



ENTAC 2024

XX ENCONTRO NACIONAL DE TECNOLOGIA DO AMBIENTE CONSTRUÍDO
Maceió, Brasil, 9 a 11 de outubro de 2024



Estrutura de referência para integração entre Avaliação do Ciclo de Vida e Aprendizado de Máquina

Reference framework for integration between Life Cycle
Assessment and Machine Learning

Natalia Nakamura Barros

Universidade Estadual de Campinas | Campinas | Brasil |
natalianakamura.arq@gmail.com

Regina Coeli Ruschel

Universidade Estadual de Campinas | Campinas | Brasil | ruschel@unicamp.br

Resumo

Esta pesquisa identifica estudos que associam Avaliação do Ciclo de Vida (ACV) e o aprendizado de máquinas (AP) e elabora uma estrutura de referência de integração entre essas áreas. Para tal, o método estruturalista foi aplicado com o seguinte delineamento: identificação dos elementos para integração a partir de uma Revisão Sistemática de Literatura (RSL), conceituação, estabelecimento das relações entre os elementos, elaboração do modelo estrutural e análise. A estrutura integrativa categoriza e associa elementos característicos da ACV e do AP. O estudo confirmou as etapas da ACV como as categorias de seus elementos, sendo estas: *goal and scope definition, life cycle inventory, life cycle impact assessment e interpretation*; e relacionada à AP: *algorithm*. Foi possível verificar que AP auxilia em todos os estágios da ACV, mas recursos como predição, otimização e clusterização variam a depender da etapa e objetivos. A contribuição da estrutura integrativa está no auxílio aos profissionais de ACV na seleção dos diferentes recursos do AP incorporando a inteligência artificial para os diferentes cenários de avaliação de impacto ambiental.

Palavras-chave: Modelo integrativo. Predição. Otimização. Clusterização.

Abstract

*This research identifies studies that associate Life Cycle Assessment (LCA) and machine learning (ML) and develops an integrative reference structure between these areas. The structuralist method was applied with the following design: identification of elements for integration based on a Systematic Literature Review (SLR), conceptualization, establishment of relationships between elements, elaboration of the structural model and analysis. The integrative structure categorizes and associates characteristic elements of LCA and ML. The study confirmed the LCA stages as the categories of its elements: *goal and scope definition, life cycle inventory, life cycle impact assessment and interpretation*; and related to ML: *algorithm*. It was possible to verify that ML helps in all stages of LCA, but prediction, optimization and clustering resources vary depending on the stage and objectives. The contribution of the integrative structure is to assist LCA professionals in selecting key ML resources incorporating artificial intelligence for different environmental impact assessment scenarios.*



Como citar:

BARROS, N.N.; RUSCHEL, R.C. Estrutura de referência para integração entre Avaliação do Ciclo de Vida e Aprendizado de Máquina. In: ENCONTRO NACIONAL DE TECNOLOGIA DO AMBIENTE CONSTRUÍDO, 20., 2024, Maceió. **Anais...** Maceió: ANTAC, 2024.

Keywords: Integrative model. Prediction. Optimization. Clustering.

INTRODUÇÃO

A maneira como abordamos o projeto de edificações deve ser repensada considerando as mudanças climáticas, o aquecimento global e a escassez de recursos. Para esse fim, métodos de avaliação de impacto ambiental, como Avaliação do Ciclo de Vida (ACV) são cada vez mais utilizados. No entanto, correm o risco de não obter os benefícios esperados devido ao alto número de parâmetros e fatores de incerteza que caracterizam os impactos dos edifícios ao longo de sua vida útil. Além disso, o esforço e o custo necessários para uma avaliação confiável parecem ser as principais barreiras para uma adoção mais ampla da ACV. Parece, portanto, possível um progresso mais rápido em direção à redução dos impactos da edificação, combinando métodos estabelecidos de avaliação de impacto ambiental com abordagens de Inteligência Artificial (IA), como aprendizado de máquina (AP) e redes neurais artificiais (RNA) [1].

Para propor corretamente medidas para economizar energia e reduzir os impactos ambientais de um edifício, como a contribuição para o efeito estufa, é necessária uma avaliação abrangente de energia e de desempenho do edifício. Atualmente, a solução desse problema complexo normalmente requer uma equipe interdisciplinar, conhecimento em software ou algoritmo específico, um usuário especialista, coleta de uma grande quantidade de dados e longo tempo computacional. A falta de uma linguagem comum frequentemente complica a interpretação dos resultados entre essas duas áreas que são significativamente diferentes, mas altamente conectadas [2].

