



Integração de Gêmeos Digitais e Aprendizado de Máquina na Previsão e Otimização do Consumo Energético

FIGUEIREDO, Karoline¹; HADDAD, Assed².

karolinefigueiredo@poli.ufrj.br¹; assed@poli.ufrj.br².

¹Doutora, Programa de Engenharia Ambiental (PEA), Universidade Federal do Rio de Janeiro (UFRJ), Brasil.

²Doutor, Programa de Engenharia Ambiental (PEA), Universidade Federal do Rio de Janeiro (UFRJ), Brasil.

Informações do

Artigo

Palavras-chave: (3)

Gêmeos Digitais

Machine Learning

Eficiência Energética

Resumo:

A eficiência energética é um dos principais desafios enfrentados no contexto da transição energética. Este estudo propõe uma solução inovadora para a previsão e otimização do consumo energético em edificações, integrando Gêmeos Digitais com técnicas de machine learning. Utilizando sensores IoT para monitorar variáveis críticas, como temperatura, consumo de eletricidade e ocupação, foi desenvolvido um modelo preditivo baseado no algoritmo RandomForest, capaz de ajustar-se dinamicamente com base nos dados coletados em tempo real, validado por meio de estudo de caso. Os resultados mostraram uma redução significativa no Energy Performance Gap (EPG), com o modelo alcançando um coeficiente de determinação (R^2) de 0,95, comprovando sua alta precisão. O estudo destaca o potencial da solução para otimizar o desempenho energético de edificações, oferecendo uma abordagem dinâmica e precisa para a gestão do consumo energético, com implicações diretas para a sustentabilidade no setor da construção.

Abstract

Energy efficiency is one of the main challenges faced in the context of energy transition. This study proposes an innovative solution for predicting and optimizing building energy consumption, integrating Digital Twins with machine learning techniques. Using IoT sensors to monitor critical variables such as temperature, electricity consumption, and occupancy, a predictive model based on the RandomForest algorithm was developed, capable of dynamically adjusting itself based on data collected in real time, validated through a case study. The results showed a significant reduction in the Energy Performance Gap (EPG), with the model achieving a coefficient of determination (R^2) of 0.95, proving its high accuracy. The study highlights the potential of the solution to optimize the energy performance of buildings, offering a dynamic and accurate approach to energy consumption management with direct implications for sustainability in the construction sector.

1. Introdução

A busca por soluções que promovam maior eficiência energética tornou-se uma prioridade na construção civil, especialmente em um cenário de transição energética global. Edifícios residenciais e comerciais são responsáveis por uma parcela significativa do consumo de energia em nível mundial, o que contribui diretamente para as emissões de gases de efeito estufa e para a uma enorme utilização de recursos naturais [1]. Assim, a implementação de estratégias que otimizem o uso de energia ao longo do ciclo de vida dos edifícios não apenas melhora a sustentabilidade do setor, mas também apoia as metas globais de mitigação de mudanças climáticas.

Entretanto, a gestão energética de edificações enfrenta diversos desafios. O *Energy Performance Gap* (EPG) — a discrepância entre o consumo energético previsto e o consumo real — continua sendo um problema recorrente, causado principalmente por simplificações nos modelos de previsão [2]. Isso porque as abordagens tradicionais de gestão energética apresentam limitações significativas, muitas vezes utilizando apenas dados estáticos para prever o consumo de energia. Esses dados estáticos são baseados em condições fixas, que não refletem as mudanças contínuas nas operações do edifício, como variações climáticas, padrões de ocupação e uso de diferentes equipamentos [3].

Além disso, a falta de integração de dados em tempo real nas avaliações energéticas impede uma visão dinâmica do comportamento do edifício, o que compromete a precisão das previsões e dificulta a identificação de oportunidades de otimização durante o uso da edificação. Esses desafios tornam evidente a necessidade de uma abordagem mais adaptativa e robusta, capaz de incorporar dados reais e atualizados no processo de avaliação energética.

Diante desse cenário, este artigo propõe uma solução inovadora baseada na integração de Gêmeos Digitais e técnicas de *machine learning* para a previsão e otimização do

consumo energético em edificações. O Gêmeo Digital, conhecido em inglês como *Digital Twin*, oferece uma representação digital em tempo real de um ativo físico. Ao ser implementado na construção civil, esse conceito proporciona a sincronização do fluxo de dados bidirecional entre o modelo digital e o edifício físico, permitindo o monitoramento e a avaliação contínua dos impactos do edifício ao longo de todo o seu ciclo de vida [4].

