

PREDIÇÃO DE DESEMPENHO ENERGÉTICO EM EDIFICAÇÕES: uma abordagem baseada em treinamento de redes neurais de múltiplas camadas

Cláudio Augusto¹, João Igor Gomes de Sena², João Vitor Chendynski³ Matheus Yrwayne Almeida dos Santos⁴, Vinicius Nazário de Carvalho⁵ e Renato Kazuo Miyamoto⁶

RESUMO

A eficiência energética em edificações é uma estratégia essencial para a redução do consumo de recursos naturais e para a promoção da sustentabilidade ambiental. Este estudo teve como objetivo analisar a influência de variáveis arquitetônicas no desempenho térmico de edifícios, por meio da aplicação de algoritmos de aprendizado de máquina em uma base de dados simulada, conhecida como *Energy Efficiency Data Set*. A metodologia envolveu análise exploratória, pré-processamento dos dados e aplicação de rede neural PMC aproximador (Perceptron múltiplas camadas) avaliados por métricas estatísticas como erro quadrático médio, coeficiente de Pearson e variância. Os resultados apontaram que a rede neural assumiu boa eficiência em sua aproximação, porém é necessário subdividir os modelos de edifícios para que evite a dispersão entre os dados, proporcionando uma menor variância. Constatou-se que a altura total do edifício e a área do telhado são os principais determinantes do desempenho energético. Conclui-se que o uso de técnicas de inteligência artificial pode subsidiar decisões mais conscientes e sustentáveis no processo de concepção arquitetônica.

Palavras-chave: eficiência energética; neurais; aproximador; Perceptron; inteligência artificial

BUILDING ENERGY PERFORMANCE PREDICTION: an approach based on training multi-layer neural networks.

ABSTRACT

Energy efficiency in buildings is an essential strategy for the reduction of natural resource consumption and for the promotion of environmental sustainability. This study aimed to analyze the influence of architectural variables on the thermal performance of buildings through the application of machine learning algorithms on a simulated database, known as the Energy Efficiency Data Set. The methodology involved exploratory analysis, data preprocessing, and the application of an MLP (Multi-Layer Perceptron) approximation neural network, evaluated by statistical

¹ Centro Universitário UniSenaiPR, Londrina/PR-Brasil; e-mail: Clausto@bol.com.br

² Centro Universitário UniSenaiPR, Londrina/PR-Brasil; e-mail: jsena8916@gmail.com

³ Centro Universitário UniSenaiPR, Londrina/PR-Brasil; joaovitorchendynski@hotmail.com

⁴ Centro Universitário UniSenaiPR, Londrina/PR-Brasil; e-mail: matheus.mat.yrwayne@gmail.com

⁵ Centro Universitário UniSenaiPR, Londrina/PR-Brasil; e-mail: vinicius.nazarioc@gmail.com

⁶ Centro Universitário UniSenaiPR, Londrina/PR-Brasil; e-mail: renato.miyamoto@sistemafiep.org.br

metrics such as mean squared error, Pearson coefficient, and variance. The results indicated that the neural network achieved good efficiency in its approximation; however, it is necessary to subdivide the building models to avoid data dispersion, providing lower variance. It was found that the total height of the building and the roof area are the main determinants of energy performance. It is concluded that the use of artificial intelligence techniques can support more conscious and sustainable decisions in the architectural design process.

Key words: Energy efficiency; neural; approximator; Perceptron; artificial intelligence

1 INTRODUÇÃO

O crescente consumo de energia no setor da construção civil tem impulsionado a busca por soluções que promovam maior eficiência energética em edificações. Edifícios comerciais e residenciais são responsáveis por uma parcela significativa da demanda energética global, sendo que grande parte desse consumo é destinada aos sistemas de climatização, como aquecimento e resfriamento ambiental. Diante desse cenário torna-se fundamental o desenvolvimento de estratégias que permitam projetar construções mais eficientes, considerando variáveis arquitetônicas que influenciem diretamente o desempenho térmico das edificações (Siqueira; Tiba; Fraidenaich, 2008).

