490538,28203	0,00000	4021326,46372	832968,67249	1456,43059	12758331,99584
2029	2	2445504,02522	1148308,58857	2,04713	3495331,52779	0,00000	0,00000	0,01238	0,00000	139,22255	5685637,97913	0,00000	485890,08589	0,00000	4028092,18463	833631,65989	1657,87801	14523011,34193
2030	1	881357,23676	748605,92446	1,41209	122880,19019	0,00000	0,00000	0,41315	0,00000	46111,72753	3645796,29593	0,00000	489722,18326	0,00000	9985546,69217	1179816,65047	1764,09279	15453452,82427
2031	95	106855,96700	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	112931,53796	0,00000	19812555,55336	703400,62305	2028,46250	17769331,51990
2032	36	144911,88200	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	69289,73898	0,00000	29144456,04940	645206,95246	2164,99363	18965344,21835
2033	5	144911,88200	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	59685,16095	0,00000	29190305,84858	300814,41859	2408,79922	21101081,17730
2034	56	148626,48200	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	238027,59039	0,00000	29171018,90793	1127588,08800	2652,21153	23233372,96708
2035	72	148626,48200	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	258717,84820	0,00000	29120409,49553	1068409,65322	2975,48101	26065213,63849
2036	91	148626,48200	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	450580,31624	0,00000	29201172,01255	812865,40565	3208,48156	28106298,42399
2037	23	148626,48200	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	473545,20980	0,00000	29222847,84882	1177519,45905	3481,54381	30498323,79941
2038	2	762596,08751	578015,79133	1,03642	922,23603	0,00000	0,00000	0,00035	0,00000	3615,76213	2857255,15432	0,00000	490406,13652	0,00000	29223103,69343	1183897,86303	3852,12831	33744644,00036
2039	2	1863735,55235	856379,66724	1,57863	2379594,73338	0,00000	0,00000	0,02208	0,00000	30935,23858	4199481,95764	0,00000	490328,02867	0,00000	29223341,78987	1183290,65629	4281,22615	37503541,03523
2040	1	3116119,76541	18836,96747	0,15253	8640845,40867	0,00000	0,00000	0,00009	0,00000	70613,91220	0,00119	0,00000	490319,82773	0,00000	30274554,54065	1184332,67875	4641,15882	40656551,30338
2041	2	3658770,64262	1294745,04128	2,42780	6277005,25818	0,00000	0,00000	0,00698	0,00000	71165,09651	6316899,57810	0,00000	488834,43713	0,00000	30273254,19119	1181781,16183	5091,76833	44603890,58122
2042	2	6060954,54400	424962,96527	0,87292	15973713,21841	0,00000	0,00000	0,01575	0,00000	68515,36738	2013694,79521	0,00000	490415,17573	0,00000	30272800,62543	1181884,27787	5707,86717	50000916,37720
2043	2	7266341,76754	1465397,69348	2,67471	16256410,17643	0,00000	0,00000	0,19932	0,00000	37160,68788	7206796,60167	0,00000	490152,43192	0,00000	30274485,53838	1180848,60358	6329,19310	55443731,53477
2044	1	10298262,78450	775405,48131	1,46902	27240225,87466	0,00000	0,00000	0,06496	0,00000	51550,12785	3771310,89179	0,00000	490394,17847	0,00000	30271328,38750	1177696,27138	7191,84145	63000531,10276
2045	2	10568321,47894	899748,80233	1,63667	32605636,25412	0,00000	0,00000	0,12921	0,00000	1,88051	15,69013	0,00000	488290,95859	0,00000	30274110,84371	1167041,86015	7307,16735	64010786,02355