Ao integrar um Gêmeo Digital de um edifício a técnicas de *machine learning*, este trabalho pretende desenvolver um modelo preditivo adaptativo, capaz de ajustar-se dinamicamente às condições de operação da edificação, oferecendo uma resposta mais precisa às variações energéticas em tempo real. Mais especificamente, essa integração busca resolver as limitações atuais das avaliações energéticas ao transformar dados estáticos em informações dinâmicas e atualizadas continuamente. Além disso, ao focar no consumo de energia, o estudo propõe soluções práticas que melhoram a eficiência energética em edificações, oferecendo uma abordagem inovadora para a transição energética. Essa abordagem possui implicações tanto socioambientais quanto econômicas para o setor da construção, perpassando por todos os pilares da sustentabilidade.

2. Revisão de Literatura

Nos últimos anos, a eficiência energética no setor da construção tem sido amplamente discutida, principalmente em função da crescente demanda por edificações que consumam menos energia e emitam menos carbono. A literatura mostra que o setor da construção é responsável por uma parcela considerável do consumo global de energia, destacando a importância de otimizar o uso energético desde a fase de projeto até a operação e manutenção dos edifícios [5,6].

Uma das principais metodologias adotadas para avaliar o desempenho energético de edifícios é o uso de modelos computacionais que simulam o consumo de energia ao longo do ciclo de vida da construção. Porém, muitos desses estudos têm

focado em abordagens estáticas, onde o consumo energético é estimado com base em condições fixas e previsíveis. Essa abordagem ignora a variabilidade do uso e das condições ambientais, limitando a precisão dessas estimativas e não captando discrepâncias conhecidas como *Energy Performance Gap*.

A fim de mitigar essas limitações, modelos preditivos que incorporam dados em tempo real têm ganhado destaque em pesquisas recentes. Por exemplo, Langner et al. [7] exploraram o uso do *Model Predictive Control* (MPC) na otimização do consumo de energia em edifícios inteligentes, especialmente através da integração de recursos energéticos distribuídos, como geração fotovoltaica, armazenamento e cargas controladas termicamente. O estudo comparou as formulações determinísticas, robustas e estocásticas do MPC, avaliando sua capacidade de lidar com incertezas nas previsões de energia. Os resultados indicaram que, embora o MPC determinístico pudesse gerenciar incertezas médias a baixas com conforto térmico satisfatório, as versões robusta e estocástica apresentaram desempenho superior em cenários com maiores erros de previsão, como durante condições climáticas extremas.

Por outro lado, a fim de melhorar a precisão das previsões de desempenho energético em larga escala, modelos baseados em aprendizado de máquina têm se mostrado promissores. Por exemplo, Ali et al. [8] propuseram uma metodologia baseada em *machine learning* combinadas com simulação paramétrica para prever o desempenho energético de edifícios urbanos. O estudo usou um conjunto de dados sintéticos gerado a partir de parâmetros críticos de edifícios residenciais, como aquecimento, iluminação, equipamentos e fontes renováveis, para prever o consumo de energia em uma escala urbana. A análise comparou diversos algoritmos de *machine learning*, demonstrando que técnicas baseadas em *Gradient Boosting*, como *XGBoost*, superaram modelos tradicionais em precisão.

Percebe-se, então, que o uso de *machine learning* para incorporação de dados em tempo

real permite que formuladores de políticas e planejadores adotem decisões mais informadas ao implementar medidas de eficiência energética, como a introdução de sistemas elétricos mais eficientes. Além disso, a capacidade dessas tecnologias de processar grandes volumes de dados e identificar padrões de consumo energético contribui significativamente para prever cenários futuros com maior precisão. Isso possibilita não apenas a otimização do desempenho energético em tempo real, mas também o desenvolvimento de estratégias de longo prazo que visam reduzir o consumo de energia e as emissões de carbono, promovendo um ambiente construído mais sustentável.

2.1 Uso de Gêmeos Digitais para Eficiência Energética

O conceito de Gêmeos Digitais tem ganhado relevância no setor da construção, especialmente no contexto da eficiência energética [9]. Um Gêmeo Digital de uma edificação é uma réplica virtual deste edifício que reflete em tempo real as condições operacionais do ativo físico, utilizando dados provenientes de sensores integrados ao ambiente construído [10]. Ao coletar informações como temperatura, ocupação e consumo energético, o Gêmeo Digital permite uma análise contínua e precisa do desempenho do edifício, possibilitando ajustes dinâmicos para otimizar a eficiência energética.

O uso de Gêmeos Digitais possibilita uma transição dos modelos preditivos baseados em dados estáticos para abordagens mais dinâmicas e interativas. Essa tecnologia não apenas aumenta a precisão das previsões de consumo energético, como também permite intervenções imediatas para ajustar as condições operacionais e reduzir o desperdício de energia [11]. Com isso, os Gêmeos Digitais emergem como uma ferramenta essencial na busca por edificações mais sustentáveis e inteligentes, capazes de se adaptar continuamente às demandas energéticas e ambientais em tempo real.