Nesse contexto, o conceito de eficiência energética em edificações ganhou destaque por representar uma estratégia eficaz na busca por construções sustentáveis, capazes de reduzir o impacto ambiental e os custos operacionais ao longo do ciclo de vida do edifício (Alves; Oliveira; Carvalho, 2019). Partindo deste princípio, surtiu-se em analisar o comportamento de diferentes edifícios quando submetidos a cargas térmicas, porém o seu resultado de carga de aquecimento e resfriamento não é tão trivial. Nesse sentido, a implementação de uma rede neural contribui para o desenvolvimento de estruturas mais sustentáveis.

Com o passar dos séculos o homem buscou a possibilidade de criar mecanismos que reproduzisse as características dos seres humanos, como realizar atividades, cálculos e interagisse conosco. Estes anseios acompanham mais de 700

anos na história da humanidade (Catarino, 2025). Ainda, Catarino (2025) menciona que a realidade em que vivemos é um futuro inimaginável, visto que as máquinas tem a capacidade de detectar objetos, figuras, reproduzir um roteiro de um filme, entre outras ações, isto evidencia como os avanços tecnológicos tem impactado em vários segmentos de negócios, principalmente naqueles que realizam tarefas rotineiras e repetitivas, otimizando assim o rendimento e produção das demandas.

E para a avaliação dos diferentes modelos de construção de edifícios, pode se utilizar de uma rede PMC que tem os seus neurônios (unidades de processamento de informação) organizados em camadas sem conexões laterais e os sinais de entrada se propagam de trás para frente através da rede que é treinada por um algoritmo de retro propagação. (Siqueira; Tiba; Fraidenraich, 2008).

A utilização de modelos preditivos baseados em aprendizado de máquina tem se mostrado uma alternativa viável para estimar o consumo energético de edifícios, especialmente em fases iniciais de projeto. Esses modelos permitem analisar como variáveis geométricas e estruturais impactam nas cargas térmicas, oferecendo aos profissionais de arquitetura e engenharia subsídios para decisões mais sustentáveis. Nesse contexto, a base de dados *Energy Efficiency*, disponibilizada pela UCI Machine Learning Repository, apresenta-se como um recurso valioso para estudos nessa área, por reunir informações simuladas de edificações com diferentes características construtivas e arquitetônicas.

A referida base de dados contempla variáveis contínuas e discretas que representam elementos do projeto arquitetônico, como compactidade relativa, área superficial, área das paredes, área do telhado, altura total, orientação solar, área de envidraçamento e sua distribuição. As variáveis de saída são as cargas térmicas de aquecimento e resfriamento, calculadas por meio de simulações computacionais. A análise dessas variáveis, aliada a técnicas de regressão multivariada, possibilita identificar quais aspectos construtivos mais influenciam no desempenho energético de uma edificação.

Dessa forma, o presente artigo tem como objetivo realizar uma análise exploratória e preditiva sobre a base de dados *Energy Efficiency*, buscando compreender as relações entre os parâmetros arquitetônicos e as cargas térmicas envolvidas. A partir da aplicação da rede neural, pretende-se avaliar a acurácia das previsões e pela SHAP values pode-se identificar as variáveis mais relevantes para o consumo energético, contribuindo com informações que possam apoiar decisões em projetos de construção sustentável.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Eficiência e contribuição das redes neurais na engenharia

A preocupação com a sustentabilidade no setor da construção civil tem se intensificado nas últimas décadas, impulsionada por fatores como a escassez de recursos naturais, o aumento das emissões de gases de efeito estufa e a crescente demanda por eficiência no uso da energia. Nesse contexto, o conceito de eficiência energética em edificações ganhou destaque por representar uma estratégia eficaz na busca por construções sustentáveis, capazes de reduzir o impacto ambiental e os custos operacionais ao longo do ciclo de vida do edifício (Alves; Oliveira; Carvalho, 2019).