Anexo I. Resultado Óptimo da Perspectiva de Energias Renováveis

Ano	Solu ção	Custo_total	Emissão_CO2	Emissão_N2 O	nuc l	lig 1	lig 2	carv	ole o	tur_gas_ole o	gas_natural	eolica	solar	bio	hidro1	hidro2	Pmax	Demanda
2027	62	23656,57700	0,00000	0,000	0,0	0,0	0,0	0,00000	0,0	0,00000	0,00000	12333877,6399 2	1971661,6518 8	0,0	3343064,4884 6	697519,58675	1361,3311 8	11925261,1432 6
2028	85	24327,37700	0,00000	0,000	0,0	0,0	0,0	0,00000	0,0	0,00000	0,00000	12899909,0815 0	3152938,3225 1	0,0	3689674,3968 0	569654,69476	1456,4305 9	12758331,9958 4
2029	62	24432,67700	0,00000	0,000	0,0	0,0	0,0	0,00000	0,0	0,00000	0,00000	14687707,8096 4	3032329,7757 9	0,0	2948706,2203 2	729326,82437	1657,8780 1	14523011,3419 3
2030	81	50680,42700	0,00000	0,000	0,0	0,0	0,0	0,00000	0,0	0,00000	0,00000	9475738,28469	3759428,7933 2	0,0	9206815,4288 1	902488,14830	1764,0927 9	15453452,8242 7
2031	93	96530,92700	0,00000	0,000	0,0	0,0	0,0	0,00000	0,0	0,00000	0,00000	11779153,4351 7	3708444,7909 0	0,0	18941253,154 29	637786,01903	2028,4625 0	17769331,5199 0
2032	62	134586,84200	0,00000	0,000	0,0	0,0	0,0	0,00000	0,0	0,00000	0,00000	13702259,9712 2	931494,36050	0,0	23094492,379 78	1079255,2642 2	2164,9936 3	18965344,2183 5
2033	99	134586,84200	0,00000	0,000	0,0	0,0	0,0	0,00000	0,0	0,00000	0,00000	12168244,4651 7	491210,19290	0,0	24637152,616 08	356251,21291	2408,7992 2	21101081,1773 0
2034	62	134586,84200	0,00000	0,000	0,0	0,0	0,0	0,00000	0,0	0,00000	0,00000	15036190,7706 7	331436,76466	0,0	28985030,136 43	1182149,2930 7	2652,2115 3	23233372,9670 8
2035	65	134586,84200	0,00000	0,000	0,0	0,0	0,0	0,00000	0,0	0,00000	0,00000	12448641,0835 9	1469438,4303 4	0,0	29021668,275 39	547546,20935	2975,4810 1	26065213,6384 9
2036	58	134586,84200	0,00000	0,000	0,0	0,0	0,0	0,00000	0,0	0,00000	0,00000	15114471,4145 7	1858370,1417 6	0,0	25337738,246 14	1180479,8997 6	3208,4815 6	28106298,4239 9
2037	77	134586,84200	0,00000	0,000	0,0	0,0	0,0	0,00000	0,0	0,00000	0,00000	13692867,2164 9	3555856,0973 2	0,0	28950627,068 44	806223,23488	3481,5438 1	30498323,7994 1
2038	21	134797,44200	0,00000	0,000	0,0	0,0	0,0	0,00000	0,0	0,00000	0,00000	13533603,8389 7	3307812,2076 2	0,0	28571373,140 54	1121270,3083 4	3852,1283 1	33744644,0003 6
2039	33	134797,44200	0,00000	0,000	0,0	0,0	0,0	0,00000	0,0	0,00000	0,00000	14890213,5417 4	4827154,8517 1	0,0	28042246,569 65	366236,24666	4281,2261 5	37503541,0352 3
2040	88	139382,49200	0,00000	0,000	0,0	0,0	0,0	0,00000	0,0	0,00000	0,00000	14802640,9042 6	4554901,1506 8	0,0	30268272,982 35	299747,49395	4641,1588 2	40656551,3033 8
2041	78	139487,79200	0,00000	0,000	0,0	0,0	0,0	0,00000	0,0	0,00000	0,00000	14615891,7101 2	5181266,3170 6	0,0	30219341,804 89	779271,27763	5091,7683 3	44603890,5812 2
2042	20	139733,49200	0,00000	0,000	0,0	0,0	0,0	0,00000	0,0	0,00000	0,00000	15260525,4632 5	6201519,4377 2	0,0	30241328,739 62	1093351,9611 3	5707,8671 7	50000916,3772 0
2043	1	533578,50774	372463,88652	0,664	0,0	0,0	0,0	0,00000	0,0	0,00001	1844245,8249 8	15697825,9226 0	6447067,5561 4	0,0	30274539,296 94	1184020,9732 9	6329,1931 0	55443731,5347 7
2044	68	2186869,2236 1	1830454,0647 3	7,725	0,0	0,0	0,0	898317,2420 2	0,0	92683,2463 5	7426217,8820 1	16118398,4754 8	7007982,8404 6	0,0	30274559,662 28	1184342,4547 7	7191,8414 5	63000531,1027 6