Eneyew et al. [12] propuseram um *framework* de calibração para Gêmeos Digitais em edifícios inteligentes, abordando os

desafios relacionados à atualização contínua de modelos físicos em um ambiente com dados incertos. Utilizando um modelo generativo, o estudo demonstrou uma abordagem escalável e eficiente, capaz de prever o consumo energético com precisão, mesmo em condições de sensores ausentes ou com ruídos. Embora os resultados sejam promissores, o estudo se concentrou principalmente na calibração contínua e na robustez do modelo diante de incertezas, sem explorar de maneira profunda o uso de *machine learning* para otimização da eficiência energética em tempo real.

Por outro lado, Benfer e Müller [13] exploraram a criação de Gêmeos Digitais semânticos para sistemas prediais por meio de inferência de metadados baseada em séries temporais. O estudo revisou 53 publicações baseadas em inteligência artificial com o objetivo de automatizar a extração de informações e metadados de sistemas prediais, um processo que frequentemente exige um grande esforço manual. A pesquisa identificou três tarefas principais para a criação de Gêmeos Digitais: classificação de tipos, inferência de relações e extração de informações operacionais.

Embora essa abordagem ofereça oportunidades promissoras, o estudo destaca que o processo de automação ainda enfrenta desafios, como a falta de padronização de dados e a dificuldade de acesso a informações críticas sobre os sistemas. Portanto, torna-se muito importante explorar a integração de Gêmeos Digitais com *machine learning* para otimizar o desempenho energético de edificações, indo além da criação de réplicas digitais e incorporando dados em tempo real para ajustes dinâmicos no consumo energético.

3. Materiais e Métodos

Este estudo propõe uma solução para melhorar a previsão e otimização do consumo energético em edificações, utilizando a integração de Gêmeos Digitais e técnicas de *machine learning*. A metodologia empregada envolve a coleta de dados em tempo real, a modelagem preditiva e a validação por meio de um estudo de caso em um edifício residencial. Com isso, pretende-se

minimizar discrepâncias entre o consumo previsto e o consumo real, além de propor estratégias para a redução da demanda energética por meio da previsão de futuros cenários da edificação. O método é composto pelos seguintes passos principais:

3.1 Estudo Preliminar para Integração de Gêmo Digital com Machine Learning

Antes do desenvolvimento da solução proposta neste trabalho, foi realizado um estudo preliminar para avaliar a viabilidade da integração do Gêmo Digital com técnicas de *machine learning*. A revisão de literatura e a análise de casos anteriores indicaram que a combinação dessas tecnologias oferece um grande potencial para a previsão precisa de consumo energético em edificações. No entanto, alguns desafios relacionados à obtenção de dados de sensores em tempo real e à adaptação do modelo para diferentes condições operacionais foram identificados.

Nesse estudo preliminar, foi estabelecido que a integração do Gêmo Digital com *machine learning* exigiria uma arquitetura robusta de coleta e processamento de dados, baseada em sensores IoT. A análise levou em consideração as especificações dos sensores necessários para captar variáveis críticas, como temperatura ambiente, consumo de eletricidade e ocupação, a fim de garantir que os dados fossem suficientes para treinar um modelo preditivo que se ajustasse dinamicamente às mudanças no comportamento da edificação.

Propõe-se que um modelo BIM (neste trabalho, desenvolvido no software Autodesk Revit) seja utilizado como a principal fonte de dados para a criação do Gêmo Digital. A modelagem BIM inclui informações detalhadas sobre as características físicas e funcionais do edifício, como materiais, componentes estruturais, instalações elétricas, HVAC, dentre outras. Vale ressaltar, porém, que o nível de detalhamento (conhecido em inglês como LOD – *Level of Development*) do modelo BIM deve ser alto o suficiente para

suportar a futura integração com dados de sensores IoT.

Ferramentas adicionais podem ser utilizadas para automatizar processos na integração do modelo BIM com dados dos sensores. Neste trabalho, por exemplo, é proposta a criação de um script no Dynamo que seja configurado para importar os dados de sensores IoT, já armazenados em uma planilha Excel ou outro banco de dados, para que o modelo digital criado no Autodesk Revit seja atualizado em tempo real.

Além disso, a linguagem de programação *Python* pode ser utilizada para processar os dados dos sensores IoT, permitindo que esses dados sejam visualizados diretamente no modelo BIM. Esses dados fornecem a base para a evolução da modelagem BIM em um Gêmeo Digital, permitindo que o modelo BIM seja atualizado dinamicamente com os dados coletados em tempo real pelos sensores IoT.