A eficiência energética refere-se à capacidade de uma edificação utilizar racionalmente a energia, mantendo níveis adequados de conforto térmico, lumínico e acústico para os ocupantes. A literatura aponta que o desempenho energético de um edifício é influenciado por diversos fatores, como características geométricas, materiais construtivos, orientação solar, ventilação natural, além do comportamento dos usuários e das condições climáticas locais (Souza; Moreira, 2020). Em especial, os sistemas de aquecimento e resfriamento representam parcela significativa do consumo energético em edifícios residenciais e comerciais, o que torna a análise das cargas térmicas uma tarefa central em estudos sobre eficiência energética.

Nesse cenário, os avanços em técnicas computacionais e inteligência artificial têm permitido o desenvolvimento de modelos preditivos para estimar o consumo energético de edificações, com base em características do projeto arquitetônico. Segundo Lima et al. (2021), esses modelos permitem reduzir custos e tempo de simulação quando comparados a softwares tradicionais de modelagem energética, como EnergyPlus ou Ecotect.

Dentre os algoritmos mais utilizados para problemas de regressão aplicados à eficiência energética, destacam-se a regressão linear, regressão de árvores (como Random Forest), máquinas de vetor de suporte (Support Vector Machines – SVM) e redes neurais artificiais. Cada um desses métodos possui vantagens e limitações, sendo importante considerar a natureza dos dados, o número de instâncias e a complexidade do problema ao escolher o modelo mais adequado (Ferreira; Santos, 2022).

O uso de bases de dados simuladas, como a *Energy Efficiency Data Set* disponibilizada pela Universidade da Califórnia em Irvine (UCI), tem sido amplamente empregado em pesquisas acadêmicas. Essa base é composta por 768 instâncias geradas a partir de simulações com diferentes configurações geométricas e construtivas de edifícios, variando parâmetros como compacidade, altura, área de envidraçamento e orientação solar. Os dados foram obtidos por meio do software Ecotect, sendo utilizados para prever as cargas térmicas de aquecimento (Heating Load) e resfriamento (Cooling Load) (Tsilimparis; Angelakis, 2012).

Embora o uso de dados simulados apresente algumas limitações, como a ausência de variáveis relacionadas ao comportamento dos usuários ou às condições climáticas reais, esse tipo de base oferece um ambiente controlado e padronizado para experimentação com algoritmos de aprendizado de máquina. Além disso, possibilita a replicação de experimentos e a comparação de diferentes abordagens metodológicas em um cenário comum (Martins; Costa, 2021).

A literatura também destaca as técnicas de análise de importância de variáveis (feature importance), como os valores de SHAP (SHapley Additive exPlanations), que permitem interpretar os modelos de aprendizado de máquina e identificar quais

fatores arquitetônicos mais influenciam no consumo energético (Lundström; Nilsson, 2020). Tais abordagens fortalecem a conexão entre a modelagem computacional e a prática arquitetônica, promovendo projetos mais embasados em dados.

Assim, observa-se que o cruzamento entre engenharia, arquitetura e ciência de dados tem potencial para transformar a forma como são concebidos os projetos de edificações, integrando análises preditivas desde as fases iniciais.

2.2 Redes neurais

As redes neurais são um conjunto de ferramentas computacionais neurais que tem como o objetivo emular o cérebro humano de acordo de uma certa tarefa. Com isso existem as RNAs que estão interligados por sinapses artificiais, representadas por vetores ou matrizes de pesos sinápticos. Essas redes em si oferecem a capacidade não apenas de aprender com dados, mas também de aplicar esse controle de forma eficaz, trazendo maior alternativa para resolver problemas complexos (Lopes, et al., 2013).

A Camada de Entrada é responsável por receber os dados brutos e encaminhá-los aos neurônios da primeira camada oculta, atribuindo um peso inicial a cada conexão. A Camada Oculta (ou Múltiplas Camadas Ocultas) realiza todo o processamento e a remoção de características (recursos) dos dados. A Camada de Saída é a camada final da rede. Depois de treinar os neurônios e ajustar os pesos, o objetivo é gerar um valor final que seja semelhante ou próximo ao resultado desejado. (Catarino, 2025).