A avaliação de sustentabilidade tem sido um dos principais contribuintes para análises avançadas de edificações e tradicionalmente envolve técnicas de ACV para avaliações retrospectivas e prospectivas. Um grande desafio para obter uma avaliação de sustentabilidade confiável vem do entendimento inadequado das atividades subjacentes relacionadas a cada um dos estágios do ciclo de vida da edificação, com base no conhecimento de especialistas. A modelagem orientada a dados, por outro lado, é uma abordagem emergente que aproveita os métodos de aprendizado de máquina na construção de modelos que complementam ou substituem os modelos baseados no conhecimento. Incorporar modelos de análise de dados adequados para utilizar dados de materiais, produtos e processos em tempo real pode melhorar significativamente as técnicas de ACV [3].

A IA é o estudo das computações que possibilita perceber, raciocinar e agir. O objetivo da IA é resolver problemas do mundo real, de modo a criar novas oportunidades em negócios, engenharia e muitas outras áreas de aplicação [4]. Para atingir este objetivo, técnicas e métodos de AP podem ser utilizadas, para descobrir padrões latentes e derivar insights úteis a partir deles [5]. Apesar do crescente interesse dos pesquisadores por este tema, ainda existem poucos estudos, principalmente voltados à arquitetura, engenharia, construção e operação (AECO).

Pesquisas na área de AP para avaliação do ciclo de vida de edificações (ACVed) estão apenas começando. Entretanto, o potencial de uso é grande. AP pode ser utilizada para

diferentes finalidades dentro da ACV. Um dos principais usos é para predição de: consumo de energia [2][3][6][7], *Global Warming Potential* (GWP) [8][9] e, outros indicadores ambientais [2]. Modelos preditivos podem ser utilizados também para substituir modelos simulados para análises de incerteza na ACV [10], ou para desenvolvimento da ACV dinâmica, na qual técnicas de análise de série temporal podem ser utilizadas para considerar o tempo na avaliação [11].

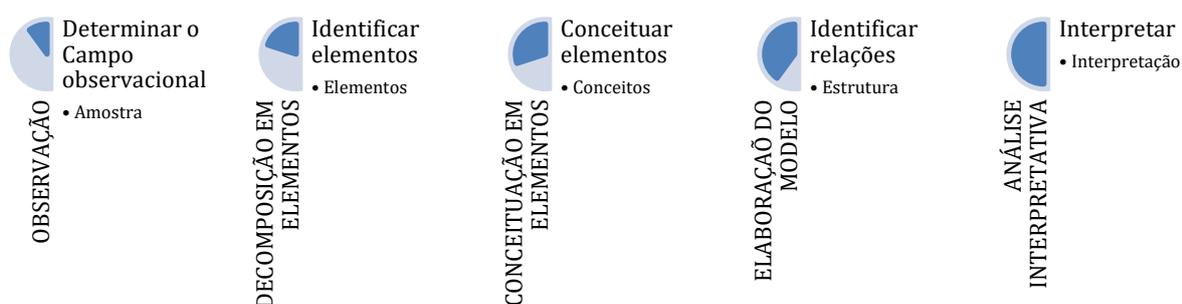
Algoritmos de AP, como a clusterização, podem ser utilizados para identificar grupos de materiais de construção [12]. A tomada de decisão do projetista também pode ser auxiliada por algoritmos de otimização. Propriedades da edificação podem ser combinadas de diferentes formas a fim de minimizar diferentes impactos, como: o consumo de energia e impactos ambientais [13], pegada de carbono e custo [14], poluição ambiental e saúde humana [15], entre outros.

Esta pesquisa identifica as abordagens de integração ACV e AP desenvolvidas em estudos anteriores, a partir de uma Revisão Sistemática da Literatura (RSL) e elabora estrutura de referência de integração, que aborda processos genéricos de integração, que podem ser aplicados em diferentes cenários e para diversas abordagens de integração entre ACV e AP. O resultado desta pesquisa pode fornecer aos profissionais de ACV uma maneira prática de selecionar a abordagem de uso de AP em diferentes cenários de avaliação de impacto ambiental e facilitar a aplicação de abordagens de integração ACV-AP no setor da construção.