A integração dessas informações facilita a criação de um ambiente digital sincronizado, que reflete as condições físicas do edifício, garantindo uma visão completa e precisa do seu comportamento operacional. Esse fluxo de dados entre o BIM e o Gêmeo Digital é central para a previsão e otimização do consumo energético da edificação. O processo de coleta e integração de dados é detalhado na Figura 1, apresentada no Anexo A.

3.2 Criação do Gêmeo Digital

Com base nos resultados do estudo preliminar, foi criado o Gêmeo Digital da edificação utilizada como estudo de caso. A edificação escolhida é uma residência unifamiliar localizada em Campos dos Goytacazes - RJ, Brasil (21°45'02.2" S 41°21'31.4" W), com dois pavimentos e uma área total de 230m². O Gêmeo Digital é uma representação virtual precisa do edifício físico, refletindo em tempo real as condições operacionais da casa, possibilitando a coleta contínua de dados e a análise do desempenho energético do edifício.

A Figura 2 apresenta o modelo digital utilizado como Gêmeo Digital, que foi

desenvolvido para ser integrado aos sensores IoT, proporcionando uma visualização contínua e detalhada das condições energéticas da edificação.

Figura 2 – Modelo digital gerado para o desenvolvimento do Gêmeo Digital da edificação



Fonte: Os autores.

3.3 Coleta de Dados a partir da Instalação de Sensores

Após a criação do Gêmeo Digital, sensores IoT foram instalados para monitorar diversos aspectos do ambiente da casa, considerando variáveis como temperatura ambiente (°C), consumo de eletricidade (kWh) e ocupação dos ambientes (presença ou não de pessoas).

A instalação dos sensores na residência foi realizada com o consentimento explícito do proprietário. Foi assegurado que a privacidade dos dados dos ocupantes seria totalmente garantida. Isso implica que todos os dados coletados são tratados com a máxima confidencialidade e não serão compartilhados com terceiros sem o consentimento explícito do proprietário. Além disso, medidas foram adotadas para garantir que os dados sejam

utilizados apenas para os fins pretendidos, sem qualquer risco de uso indevido.

Para este estudo, por se tratar do desenvolvimento de uma solução inovadora e sua validação inicial, os dados foram coletados em intervalos de 15 minutos durante um período de 2 meses. Além disso, dados históricos de consumo energético foram utilizados para o treinamento inicial do modelo preditivo.

3.4 Modelo de Previsão

Para prever o consumo energético de períodos futuros e preencher lacunas nos dados, foi utilizado o algoritmo *RandomForest*, uma técnica de *machine learning* baseada em árvores de decisão. O processo de modelagem seguiu os seguintes passos:

- a) Divisão dos dados: Os dados foram divididos em conjunto de treinamento (80%) e conjunto de teste (20%).
- b) Treinamento do modelo: O modelo foi treinado com dados históricos de consumo energético, temperatura e ocupação.
- c) Avaliação do modelo: O desempenho do modelo foi avaliado por meio de métricas como o erro quadrático médio (MSE) e o coeficiente de determinação (R^2).

A lógica detalhada do processo de previsão, incluindo as etapas principais de coleta e análise dos dados, está representada no pseudocódigo apresentado na Figura 3 do Anexo B.

3.5 Atualização em Tempo Real

Os dados de consumo energético foram coletados continuamente pelos sensores IoT e integrados ao Gêmeo Digital, que oferece uma visualização em tempo real do desempenho energético do edifício. O modelo preditivo foi ajustado dinamicamente conforme novos dados eram recebidos, garantindo uma

previsão precisa e adaptativa do consumo energético.

3.6 Visualização e Análise

Para a solução desenvolvida neste estudo, os resultados são visualizados por meio de gráficos comparando o consumo energético real e predito ao longo do tempo. Gráficos de distribuição de erros também são gerados para avaliar a precisão das previsões e identificar discrepâncias no modelo.

3.7 Tratamento de Exceções

Um mecanismo de tratamento de exceções foi implementado para lidar com eventuais falhas nos sensores IoT. Em caso de ausência de dados em tempo real, o sistema deve utilizar os dados mais recentes disponíveis para estimar o consumo energético. Além disso, uma mensagem de erro deve ser registrada no sistema para monitoramento e correção.