Com base em alguns pesquisadores como David E. Rumelhart, Geoffrey E. Hinton e Ronald J. Wiliams, publicaram um artigo a respeito do estudo das redes neurais com base na retropropagação, e este estudo possibilita a novas aplicações, visto que a retropropagação permitiria que camadas intermediárias da Perceptron conseguem ser corrigidas durante a execução, permitindo a resolução de problemas mais complexos (Catarino, 2025).

A rede PMC aproximador permite a integração de redes neurais em um sistema cuja variáveis apresentam uma solução não trivial e complexa, fazendo com que a inteligência artificial seja aplicada de acordo com cada variável, sendo uma forma de interação entre as áreas como a engenharia, diminuição de custos integrado a gestão das estruturas, a área da física e transferência de calor e massa.

3 METODOLOGIA

Este estudo caracteriza-se como uma pesquisa aplicada, de abordagem quantitativa e natureza exploratória e explicativa. É aplicada, pois visa contribuir com soluções práticas no campo da construção civil e da eficiência energética em edificações. Possui caráter exploratório ao investigar as relações entre variáveis arquitetônicas e desempenho energético, e explicativo ao propor modelos preditivos para estimar as cargas térmicas de aquecimento e resfriamento.

Quanto aos meios, trata-se de uma pesquisa documental e experimental computacional, uma vez que utiliza uma base de dados secundária proveniente do repositório público da *University of California, Irvine* (UCI Machine Learning Repository), associada à realização de experimentos com algoritmos de regressão multivariada por meio de linguagem de programação Python.

3.1 Base de Dados

Para o desenvolvimento deste trabalho, foi empregado um conjunto de dados focado na área da engenharia mecânica. Este conjunto de dados visa a relação de carga térmica (aquecimento e resfriamento) com a eficiência energética do edifício, ou seja, conforme o design do edifício varia como área envidraçada, área do telhado, orientação, área de superfície, também irá variar a eficiência energética resultante do edifício.


Figura 1 – Nomeação do conjunto de dados.

Nome da variável	Papel	Tipo	Descrição	Valores ausentes
X1	Recurso	Contínuo	Compacidade relativa	não
X2	Recurso	Contínuo	Área da superfície	não
X3	Recurso	Contínuo	Área da parede	não
X4	Recurso	Contínuo	Área do telhado	não
X5	Recurso	Contínuo	Altura total	não
X6	Recurso	Número inteiro	Orientação	não
X7	Recurso	Contínuo	Área envidraçada	não
X8	Recurso	Número inteiro	Distribuição da área envidraçada	não
Y1	Alvo	Contínuo	Carga de aquecimento	não
Y2	Alvo	Contínuo	Carga de resfriamento	não

Fonte: Adaptado de Tsanas, Xifara (2012).

A figura 1 representa o significado para cada uma das colunas e o método utilizado para o desenvolvimento do projeto foi a utilização do software MatLab, partindo de uma rede neural PMC (Perceptron de múltiplas camadas) aproximador, validando que conforme a variáveis se alteram, será alterado também a eficiência energética, sendo assim a PMC aproximador gerará uma “função” para prever a eficiência do edifício com base nas alterações das variáveis.

Figura 2 – Topografia da rede PMC para aproximação



Fonte: Silva et al. (2010)

A topografia da rede neural descrita figura 2, mostra o funcionamento da rede PMC para aproximação, destaca-se que o conjunto de dados foi fiel ao repositório

público da *University of California, Irvine* (UCI Machine Learning Repository, não submetendo a nenhuma alteração.

Figura 3 – Parte do conjunto de dados de treinamento

	1	2	3	4	5	6	7	8	9	10
1	0.9800	514.5000	294	110.2500	7	2	0	0	15.5500	21.3300
2	0.9800	514.5000	294	110.2500	7	3	0	0	15.5500	21.3300
3	0.9800	514.5000	294	110.2500	7	4	0	0	15.5500	21.3300
4	0.9800	514.5000	294	110.2500	7	5	0	0	15.5500	21.3300
5	0.9000	563.5000	318.5000	122.5000	7	2	0	0	20.8400	28.2800
6	0.9000	563.5000	318.5000	122.5000	7	3	0	0	21.4600	25.3800
7	0.9000	563.5000	318.5000	122.5000	7	4	0	0	20.7100	25.1600

Fonte: Autoria própria (2025).