Anexo J. Código Do Programa Python Para As Redes Neurais Artificiais

```
pontas = pd.concat(pontas_lista, axis=0, ignore_index=True)
pontas = pontas.sort_values('Data').reset_index(drop=True)
pontas['Data'] = pd.to_datetime(pontas['Data'])
pontas['Valor'] = pd.to_numeric(pontas['Valor'], errors='coerce')
pontas.set_index('Data', inplace=True)
resultado = seasonal_decompose(pontas['Valor'], model='additive', period=365)
resultado.plot()
plt.show()
tendencia = resultado.trend.dropna()
sazonalidade = resultado.seasonal.dropna()
residuos = resultado.resid.dropna()
dados_completos = pd.DataFrame({
    'trend': tendencia,
    'seasonal': sazonalidade,
    'resid': residuos
}).dropna()
scaler_trend = StandardScaler()
scaler_resid = StandardScaler()
dados_completos['trend_norm'] = scaler_trend.fit_transform(dados_completos[['trend']])
dados_completos['resid_norm'] = scaler_resid.fit_transform(dados_completos[['resid']])
def criar_sequencias(data, janela):
    X, y = [], []
    for i in range(janela, len(data)):
        valores = data[i-janela:i]
        tempos = np.arange(i-janela, i) # Dias corridos
        sequencia = np.stack((valores, tempos / len(data)), axis=1) # Normaliza tempo
        X.append(sequencia)
        y.append(data[i])
    return np.array(X), np.array(y)
janela = 1095
```

```

X_trend, y_trend = criar_sequencias(dados_completos['trend_norm'].values, janela)
X_resid, y_resid = criar_sequencias(dados_completos['resid_norm'].values, janela)
X_train_trend, X_test_trend, y_train_trend, y_test_trend = train_test_split(X_trend, y_trend,
test_size=0.2, shuffle=False)
X_train_resid, X_test_resid, y_train_resid, y_test_resid = train_test_split(X_resid, y_resid,
test_size=0.2, shuffle=False)
def treinar_gru(X_train, y_train, X_test, y_test):
    #X_train = X_train.reshape((X_train.shape[0], X_train.shape[1], 1))
    #X_test = X_test.reshape((X_test.shape[0], X_test.shape[1], 1))
    model = Sequential()
    model.add(GRU(128, return_sequences=True, input_shape=(X_train.shape[1], X_train.shape[2])))
    model.add(GRU(64))
    model.add(Dense(1, activation='linear'))
    model.compile(optimizer=Adam(learning_rate=0.0001), loss='mae')
    model.fit(X_train, y_train, epochs=60, batch_size=16, validation_data=(X_test, y_test))
    y_pred = model.predict(X_test)
    return y_test, y_pred, model
y_test_trend, y_pred_trend, model_trend = treinar_gru(X_train_trend, y_train_trend, X_test_trend,
y_test_trend)
y_test_resid, y_pred_resid, model_resid = treinar_gru(X_train_resid, y_train_resid, X_test_resid,
y_test_resid)
y_pred_trend_inv = scaler_trend.inverse_transform(y_pred_trend)
y_pred_resid_inv = scaler_resid.inverse_transform(y_pred_resid)
y_test_trend_inv = scaler_trend.inverse_transform(y_test_trend.reshape(-1, 1)).flatten()
y_test_resid_inv = scaler_resid.inverse_transform(y_test_resid.reshape(-1, 1)).flatten()
# === Sazonalidade histórica fixa ===
sazonalidade.index = pd.to_datetime(sazonalidade.index)
sazonalidade_df = sazonalidade.to_frame(name='sazonalidade')
sazonalidade_df['dia_do_ano'] = sazonalidade_df.index.dayofyear
sazonalidade_media = sazonalidade_df.groupby('dia_do_ano').mean()
# Recuperar as datas reais para o conjunto de teste
data_inicio = dados_completos.index[janela + len(y_train_trend)]