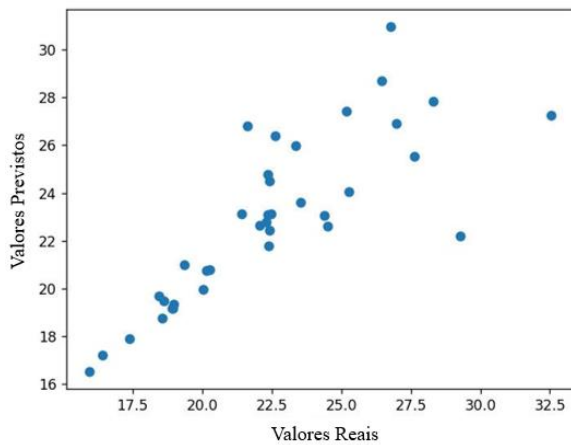
4. Resultados

Os resultados a seguir apresentam a eficácia do modelo preditivo integrado ao Gêmeo Digital, utilizando *machine learning* para prever o consumo energético da edificação estudada. O desempenho do modelo foi avaliado por meio de comparações entre os valores previstos e os valores reais, além de uma análise detalhada do funcionamento do código no terminal, demonstrando a robustez do sistema.

4.1 Precisão do Modelo: Previsão vs Valor Real

A precisão do modelo de *machine learning* foi avaliada por meio de um gráfico de dispersão que compara os valores de consumo energético previstos pelo modelo com os valores reais registrados pelos sensores IoT ao longo do período de análise. Conforme mostrado na Figura 4, há uma forte correlação entre as previsões do modelo e os valores reais, com poucas discrepâncias significativas. O coeficiente de determinação (R^2) próximo de 0,95 indica que o modelo consegue prever com alta precisão o consumo energético da edificação, ajustando-se dinamicamente conforme novas informações são recebidas.

Figura 4 – Comparação entre os valores de consumo energético previstos pelo modelo de *machine learning* e os valores reais coletados pelos sensores IoT



Fonte: Os autores.

Essa análise destaca a capacidade do modelo preditivo de reduzir o *Energy Performance Gap* (EPG), permitindo previsões mais precisas e alinhadas com o consumo real de energia, mesmo em condições operacionais variáveis.

4.2 Robustez do Sistema: Análise no Terminal

A robustez do sistema preditivo é evidenciada na captura de tela da análise no terminal, apresentada na Figura 5, onde o código processa novos dados de consumo energético e outras variáveis monitoradas, como temperatura e ocupação. A saída do terminal mostra o valor do erro quadrático médio (MSE), que foi de aproximadamente 5,03, confirmando a eficácia do modelo preditivo em minimizar os erros de previsão.

Figura 5 – Captura de tela da análise no terminal

```

Enter new EnergyConsumption: 23.43
Enter new Temperature: 29
Enter new Room1_Occupants: .666
Enter new Room2_Occupants: .353
Enter new Room3_Occupants: .318
=====
Data Analysis
=====
Mean Squared Error on Data: 5.031957366824519

```

Fonte: Os autores.

O código oferece a possibilidade de atualização em tempo real dos dados inseridos, ajustando automaticamente o modelo com base nos novos valores. Isso reforça a flexibilidade e adaptabilidade do sistema na

previsão contínua de consumo energético, garantindo que as previsões estejam sempre alinhadas com as condições reais do edifício.

Esses resultados confirmam que a integração do Gêmeo Digital com *machine learning* proporciona um sistema preditivo preciso e robusto, capaz de otimizar o desempenho energético da edificação em tempo real. A precisão das previsões e a capacidade de ajuste dinâmico demonstram o potencial da solução para reduzir o *Energy Performance Gap* e melhorar a eficiência energética de edificações.

5. Discussão

A abordagem proposta neste estudo está alinhada com a necessidade de superar os modelos tradicionais baseados em dados estáticos, que contribuem significativamente para a persistência do *Energy Performance Gap*. Os modelos preditivos baseados em *machine learning* oferecem a capacidade de se ajustar dinamicamente às mudanças operacionais em tempo real, permitindo uma análise mais precisa e adaptativa do consumo energético.

Em contraste com estudos anteriores, o presente trabalho vai além ao integrar Gêmeos Digitais com técnicas de *machine learning* para não apenas prever o consumo energético, mas também ajustar dinamicamente o desempenho da edificação em tempo real, com base nos dados coletados pelos sensores IoT. Essa abordagem permite uma adaptação proativa às condições operacionais, oferecendo uma solução prática e eficiente para a gestão energética de edifícios inteligentes. Ao incorporar dados em tempo real, essas soluções reduzem as discrepâncias entre o consumo previsto e o real, permitindo uma resposta imediata a variações nas condições ambientais e no comportamento dos ocupantes, promovendo a otimização contínua dos recursos energéticos e contribuindo para a criação de um ambiente construído mais eficiente e sustentável.

A contribuição deste estudo está relacionada à compreensão das lacunas no

EPG em edifícios. No entanto, algumas questões-chave precisam ser abordadas para avançar neste campo e desenvolver uma compreensão mais sistemática do EPG em edifícios energeticamente eficientes.