Para efeito de entendimento do funcionamento da rede, a figura 3 mostra inicialmente os valores da coluna 1 à coluna 8 que assume um valor de entrada e a partir destes dados são calculados pesos aleatórios em função de cada neurônio. O valor gerado pelo neurônio é enviado para a saída da rede Y1 ou Y2, caso o valor que foi treinado e “enviado” para as saídas não seja próximo do valor de saída esperada, os pesos são novamente calculados até que a “função de aproximação” seja encontrada. Estas repetições que são realizadas no processo de treinamento vão se repetir até o limite estabelecido de épocas de treinamento definido seja atingido. Vale ressaltar que caso tenhamos um valor de neurônios fora da proporção de dados, fora da taxa de aprendizagem e precisão, teremos uma aproximação dispersa.

Figura 4 – Coeficiente de Pearson para Carga de aquecimento

Coeficiente de Pearson (Aquecimento)		
Variável	Coeficiente	Interpretação
X1	0,62	Moderada positiva
X2	-0,66	Moderada negativa
X3	0,46	Moderada positiva
X4	-0,86	Forte negativa
X5	0,89	Forte positiva
X6	0,00	Nula (Sem correlação)
X7	0,27	Fraca positiva
X8	0,09	Muito fraca (Quase nula)

Fonte: Autoria própria (2025).

Com base na figura 4, foi realizado a verificação do coeficiente de Pearson, mostrando quais as variáveis que mais interferem na carga do edifício. É notável que as variáveis X1 - compactidade relativa, X2 – área de superfície, X3 – área da parede, X4 – área do telhado, X5 – altura total, são os parâmetros que mais interferem na saída da rede, sendo os mais fortes a altura total do edifício e a área do telhado, neste quesito prevemos que quanto maior a sua altura do prédio maior a carga, e quanto menor a área do telhado maior é a carga, visto que a região interna do prédio tem pouca circulação e alto aglomeração de calor no ambiente.

3.2 Pré-processamento dos Dados

O pré-processamento dos dados consistiu nas seguintes etapas:

- Normalização dos atributos contínuos por meio da técnica Min-Max Scaling, de forma a adequar os valores ao intervalo [0, 1];
- Separação da base em 80% para treinamento e 20% para validação, de forma estratificada, garantindo a proporcionalidade das distribuições.

Figura 5 – Inicialização e parametrização do script

```

%inicialização dos vetores randômicos de pesos W1 e W2
Neuronios_entrada = 24;%20 25
Neuronios_saida = 2;
W1 = rand(Neuronios_entrada,n_ent+1);
fprintf('Pesos iniciais primeira camada neural: []');
fprintf('%g, ', W1(1:end-1));
fprintf('%g]\n', W1(end));
% %salvar pesos para utilizar na rede momentum
save('w1_inicial.txt','W1','-ascii');

W2 = rand(Neuronios_saida,Neuronios_entrada+1);
fprintf('Pesos iniciais segunda camada neural: []');
fprintf('%g, ', W2(1:end-1));
fprintf('%g]\n', W2(end));
% %salvar pesos para utilizar na rede momentum
save('w2_inicial.txt','W2','-ascii');

fprintf('-----\n');
pause(2);
%-----\n
n=0.07; %taxa de aprendizagem
e = 1e-7; % precisão

```

Fonte: Autoria própria (2025).

Na figura 5, vemos parâmetros que foram adequados ao script da PMC foram o número de neurônios, a taxa de aprendizagem e a precisão, ora os valores geravam uma discrepância maior e ora menor, porém o que melhor atendeu as expectativas foi o valor de 24 neurônios, 0.07 de taxa de aprendizagem e uma precisão de $1 \cdot 10^{-7}$.