MÉTODO

Para o desenvolvimento do modelo estrutural para integração entre ACV e AP, foi utilizado o método estruturalista. O estruturalismo é uma construção teórica iniciada pelo etnólogo Claude Lévi-Strauss, que se propõe a desenvolver uma teoria lógica construída a partir do real concreto [16]. Pretende-se, portanto, criar uma estrutura lógica da integração entre ACV e AP a partir de artigos relacionados ao tema. Para tal, foi conduzida uma RSL para buscar estas proposições e identificar os elementos de diálogo entre os sistemas AP a ACV e suas relações. O delineamento do método está demonstrado na Figura 1 e consistiu na identificação dos elementos de aproximação entre AP e ACV, conceituação dos elementos, estabelecimento das relações entre os elementos, elaboração do modelo estrutural e análise do modelo estrutural.

Figura 1: Etapas do método



Fonte: os autores.

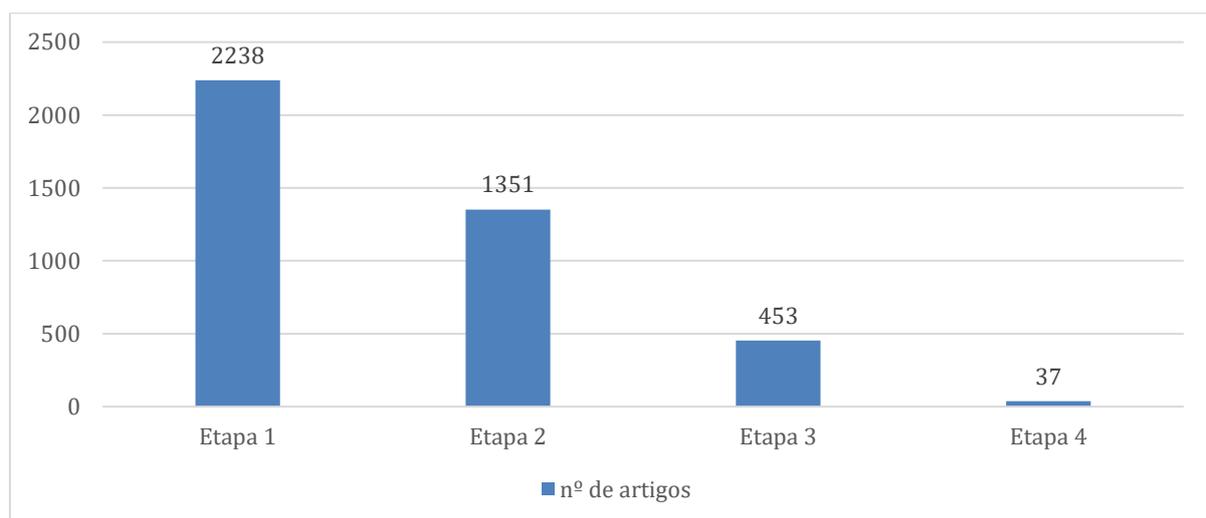
As fontes utilizadas correspondem à bases de dados relevantes para a área de Arquitetura, Engenharia, Construção e Operação (AECO), sendo estas: *Scopus*, *Engineering Village* e *Web of Science*. Os termos de busca utilizados foram “*Life Cycle Assessment*”, “*Machine Learning*”, ML e LCA, e o conector “*and*”, para os campos de título, resumo e palavras-chave. Foram analisados os documentos publicados até 2023, sendo que os repositórios apresentaram um total 2238 estudos. Como critérios de exclusão, foram desconsiderados os estudos que não estavam publicados em língua inglesa, que não foram publicados em periódicos ou não foram publicados em anais de conferências com revisão por pares, ACV e AP não eram o foco principal do artigo, ou não eram relacionados à AECO.

Após esta etapa, os artigos foram lidos na íntegra, e manteve-se apenas os estudos avaliados como de alta qualidade [17], que constituem estudos que abordam precisamente a integração de ACV com AP. Após a execução da RSL, outros artigos foram incluídos na amostra a partir da lista de referências da amostra, na qual verificou-se estudos de alta qualidade durante a leitura completa dos artigos.