Primeiramente, embora estudos anteriores tenham revisado o EPG no setor da construção, a maioria das análises concentra-se em edifícios convencionais, que geralmente não possuem estratégias avançadas de eficiência energética. No entanto, edifícios altamente eficientes desempenham um papel crucial na descarbonização global, sendo, portanto, essencial focar no EPG desses edifícios. A presente pesquisa busca preencher essa lacuna ao integrar tecnologias avançadas, como Gêmeos Digitais e *machine learning*, para fornecer uma visão mais dinâmica e precisa do consumo energético em tempo real de edifícios inteligentes.

Em segundo lugar, embora as causas do EPG e as estratégias para sua mitigação sejam amplamente discutidas na literatura, é necessário expandir essa análise para incluir os impactos do EPG sobre diferentes stakeholders envolvidos. O uso de *machine learning* integrado ao Gêmeo Digital neste estudo não só melhora a precisão das previsões, mas também oferece uma solução prática que pode ser utilizada por gestores de edifícios, engenheiros e tomadores de decisão para otimizar o desempenho energético ao longo do ciclo de vida do edifício.

Além disso, ainda há uma lacuna na literatura quanto ao desenvolvimento de um *framework* sistemático que aborde o EPG de forma abrangente. O EPG é um fenômeno complexo, envolvendo múltiplos fatores, partes interessadas, diferentes fases do ciclo de vida de um edifício e conhecimentos multidisciplinares. A abordagem proposta por este estudo, que combina dados em tempo real, Gêmeos Digitais e *machine learning*, representa um avanço em direção à criação de um *framework* mais robusto e adaptável para lidar com as complexidades do EPG. No entanto, a implementação dessa solução requer esforços coordenados entre desenvolvedores de tecnologias, projetistas, operadores e reguladores do setor de construção.

Outro ponto relevante é que, embora a integração de Gêmeos Digitais e *machine learning* para eficiência energética tenha mostrado resultados promissores, ainda existem desafios práticos na implementação em larga escala. A configuração de sensores IoT e a gestão dos dados coletados continuam sendo obstáculos consideráveis. Além disso, os custos iniciais de implementação podem ser uma barreira significativa para projetos de menor porte, como edifícios residenciais e comerciais de médio porte. Portanto, é essencial desenvolver soluções escaláveis e acessíveis para permitir a adoção mais ampla dessa tecnologia em diferentes contextos construtivos.

Por fim, é importante destacar o impacto social e econômico dessa abordagem. A otimização do consumo energético por meio da integração de Gêmeos Digitais e *machine learning* tem o potencial de gerar economias substanciais a longo prazo, tanto em termos de redução de custos energéticos quanto de sustentabilidade ambiental. Essas economias, no entanto, dependem da eficácia na adoção da tecnologia e da capacidade de gestores e operadores de edifícios utilizarem essas ferramentas para ajustar continuamente o desempenho energético das edificações.

6. Conclusão

Este estudo apresentou uma abordagem inovadora para a previsão e otimização do consumo energético em edifícios, utilizando Gêmeos Digitais e *machine learning*. Ao integrar dados em tempo real com algoritmos preditivos, foi possível criar um modelo dinâmico que se adapta às condições operacionais de um edifício, oferecendo uma solução prática para reduzir o *Energy Performance Gap*.

Os resultados obtidos demonstram que a utilização de Gêmeos Digitais e *machine learning* pode melhorar significativamente a precisão das previsões de consumo energético e a eficiência energética geral de edificações. A análise em tempo real e a capacidade de adaptação dos modelos preditivos oferecem uma vantagem substancial em comparação

com abordagens tradicionais baseadas em dados estáticos, que falham em capturar as variações no uso e nas condições ambientais.

No entanto, a implementação dessa tecnologia ainda enfrenta desafios, principalmente relacionados aos custos e à complexidade de instalação de sensores IoT e da criação de modelos digitais detalhados. Assim, o desenvolvimento de soluções mais acessíveis e escaláveis é essencial para garantir que essa tecnologia seja adotada em larga escala, contribuindo para a transição energética no setor da construção civil.

Por fim, este trabalho fornece uma base sólida para futuras pesquisas e aplicações de Gêmeos Digitais e *machine learning* no contexto da eficiência energética em edificações. As soluções discutidas têm o potencial de impactar positivamente tanto a sustentabilidade ambiental quanto a economia de recursos energéticos, promovendo uma gestão mais eficiente e adaptativa dos edifícios no longo prazo. O avanço contínuo dessas tecnologias pode transformar a maneira como os edifícios são projetados, operados e mantidos, abrindo caminho para um futuro mais sustentável.