3.3 Avaliação do Desempenho

A avaliação dos modelos foi feita por meio de três métricas estatísticas:

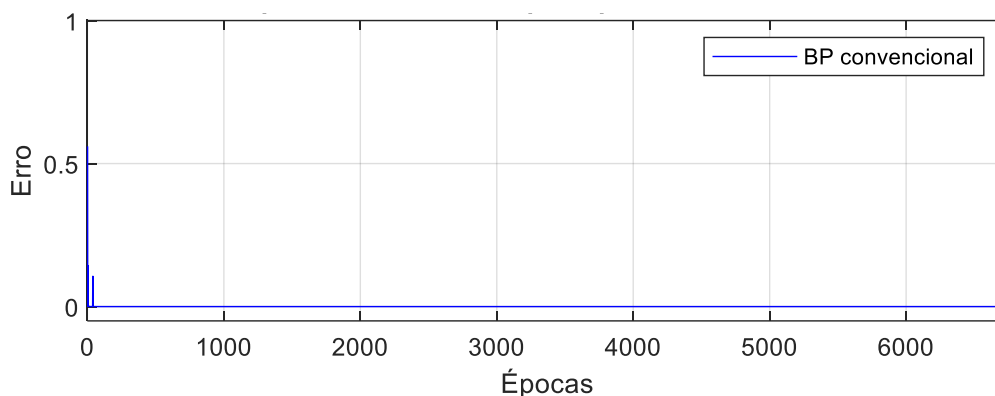
- Root Mean Squared Error (RMSE): mede o erro médio quadrático da previsão;
- Variância: indica o quanto os valores variam em relação ao conjunto de dados.
- Taxa de acerto: validar qual a margem de acerto ao comparar o conjunto de dados de validação com o de treinamento.
- Coeficiente de Pearson: medir a interferência de dados com relação à carga do edifício.

4 APRESENTAÇÃO E DISCUSSÃO DOS RESULTADOS

Esta seção apresenta os resultados obtidos a partir das etapas de análise exploratória, modelagem preditiva e interpretação dos modelos aplicados sobre a base de dados *Energy Efficiency*. A discussão está estruturada em tópicos que visam facilitar a compreensão da contribuição de cada etapa para os objetivos da pesquisa.

O banco de dados foi implementado na rede neural por meio do MatLab, e inicialmente foi realizado diversos teste para prever a melhor condição para o aproximador. A figura 6 representa o comportamento do erro em relação as épocas de treinamento, apresentando um baixo percentual de erros que adiante do artigo será apresentado.

Figura 6 – Gráfico do comportamento do erro com relação às épocas de treinamento



Fonte: Autoria própria (2025).

Importante calcularmos a relação que existe entre o erro relativo médio com um dos valores que fazem parte do conjunto de dados na saída.

A figura 3 representa na coluna 9 e 10 as saídas para Y1 e Y2 respectivamente, podemos pegar como exemplo a linha 1, onde a média entre as saídas é de 18,44 e o erro relativo médio é de 0,9757. Sendo assim a taxa de acerto é calculada por:

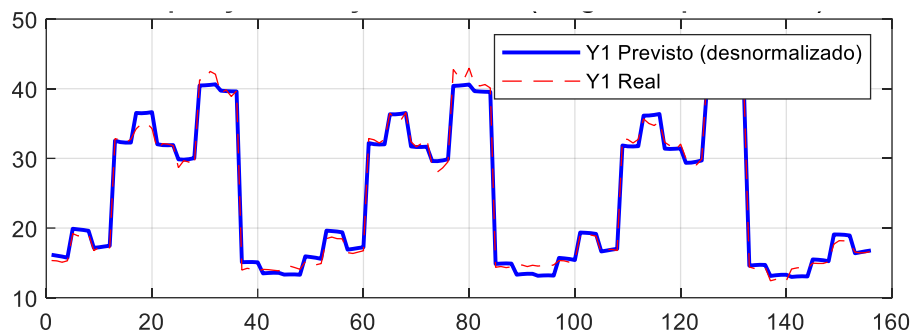
$$\text{Taxa de acerto 1} = \frac{18,44 - 0,9757}{18,44} \cdot 100 = 94,71 \% \quad (1)$$

A taxa de acerto pode variar de acordo com a saída que encontramos, como é o exemplo da linha 5, onde a média é de 24,56

$$\text{Taxa de acerto 2} = \frac{24,56 - 0,9757}{24,56} \cdot 100 = 96,03 \% \quad (2)$$

Para efeito de testes é conveniente que a carga térmica tanto de aquecimento quanto para resfriamento assumam valores próxima à 20, pois desta maneira o erro relativo médio se comporta com maior precisão. Mas caso estes valores não se aproximem de 20, é interessante a formulação de um novo conjunto de dados com resultados menores para que a aproximação tenda a uma maior precisão, visto que a figura 6 demonstra o comportamento do erro com um valor pequeno em comparação com a quantidade de épocas.


