



## Avaliação do Ciclo de Vida Inteligente: Predição do Consumo Energético em Laboratório de Análise de Concreto

**Palavras-Chave:** Aprendizado de Máquina, Internet das Coisas, Gêmeo Digital

**Autores(as):**

**Lucas Nastari Ziza, FT - UNICAMP**

**Prof<sup>a</sup>. Dr<sup>a</sup>. Regina Coeli Ruschel, FECFAU - UNICAMP**

---

### INTRODUÇÃO:

A coleta de dados para a Avaliação do Ciclo de Vida (ACV) ainda é predominantemente realizada de forma manual na abordagem tradicional, assim como a busca de informações em bases de dados existentes (HARRIS; LANDIS, 2020). No entanto, essa abordagem tem sido criticada devido à possível diminuição da confiabilidade e precisão dos resultados. Além disso, muitos estudos enfrentam a ausência de dados, o que leva a ACVs no Brasil, por exemplo, a depender em grande parte de informações adaptadas de bases de dados internacionais para adequação ao contexto brasileiro. Consequentemente, um dos principais desafios enfrentados pela ACV está relacionado principalmente à disponibilidade e qualidade dos dados (GOMES et al., 2019). Além disto, dada a complexidade da ACV, que envolve as edificações, se faz necessário o desenvolvimento e implementação de métodos computacionais inovadores. A Internet das Coisas é uma tecnologia que possibilita a comunicação de dispositivos eletrônicos e sensores pela internet, a integração destas tecnologias com o ambiente tem contribuído para a criação de novas oportunidades quando aplicadas a edificações (LI et al., 2017).

A eficiência energética, questão abordada na ACV, tem uma grande importância no setor público no contexto das cidades inteligentes, dado ao fato que os edifícios públicos consomem grandes quantidades de energia, principalmente aqueles voltados para a área educacional, de saúde e outras instituições que têm uma alta frequência de uso. A implementação de técnicas de aprendizado de máquina e da análise de Big Data são ferramentas fundamentais para criar modelos preditivos que melhorem o consumo de energia em edifícios, resultando em uma administração pública mais eficiente, serviços de maior qualidade e um ambiente mais saudável (ZEKIĆ-SUŠAC; MITROVIĆ; HAS, 2021).

Este projeto tem como objetivo aplicar modelos estatísticos, criar indicadores e realizar análise de dados, incorporando também técnicas avançadas de aprendizado de máquina, a fim de aprimorar a ACV. Com a utilização dessas abordagens, busca-se identificar oportunidades para otimização de consumo energético em todas as etapas do ciclo de vida dos produtos e serviços, contribuindo assim

para a redução de impactos ambientais e uma abordagem mais sustentável para o desenvolvimento de soluções e práticas industriais.

## METODOLOGIA:

Para este estudo foi utilizado o laboratório de pesquisa e ensino de materiais de construção. O monitoramento do consumo de energia foi realizado por diversos dispositivos microcontroladores e sensores, por meio dos conceitos de Internet das Coisas. Os dados foram armazenados no serviço de nuvem da IoT Konker Platform e analisados pela ferramenta *Google Colaboratory* com a linguagem de programação Python.

Foram aplicados aos dados técnicas de pré-processamento, como a detecção de anomalias e remoção de outliers, identificando possíveis ruídos na rede elétrica ou na medição do sensor. Além disso, foi necessário decidir uma data inicial para a aplicação das análises. A Figura 1 mostra a quantidade de dispositivos que estavam enviando dados no período de tempo do monitoramento. Através desta figura, foi possível decidir o período de 11/2022 como início das análises, devido a grande diferença de sensores fazendo a aquisição dos dados.



Figura 1 - Quantidade de dispositivos conectados simultaneamente no laboratório ao longo do tempo  
Fonte: Os Autores

Por fim foi necessário converter os dados coletados de potência em *Watts* para dados de energia consumida. Para realizar essa transformação, utilizou-se a frequência de aquisição dos dados (periodicidade) e o fator de potência esperado para os dados de potência aparente adquiridos. Desta forma, foi possível aplicar modelos preditivo e realizar análises do consumo de energia.