RESULTADOS

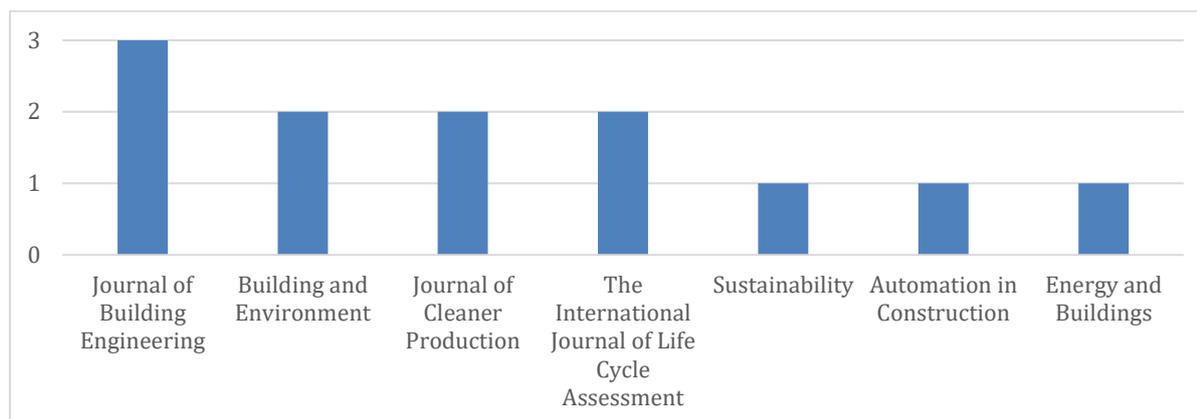
A etapa de observação foi realizada para delimitar o universo observacional, a Figura 2 mostra o número de artigos resultantes em cada etapa da RSL. A maioria dos artigos que compõem a amostra são de artigos de jornais (24 artigos), seguido por artigos de conferência (9 artigos). Entre os artigos de periódicos, a revista mais publicada foi *Journal of Building Engineering*, com 3 artigos. A Figura 3 mostra o número de artigos por revista.

Figura 2: Nº de artigos resultantes em cada etapa da RSL



Fonte: os autores.

Figura 3: Nº de artigos por revista



Fonte: os autores.

Os artigos da RSL de AP+ACV foram classificados segundo a finalidade de uso do algoritmo de AP, sendo esta para: predição, classificação ou otimização. Outros artigos fizeram uma revisão de literatura sobre o tema. A predição utilizou principalmente o aprendizado supervisionado; a classificação, o aprendizado não supervisionado; a otimização, o algoritmo evolutivo ou o algoritmo híbrido. A amostra resultante da etapa de observação está apresentada no Quadro 1. Esta amostra foi utilizada como base para o desenvolvimento das demais etapas do método estruturalista.

Quadro 1: Amostra resultante da RSL classificado por uso de AP

Predição	Classificação	Otimização
[2] [8] [18] [19] [3] [11] [9] [20] [6] [7] [10] [21] [22] [23] [24] [25] [26][27] [28] [29] [30]	[12] [31]	[13] [14] [15] [32] [33] [34] [35] [36]
Revisão de Literatura		
[37] [38] [39] [40]		

Fonte: o autor.

Para predição de impactos em ACV foi utilizado principalmente algoritmos de aprendizado supervisionado, de modo a fornecer suporte à decisão para permitir que usuários não especialistas identifiquem de forma rápida e fácil os desempenhos energéticos e ambientais de edifícios. Os principais focos destes autores foram aplicar algoritmos de AP para: estimativa do consumo de energia [2][3][20], predição de GWP [8] e, estimativa de emissões na etapa de transporte [9]. Outros aplicaram para quantificar as incertezas ambientais [18], predição de vida útil de edifícios [23] e geração de *benchmarks* ambientais para tipologias de construção [24].

A rede neural artificial (RNA) foi o algoritmo que apresentou os melhores resultados [2][8]. Além disso, houve uma melhoria do tempo computacional junto a uma precisão aceitável [20]. Entretanto, verificou-se que a RNA necessita de um número considerável de dados de aprendizagem [8][19]. Outros algoritmos, também podem ser utilizados para estimativa do consumo de energia, como a rede Bayesiana (BN) [3], abordagem estocástica baseada na cadeia de Markov [6], rede neural de retropropagação (BPNN) [7] e algoritmo de regressão de processo gaussiano (GPR) [30].