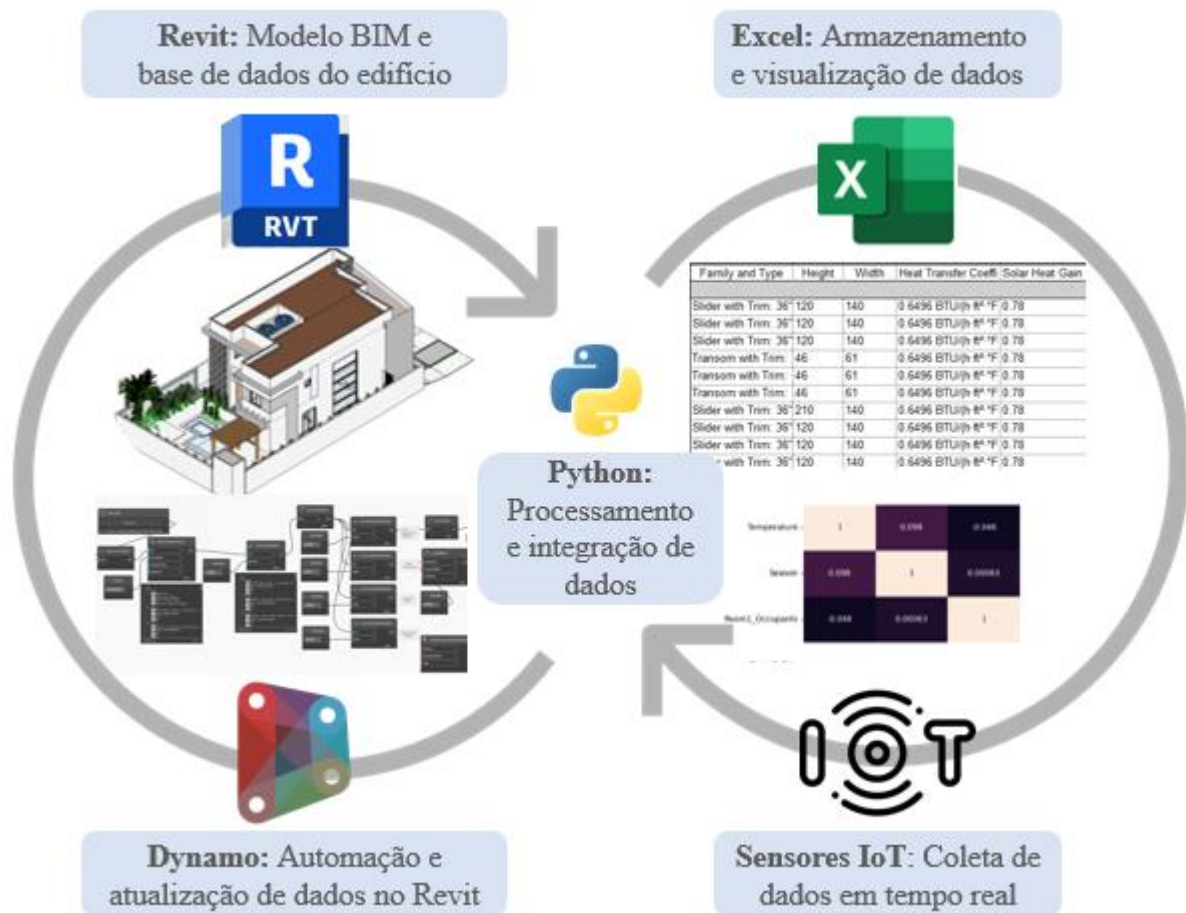
7. Referências

- [1] CHASTAS, P.; THEODOSIOU, T.; BIKAS, D. *Embodied energy in residential buildings-towards the nearly zero energy building: A literature review*. Build Environ, v. 105, p. 267–282, 2016.
- [2] KAMPELIS, N.; GOBAKIS, K.; VAGIAS, V.; KOLOKOTSA, D.; STANDARDI, L.; ISIDORI, D.; CRISTALLI, C.; MONTAGNINO, F. M.; PAREDES, F.; MURATORE, P.; VENEZIA, L.; DRACOU, M. K.; MONTENON, A. *Evaluation of the Performance Gap in Industrial, Residential & Tertiary Near-Zero Energy Buildings*. Energy Build, 2017.
- [3] FIGUEIREDO, K.; HAMMAD, A. W. A.; PIEROTT, R.; TAM, V. W. Y.; HADDAD, A. *Integrating Digital Twin and Blockchain for Dynamic Building Life Cycle Sustainability Assessment*. Journal of Building Engineering, 2024.
- [4] KUO, Y. H.; PILATI, F.; QU, T.; HUANG, G. Q. *Digital twin-enabled smart industrial systems: recent developments and future perspectives*. Int J Comput Integr Manuf, v. 34, p. 685–689, 2021.
- [5] GERALDI, M. S.; GHISI, E. *Building-level and stock-level in contrast: A literature review of the energy performance of buildings during the operational stage*. Energy Build, v. 211, 2020.
- [6] CHEN, S.; ZHANG, G.; XIA, X.; SETUNGE, S.; SHI, L. *A review of internal and external influencing factors on energy efficiency design of buildings*. Energy Build, v. 216, 2020.
- [7] LANGNER, F.; WANG, W.; FRAHM, M.; HAGENMEYER, V. *Model predictive control of distributed energy resources in residential buildings considering forecast uncertainties*. Energy Build, v. 303, 2024.
- [8] ALI, U.; BANO, S.; SHAMSI, M. H.; SOOD, D.; HOARE, C.; ZUO, W.; HEWITT, N.; O'DONNELL, J. *Urban building energy performance prediction and retrofit analysis using data-driven machine learning approach*. Energy Build, v. 303, 2024.
- [9] KAEWUNRUEN, S.; RUNGSKUNROCH, P.; WELSH, J. A. *digital-twin evaluation of Net Zero Energy Building for existing buildings*. Sustainability (Switzerland), v. 11, 2019.