O algoritmo escolhido para a predição foi a árvore de decisão que é uma técnica de aprendizado de máquina que se baseia em uma estrutura hierárquica de decisões em forma de árvore. Ele trabalha identificando características importantes nos dados e dividindo-os em subgrupos, seguindo um processo

de perguntas "sim ou não" em cada nó da árvore. Essa abordagem permite que o algoritmo tome decisões complexas ao mapear diferentes caminhos na árvore, tornando-se uma poderosa ferramenta para classificação e regressão de dados (MIENYE; SUN; WANG, 2019).

## RESULTADOS E DISCUSSÃO:

A primeira análise realizada foi a matriz de correlação, com o intuito encontrar possíveis dados de sensores que contribuíssem para a performance do modelo preditivo e pudessem ser utilizados como dados de entrada. A Figura 2 mostra a correlação entre diversos tipos de gases com o consumo de água e energia do laboratório.

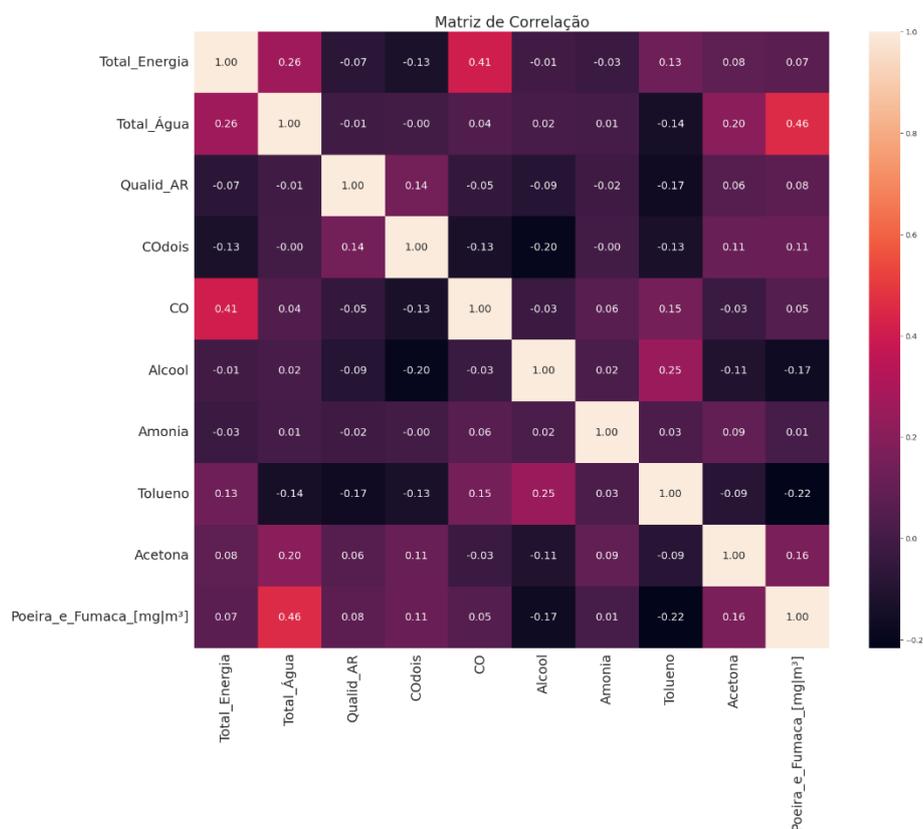


Figura 2 – matriz de correlação dos sensores presentes no laboratório  
Fonte: Os Autores

O monóxido de Carbono (CO) foi o dado que apresentou a maior correlação com o consumo de energia, entretanto não houve melhora significativa ao adicionar o CO na previsão do consumo de Energia. Em seguida foi analisado o padrão de consumo semanal do laboratório considerando a média de consumo dos 30 equipamentos instalados no laboratório agrupando os dados por dia e por horário, como mostra a Figura 3.