Ma e Kim [11] propuseram um algoritmo de mineração de uso preditivo para avaliação do ciclo de vida, chamado PUMLCA, que permite ACV preditiva em um horizonte de tempo real. Kharbanda *et al.* [27] apresentaram o desenvolvimento de uma ferramenta chamada LearnCarbon, como plugin do Rhino3d, utilizada para auxiliar arquitetos e engenheiros em estágios iniciais sobre o impacto ambiental de seus projetos.

Teodosio *et al.* [21] aplicaram um *multi-output deep learning* (DL) model, denominado *Multi-Output Non-linear Design of Slabs* (MOUNDS), para investigar o tipo de fundação mais vantajoso em termos de atributos de sustentabilidade e desempenho de manutenção. Esteghamati e Flint [25] avaliaram cinco modelos de AP, regressão múltipla, floresta aleatória, *extreme gradientboosting*, *support vector machine* (SVM) e *k-nearest neighbor*, para prever a vulnerabilidade sísmica e os impactos ambientais de edifícios de escritórios.

Koyampambath *et al.* [28] propuseram o uso de técnicas de Processamento de Linguagem Natural e floresta aleatória para prever o desempenho ambiental. Su *et al.* [29] propuseram um modelo dinâmico de avaliação do consumo de energia doméstico e das emissões de carbono na perspectiva do ocupante. Bragança e Muniesa [26] utilizaram a regressão linear como método de medição de baixo carbono para a concepção de edifícios.

Dos artigos que trataram acerca da clusterização, os algoritmos de aprendizado não supervisionado foram utilizados para encontrar padrões entre os dados. Estes podem auxiliar na identificação de grupos de materiais de construção [12] e para definição de arquetipos [31].

A otimização da performance ambiental, foi feita principalmente com uso de algoritmos evolutivos. Alguns autores utilizaram um algoritmo de otimização multi-objetivo (MOGA) para minimizar o consumo de energia e impactos ambientais [13][20], outros para minimizar a pegada de carbono do ciclo de vida e avaliação de custo do ciclo de vida (ACC) [14]. Já Shi e Xu [15] utilizaram um algoritmo híbrido GA-BP, que combina algoritmo genético (GA) e BPNN, para avaliação de materiais de construção. Song *et al.* [36] aplicaram um algoritmo baseado em rede neural profunda combinado com NSGA-II para determinar a melhor opção de desempenho da estrutura de edifício, considerando a GWP, ACC e horas de desconforto térmico. Abdou *et al.* [32] analisaram a otimização de cargas de aquecimento e arrefecimento em três climas diferentes em Marrocos. Zhou, Tam e Le [33] avaliaram os impactos incorporados e operacionais e, Abokersh *et al.* [34] otimizaram o desempenho térmico, o custo líquido e o impacto ambiental. Por fim, Apellániz, Pettersson e Gengnagel [35] desenvolveram um novo plug-in Grasshopper para implementar aprendizado por reforço.

Dos autores que fizeram revisão de literatura, Farahzadi e Kioumars [37] encontraram cinco clusters conceituais: (1) design/produção de materiais e componentes sustentáveis, (2) veículos e equipamentos no local, (3) avaliação de energia e ciclo de vida, (4) otimização, tomada de decisão e plataformas baseadas em soluções e (5) monitoramento do mundo real. Ghoroghi *et al.* [38] dividiram os níveis computacionais na ACV em três categorias: inventário, modelagem e otimização. Algren, Fisher e

Landis [40] verificaram que AP tem sido utilizado na ACV para estimar os valores dos fatores de caracterização do impacto ambiental e para realizar análises de sensibilidade. E, Barros e Ruschel [39] demonstraram: (i) aumento no número de artigos nos últimos anos; (ii) que os indicadores ambientais mais pesquisados foram o consumo de energia e GWP; (iii) o aprendizado de máquina é usado principalmente para previsão de impactos e; (iv) o método de AP mais utilizado são as Redes Neurais Artificiais.