```

```

datas_teste = pd.date_range(start=data_inicio, periods=len(y_test_trend))
dias_do_ano = datas_teste.dayofyear

# Obter a sazonalidade correspondente a cada dia do ano
sazonalidade_teste = sazonalidade_media.loc[dias_do_ano].values.flatten()

# Reconstituir série final
final_real = y_test_trend_inv + sazonalidade_teste + y_test_resid_inv
final_pred = y_pred_trend_inv.flatten() + sazonalidade_teste + y_pred_resid_inv.flatten()

plt.figure(figsize=(16, 6))

plt.plot(final_real, label='Real', color='black')
plt.plot(final_pred, label='Previsão', color='orange')
plt.legend()

plt.title("Previsão GRU baseada em decomposição")
plt.show()

print("R2 tendencia:", r2_score(y_test_trend, y_pred_trend))
print("R2 residuo:", r2_score(y_test_resid, y_pred_resid))
print("RMSE:", root_mean_squared_error(final_real, final_pred))
print("MAE:", mean_absolute_error(final_real, final_pred))
print("R2:", r2_score(final_real, final_pred))

dias_prev = 8037

# Última sequência de entrada
entrada_trend = dados_completos['trend_norm'].values[-janela:].reshape(1, janela, 1)
entrada_resid = dados_completos['resid_norm'].values[-janela:].reshape(1, janela, 1)
pred_trend_futuro = []
pred_resid_futuro = []

for _ in range(dias_prev):
    pred_t = model_trend.predict(entrada_trend)[0, 0]
    pred_r = model_resid.predict(entrada_resid)[0, 0]
    pred_trend_futuro.append(pred_t)
    pred_resid_futuro.append(pred_r)

# Atualizar entradas com o novo valor previsto
entrada_trend = np.append(entrada_trend[:, 1:, :], [[[pred_t]]], axis=1)

```

```

    entrada_resid = np.append(entrada_resid[:, 1:, :], [[[pred_r]]], axis=1)

# Desnormalizar previsões

trend_futuro_real = scaler_trend.inverse_transform(np.array(pred_trend_futuro).reshape(-1,
1)).flatten()

resid_futuro_real = scaler_resid.inverse_transform(np.array(pred_resid_futuro).reshape(-1,
1)).flatten()

# Obter sazonalidade do próximo ano (baseando-se no último dia conhecido)

ultimo_dia = pontas.index[-1]

datas_futuras = pd.date_range(start=ultimo_dia + pd.Timedelta(days=1), periods=dias_prev)

dias_futuros_do_ano = datas_futuras.dayofyear

sazonalidade_futura = sazonalidade_media.loc[dias_futuros_do_ano].values.flatten()

# Previsão final

previsao_final = trend_futuro_real + sazonalidade_futura + resid_futuro_real

previsao_final = pd.DataFrame(previsao_final)

import xlswriter

writer = pd.ExcelWriter('Pontas_Maximas_2024-2045.xlsx', engine='xlswriter')

previsao_final.to_excel(writer, sheet_name='Sistemas Interligados')

writer.close()

# Plotagem

plt.figure(figsize=(16, 6))

plt.plot(datas_futuras, previsao_final, label='Previsão 3 Ano', color='green')

plt.title("Previsão para o Próximo Ano (Carga Diária em MW)")

plt.xlabel("Data")

plt.ylabel("Carga (MW)")

plt.legend()

plt.grid(True)

plt.tight_layout()

plt.show()