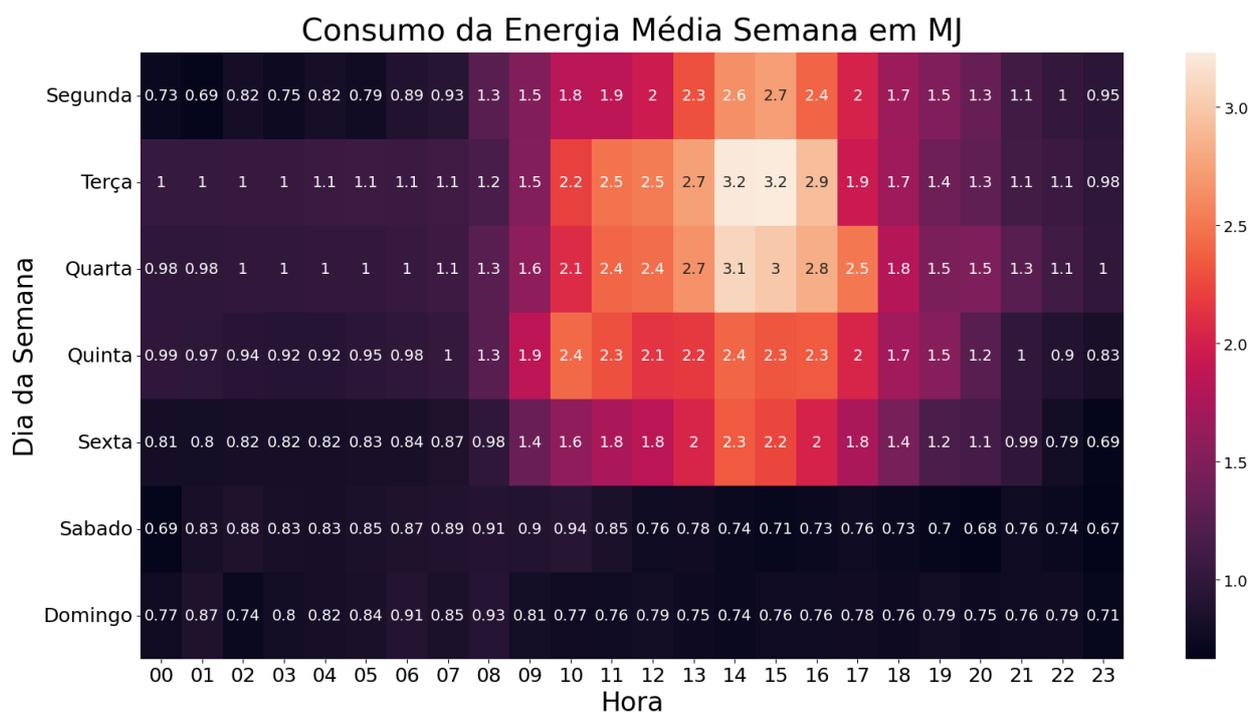


Figura 3 – Consumo de Energia em Mega Joules semanal do laboratório  
Fonte: Os Autores

Observou um aumento do consumo no período entre as 9:00 e 20:00 horas, como esperado os picos de consumo ocorreram nos mesmos horários de aula e utilização do laboratório. Ao todo foram 188 dias avaliados e esses dados foram utilizados para treinar um modelo de regressão, com o intuito de prever o consumo de energia.

A Arvore de Decisão foi aplicada com os parâmetros definidos por um algoritmo de busca chamado *GridSearchCV*, esta técnica aplica o modelo diversas vezes para encontrar os melhores resultados. Os parâmetros do melhor modelo foi uma árvore com no máximo 9 ramificações em que cada ramificação deve conter pelo menos 6 amostras a serem separadas em um nó interno. A Figura 4 mostra os resultados das previsões feita pelo modelo.