- [10] JIANG, Y.; LI, M.; GUO, D.; WU, W.; ZHONG, R. Y.; HUANG, G. Q. *Digital twin-enabled smart modular integrated construction system for on-site assembly*. *Comput Ind*, v. 136, 2022.
- [11] FIGUEIREDO, K.; TAM, V. W. Y.; HADDAD, A. *Examining the Use of BIM-Based Digital Twins in Construction: Analysis of Key Themes to Achieve a Sustainable Built Environment*. In: LI, J.; LU, W.; PENG, Y.; YUAN, H.; WANG, D. (Eds.). *Proceedings of the 27th International Symposium on Advancement of Construction Management and Real Estate*. CRIOCM 2022. *Lecture Notes in Operations Research*. Springer, Singapore, 2023. p. 1462–1474.
- [12] ENEYEW, D. D.; CAPRETZ, M. A. M.; BITSUAMLAK, G. T. *Continuous model calibration framework for smart-building digital twin: A generative model-based approach*. *Appl Energy*, v. 375, 2024.
- [13] BENFER, R.; MÜLLER, J. *Semantic digital twin creation of building systems through time series based metadata inference – A review*. *Energy Build*, v. 321, 2024.

ANEXO A

Figura 1 – Fluxo de integração entre as diferentes ferramentas computacionais utilizadas neste estudo



Fonte: Os autores.

ANEXO B

Figura 3 – Pseudocódigo para previsão de consumo de energia utilizando dados em tempo real e *machine learning*

```

BEGIN
  1. IMPORT necessary libraries (e.g., pandas, sklearn, seaborn, matplotlib)

  2. DEFINE parameters:
    a. INPUT dataset (historical data for energy consumption)
    b. MODEL configuration (e.g., RandomForest with specific hyperparameters)
    c. Real-time data stream (sensor data source)
    d. INITIALIZE missing value indicator (-1 for missing energy consumption)
    e. SET threshold for acceptable model error (e.g., Mean Squared Error < 0.05)

  3. LOAD the energy consumption dataset (real-time or historical data)
  4. IDENTIFY missing energy consumption values (if any)

  PROCEDURE PredictEnergyConsumption(df, model)
    5. IF missing values exist THEN
      6. TRAIN a machine learning model (e.g., RandomForest) with known energy consumption data
      7. PREDICT the missing energy consumption values
      8. UPDATE the dataframe with predicted values
      9. RECALCULATE any dependent metrics like energy costs
    END IF
  END PROCEDURE

  PROCEDURE AnalyzeData(df)
    10. SPLIT data into training and testing sets
    11. CONFIGURE and TRAIN a machine learning model (e.g., RandomForest) using training data
    12. EVALUATE the model's performance (e.g., Mean Squared Error, R-squared)
    13. IF model error exceeds threshold THEN
      a. ADJUST model parameters (e.g., tuning hyperparameters)
      b. RE-TRAIN the model
    END IF
    14. VISUALIZE data and model predictions:
      a. PLOT actual vs predicted energy consumption over time (e.g., line graph)
      b. DISPLAY residual error distribution (e.g., bar graph or histogram)
  END PROCEDURE

  PROCEDURE RealTimeEnergyUpdate(df)
    15. ITERATE while new real-time data is available
      16. IF real-time data stream is unavailable THEN
        a. LOG error message (e.g., "No real-time data available")
        b. SKIP real-time update for the current cycle
      ELSE
        17. UPDATE energy consumption values with real-time sensor input
        18. CALL PredictEnergyConsumption(df, model)
      END IF
    END WHILE
  END PROCEDURE

  MAIN
  19. CALL AnalyzeData(df)
  20. CALL RealTimeEnergyUpdate(df)
END

```

Fonte: Os autores.