Figura 7 -Comparativo de validação da carga de aquecimento



Fonte: Autoria própria (2025).

Na figura 7 podemos ver a proximidade dos valores reais com os valores previstos, e como estamos falando de carga térmica em relação a um prédio inteiro vemos que temos muitas variações de valores atingindo grandes picos ou vales, é interessante realizar a separação em diferentes categorias, como por exemplo: uma categoria de 15 a 25, uma de 26 a 30, e de 31 a 50, para que tenha uma maior homogeneidade entre os dados, e assim o aproximador terá maior eficiência.

Figura 8 – Comparativo de validação de carga de resfriamento.



Fonte: Autoria própria (2025)

A figura 8 faz um comparativo entre o Y2 Previsto e o Y2 Real, vemos que o comportamento da rede é semelhante à da carga de aquecimento, apresentando picos e vales em diferentes regiões, mostrando que o conjunto de dados deve ser

avaliado em forma de categorias, visto que as variáveis de maior coeficiente de correlação interferem nitidamente no resultado da projeção.

O erro relativo médio gerado pela rede foi de 0,9758 e uma variância de 28,98 %. Devido a não homogeneidade há uma discrepância entre os dados tendo um número maior de variância quando realizado os testes da rede neural., porém o erro relativo médio é baixo, mostrando que os dados têm uma certa variação devida as diferentes condições que o edifício tem, porém com aceitação para a rede visto a boa taxa de acerto.

5 CONSIDERAÇÕES FINAIS

A eficiência energética em edificações representa um desafio estratégico no contexto da sustentabilidade urbana e da racionalização do consumo de recursos naturais. O presente estudo buscou analisar, por meio de técnicas que avaliam variáveis arquitetônicas e o desempenho energético de edifícios simulados, utilizando a base de dados *Energy Efficiency*, disponibilizada pela UCI Machine Learning Repository.

Inicialmente, foi realizada uma análise exploratória detalhada dos dados, permitindo identificar padrões de correlação entre os atributos geométricos dos edifícios e as cargas térmicas de aquecimento e resfriamento. Verificou-se que variáveis como X1 - compactidade relativa, X2 – área de superfície, X3 – área da parede, X4 – área do telhado, X5 – altura total, são os parâmetros que mais interferem na saída da rede, sendo os mais fortes X5 - altura total do edifício e X4 - área do telhado apresentaram forte impacto no consumo energético, evidenciando a influência direta do formato e das proporções arquitetônicas sobre a eficiência térmica das construções.

Apesar da qualidade da base de dados e da eficiência do modelo aplicado, o estudo apresenta limitações que devem ser consideradas. A principal delas refere-se

ao fato de que os dados analisados são provenientes de simulações computacionais e, portanto, não incorporam variáveis contextuais do mundo real, como clima local, comportamento dos usuários e manutenção dos sistemas. Essas limitações abrem caminho para estudos futuros que integrem dados reais de edificações, com maior variabilidade e complexidade, além de testar os modelos em diferentes zonas climáticas, e outro parâmetro seria quanto a variância entre os dados, para que os dados venham ser subdivididos em categoria de 15 a 25, uma de 26 a 30, e de 31 a 50, para que tenha uma maior homogeneidade que resultará em um aproximador mais eficiente.

Conclui-se, portanto, que a aliança entre ciência de dados e arquitetura pode promover avanços significativos em direção à sustentabilidade do ambiente construído, desde que os métodos adotados sejam cuidadosamente validados e contextualizados. Os resultados desta pesquisa demonstram que é possível utilizar inteligência artificial para prever e interpretar o comportamento energético de edifícios, oferecendo suporte técnico e estratégico para decisões projetuais.