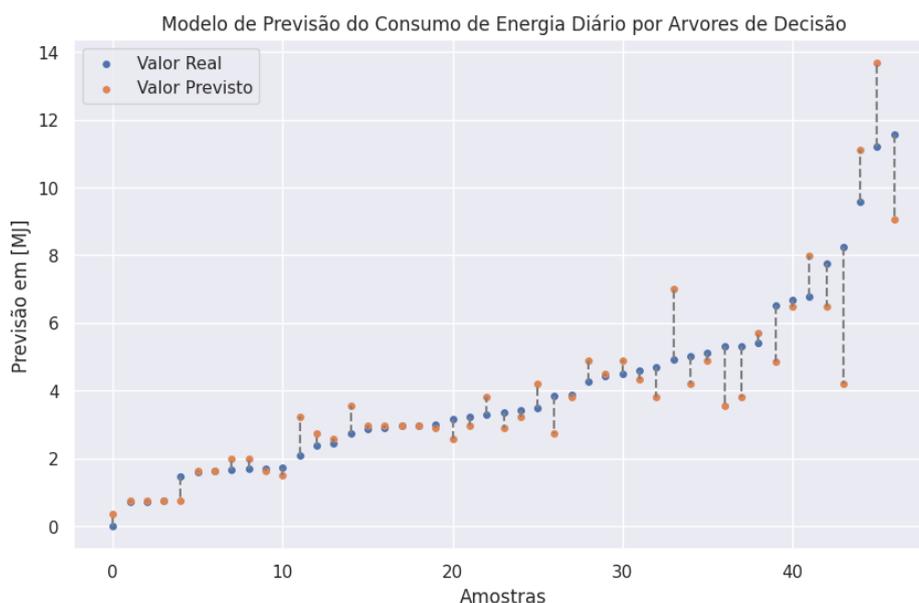


Figura 4 – Modelo Preditivo utilizando Arvores de Decisão para o consumo de Energia Diário do Laboratório  
Fonte: Os Autores

As previsões do modelo apresentaram um erro absoluto médio de 0,05024 e um erro quadrático médio de 0,00612. Esses valores indicam que o modelo possui um bom desempenho em fazer previsões próximas aos valores reais, com erros médios relativamente baixos, entretanto as previsões são limitadas a um intervalo de 24 horas devido a quantidade de dados coletados pelos sensores.

## **CONCLUSÕES:**

A pesquisa contribuiu para compreender os benefícios e limitações da implementação de conceitos de IoT e métodos computacionais para análise do consumo energético. Contudo, apesar dos bons resultados realizados pelos modelos preditivos, estes limitam a previsão de curto prazo devido ao período de coleta que foi de 6 meses e abrangeu também o período de férias escolares e não previsões a longo prazo como esperado.

O tratamento dos dados monitorados e consumo de energia semanal calculado viabilizou a colaboração com outros membros da equipe de projeto. Uma das colaborações foi com os envolvidos nos cálculos comparativos entre consumo de energia primária real x estimada, sendo um indicador importante para a ACV de um ambiente em uso. A segunda colaboração foi o fornecimento de dados contínuos para serem visualizados no Gêmeo Digital do ambiente monitorado, permitindo a visualização do desempenho do indicador de ACV em análise. Futuramente, tomando como base um período maior de coleta de dados, retoma-se os algoritmos de predição do consumo retomar o problema de confiabilidade e precisão dos resultados da ACV.

---

## **BIBLIOGRAFIA**

HARRIS T.; LANDIS A. Life Cycle Assessment: A Tool to Help Design Environmentally Sustainable Space Technologies, 2020 IEEE Aerospace Conference, Big Sky, MT, USA , p. 1-11, 2020.

LI Yan, et al. Fuzzy Comprehensive Evaluation Method for Energy Management Systems Based on an Internet of Things, IEEE Access, v.5, p.21312-21322, 2017.

MIENYE I. D.; SUN Y.; WANG Z. Prediction performance of improved decision tree-based algorithms: a review, Procedia Manufacturing, v. 35, p. 698-703, 2019.

ZEKIĆ-SUŠAC M.; MITROVIĆ S.; HAS A. Machine learning based system for managing energy efficiency of public sector as an approach towards smart cities, International Journal of Information Management, v. 58, p. 102074, 2021.