DECOMPOSIÇÃO E CONCEITUAÇÃO

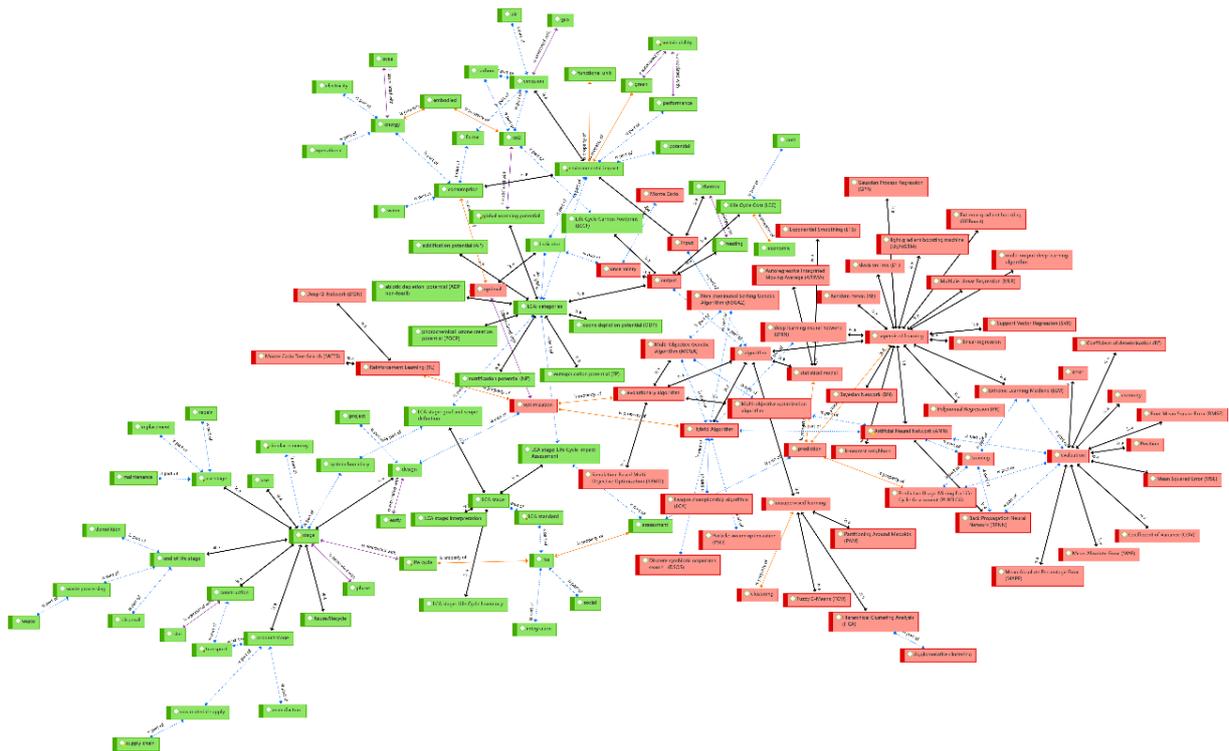
Na primeira etapa da decomposição, a lista de recorrência de palavras foi extraída a partir do software Atlas Ti e as palavras com porcentagem maior que 0,10% em relação ao total de palavras do conjunto amostral foram selecionados. Desta extração, resultou-se em 161 palavras. Na segunda etapa da decomposição, foram excluídas palavras de um caractere, números, hífen, elementos duplicados, pronomes, preposições, advérbios, conjunções, artigos, numerais, adjetivos e verbos. A técnica de homogeneização foi aplicada a fim de eliminar elementos no plural e outros que apresentam similaridade conceitual, como *environment* e *environmental*. Uma leitura minuciosa na íntegra dos textos foi realizada. Os elementos foram readequados, alguns, que não eram muito significativos foram excluídos e outros foram gerados. Alguns elementos foram mesclados, como *Machine + Learning* ou *Life + Cycle + Assessment*. Quando estes elementos apareciam em conjunto, eles eram mesclados em um elemento único, no caso, ML e LCA, respectivamente. Esta etapa resultou em 125 elementos finais.

Na etapa de conceituação, utilizou-se a codificação teórica e análise global para buscar os significados dos elementos. A partir dos elementos selecionados, foi realizada a codificação automática em todos os documentos da amostra, para identificar toda e qualquer ocorrência isolada de um elemento numa frase. As citações geradas pela codificação automática foram redimensionadas de modo que se concentrassem apenas no texto do documento. Nesta etapa também foi utilizado o software Atlas Ti. A partir da leitura completa dos textos, buscou-se os significados dos elementos. Os conceitos foram retirados diretamente dos textos, a partir de buscas em dicionário, ou a partir de referências. Os conceitos auxiliaram a estabelecer as relações entre os elementos e construir o modelo integrativo.