REFERÊNCIAS

- ALVES, Mariana; OLIVEIRA, Tânia; CARVALHO, Lucas. *Eficiência energética em edificações: fundamentos e aplicações práticas*. São Paulo: Editora Técnica, 2019.
- CATARINO, M. H. *Redes neurais*. Rio de Janeiro, RJ: Freitas Bastos, 2025. E-book. Disponível em: <https://plataforma.bvirtual.com.br>. Acesso em: 18 nov 2025.
- FERREIRA, Douglas; SANTOS, Camila. Avaliação comparativa de algoritmos de regressão para previsão de consumo energético em edifícios. *Revista Brasileira de Ciência e Tecnologia*, Brasília, v. 12, n. 1, p. 45–61, 2022.
- GIL, Antônio Carlos. *Como elaborar projetos de pesquisa*. 6. ed. São Paulo: Atlas, 2010.
- LIMA, Priscila; ANDRADE, João; MENDES, Rebeca. Previsão de cargas térmicas em edificações com aprendizado de máquina. *Revista de Engenharia e Sustentabilidade*, Belo Horizonte, v. 8, n. 2, p. 88–102, 2021.

LOPES, Tiago Drummond; GOEDEL, Alessandro; BRONIERA JUNIOR, Paulo; GRACIOLA, Clayton Luiz; MIZUYAMA, Daniel. Uma abordagem neural no monitoramento preditivo de temperatura num motor de indução trifásico. In: SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE (SBAI), 14., 2013, Fortaleza. Anais [...]. Fortaleza: SBAI, 2013. p. 1–6. Disponível em: <https://www.sbai2013.ufc.br/pdfs/5487.pdf>. Acesso em: 19 de abr. 2025.

LUNDSTRÖM, Linda; NILSSON, Adam. Machine learning models for energy performance in buildings: A SHAP-based analysis. *Energy and Buildings*, Amsterdam, v. 209, p. 109685, 2020.

MARTINS, Vinícius; COSTA, Ana Paula. Bases simuladas versus dados reais: implicações para modelagem energética de edifícios. *Cadernos de Arquitetura e Sustentabilidade*, Florianópolis, v. 4, n. 1, p. 28–43, 2021.

SILVA, Ivan Nunes da; SPATTI, Danilo Hernane; FLAUZINO, Rogério Andrade. Redes neurais artificiais para engenharia e ciências aplicadas: curso prático. São Paulo: Artliber Editora, 2010. 399 p.

SIQUEIRA, Adalberto N.; TIBA, Chigueru; FRAIDENRAICH, Naum. Estimação da irradiação solar global diária usando Redes Neurais Artificiais dos tipos PMC e FBR. In: CONGRESSO BRASILEIRO DE ENERGIA SOLAR, 2., 2008, Florianópolis. Anais [do] II Congresso Brasileiro de Energia Solar e III Conferência Regional Latino-Americana da ISES. Florianópolis: [s. n.], 2008. p.10

SOUZA, Daniela; MOREIRA, Cláudio. Fatores determinantes do consumo de energia em edificações urbanas. *Revista de Arquitetura e Urbanismo Sustentável*, Salvador, v. 5, n. 3, p. 112–127, 2020.

TSILIMPARIS, A.; ANGELAKIS, V. *Energy efficiency of building simulations using DesignBuilder and Ecotect*. Athens: University of Crete, 2012. Disponível em: <https://archive.ics.uci.edu/dataset/242>. Acesso em: 12 nov. 2025.

UNIVERSITY OF CALIFORNIA. *UCI Machine Learning Repository – Energy Efficiency Data Set*. Irvine: UCI, 2012. Disponível em: <https://archive.ics.uci.edu/ml/datasets/Energy+efficiency>. Acesso em: 12 nov. 2025.



Esta obra está licenciada com Licença Creative Commons Atribuição-Não Comercial 4.0 Internacional.
[Recebido/Received: Dezembro 18 2024; Aceito/Accepted: Janeiro 29, 2025]