```

Anexo K. Código Do Programa Em Python Para A Optimização Da Matriz Energética

```
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
from pymoo.core.problem import ElementwiseProblem
from pymoo.optimize import minimize
from pymoo.algorithms.moo.nsga2 import NSGA2
from pymoo.factory import get_sampling, get_crossover, get_mutation
import os
from IPython.display import display

# ===== 1. Carregamento dos dados =====
df_cap = pd.read_excel("nuclear_cap.xlsx")
df_pmax = pd.read_excel("Pontas_Maximas_2024-2045r.xlsx")
df_pmax["Ano"] = df_pmax["Data"].dt.year
pmax_ano = df_pmax.groupby("Ano")["Valor"].max().to_dict()

# ===== 2. Extração dos parâmetros =====
def extrair_parametros_para_ano(df, ano):
    linha = df[df["Ano"] == ano].iloc[0]

    fontes = [
        "nucl", "lig1", "lig2", "carv", "oleo", "tur_gas_oleo", "gas_natural", "eolica",
        "solar", "bio", "hidro1", "hidro2"
    ]

    capacidade = np.array([linha[f"c_{f}[MW]"] for f in fontes])
    cust_fix = np.array([linha[f"cust_fix_{f}"] for f in fontes])
    op_man = np.array([linha[f"Op&Man_{f}"] for f in fontes])
    co2 = np.array([linha[f"CO2_{f}"] for f in fontes])
    n2o = np.array([linha[f"N2O_{f}"] for f in fontes])

    return capacidade, cust_fix, op_man, co2, n2o, fontes

# ===== 3. Classe de otimização =====
class EnergyMatrixOptimization(ElementwiseProblem):
```

```

def __init__(self, capacidade, cust_fix, op_man, co2, n2o, pmax, limite_frac=0.8):
    self.capacidade = capacidade
    self.cap_maxima_utilizada = limite_frac * capacidade
    self.cust_fix = cust_fix
    self.op_man = op_man
    self.co2 = co2
    self.n2o = n2o
    self.pmax = pmax
    super().__init__(n_var=len(capacidade), n_obj=3, n_constr=1, xl=0.0, xu=1.0)
def _evaluate(self, x, out, *args, **kwargs):
    cap_ativada = x * self.cap_maxima_utilizada
    energia = cap_ativada * 8760
    custo = np.sum(cap_ativada * 1000 * self.op_man + self.cust_fix * self.capacidade)
    co2_total = np.sum(self.co2 * energia)
    n2o_total = np.sum(self.n2o * energia)
    out["F"] = [custo, co2_total, n2o_total]
    out["G"] = [self.pmax - np.sum(cap_ativada)]
# ===== 4. Função para otimização de um ano =====
def otimizar_ano(ano):
    capacidade, cust_fix, op_man, co2, n2o, fontes = extrair_parametros_para_ano(df_cap, ano)
    pmax = pmax_ano.get(ano, None)
    if pmax is None:
        raise ValueError(f"Pmax não encontrado para o ano {ano}")
    problema = EnergyMatrixOptimization(capacidade, cust_fix, op_man, co2, n2o, pmax)
    algoritmo = NSGA2(
        pop_size=100,
        sampling=get_sampling("real_random"),
        crossover=get_crossover("real_sbx", prob=0.9, eta=15),
        mutation=get_mutation("real_pm", eta=20),
        eliminate_duplicates=True
    )

```

```

    resultado = minimize(problema, algoritmo, ("n_gen", 200), seed=1, verbose=False)

    return resultado, fontes

# ===== 5. Loop sobre os anos e salvar resultados =====
resultados_excel = []

os.makedirs("graficos_pareto", exist_ok=True)

for ano in range(2027, 2046):
    print(f"Otimizando ano {ano}...")

    try:
        res, fontes = otimizar_ano(ano)

        # Verifica se houve solução
        if res.X is None or res.F is None:
            print(f"Aviso: Nenhuma solução encontrada para o ano {ano}.")
            continue

        for i, (x, f) in enumerate(zip(res.X, res.F)):
            linha = {
                "Ano": ano,
                "Solução": i + 1,
                "Custo_total": f[0],
                "Emissão_CO2": f[1],
                "Emissão_N2O": f[2],
            }

            for nome, frac in zip(fontes, x):
                linha[f"{nome}_frac"] = frac

            resultados_excel.append(linha)

    except Exception as e:
        print(f"✗ Erro ao otimizar o ano {ano}: {e}")

# ===== 6. Exportar resultados =====
df_resultados = pd.DataFrame(resultados_excel)

df_resultados.to_excel("resultados_otimizacao_2027_2045-nuclear.xlsx", index=False)

print("✅ Otimização concluída e resultados salvos.")

```