MODELO INTEGRATIVO

O modelo desenvolvido permite verificar os elementos essenciais de AP necessários para apoiar a ACV de edificações. O modelo integrativo de ACV com suporte de AP e suas relações estão demonstrados na Figura 4. O modelo foi demonstrado a partir de layouts elaborados automaticamente pelo software Atlas Ti.

Figura 4: Modelo integrativo de ACV + AP visualizado no layout orgânico

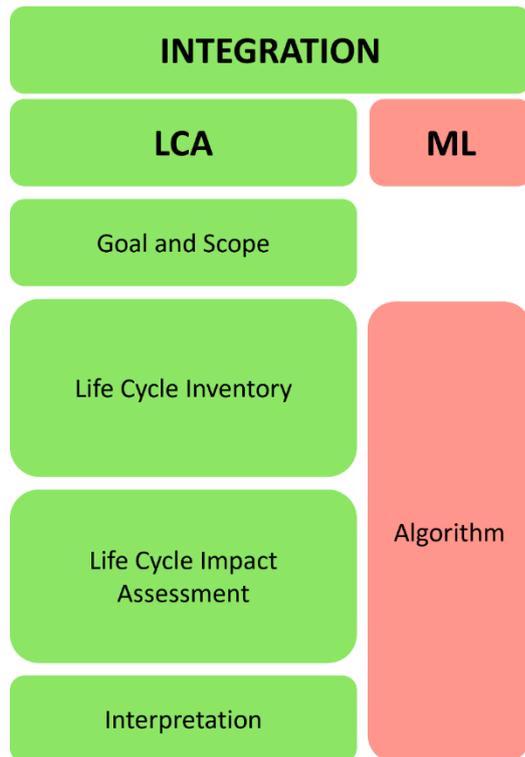


Fonte: os autores.

A figura anterior não permitiu a visualização clara dos elementos e suas relações. Deste modo, foi aplicada a codificação seletiva, ou seja, os elementos foram divididos em categorias e apresentados no formato de tabela periódica. Os principais elementos comuns dos sistemas de AP voltados à ACV foram divididos em 5 categorias. As categorias foram organizadas no formato de tabela periódica, cuja classificação se deu devido à proximidade conceitual entre os elementos, conforme mostrado na Figura 5. À esquerda, encontram-se as categorias relacionadas à ACV: *goal and scope definition*, *life cycle inventory*, *life cycle impact assessment* e *interpretation*. À direita, encontra-se *algorithm* relacionado à AP.

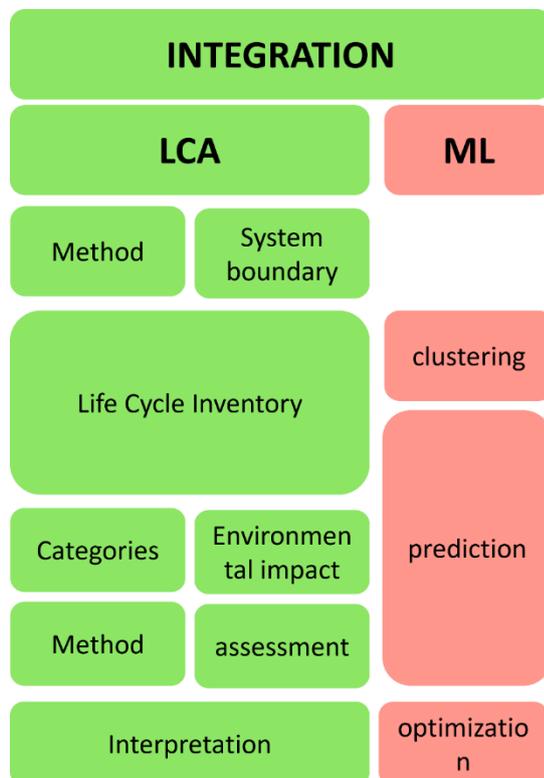
Cada uma dessas categorias se expande em elementos distintos de um ecossistema de ACV com AP. A ordenação dos elementos dentro de cada categoria representa um detalhamento, do geral para o específico, ou um encadeamento, conforme apresentado na Figura 6.

Figura 5: Diagrama das categorias da estrutura de integração entre AP e ACV



Fonte: os autores.

Figura 6: Tabela periódica dos elementos do ecossistema de AP com ACV



Fonte: os autores.

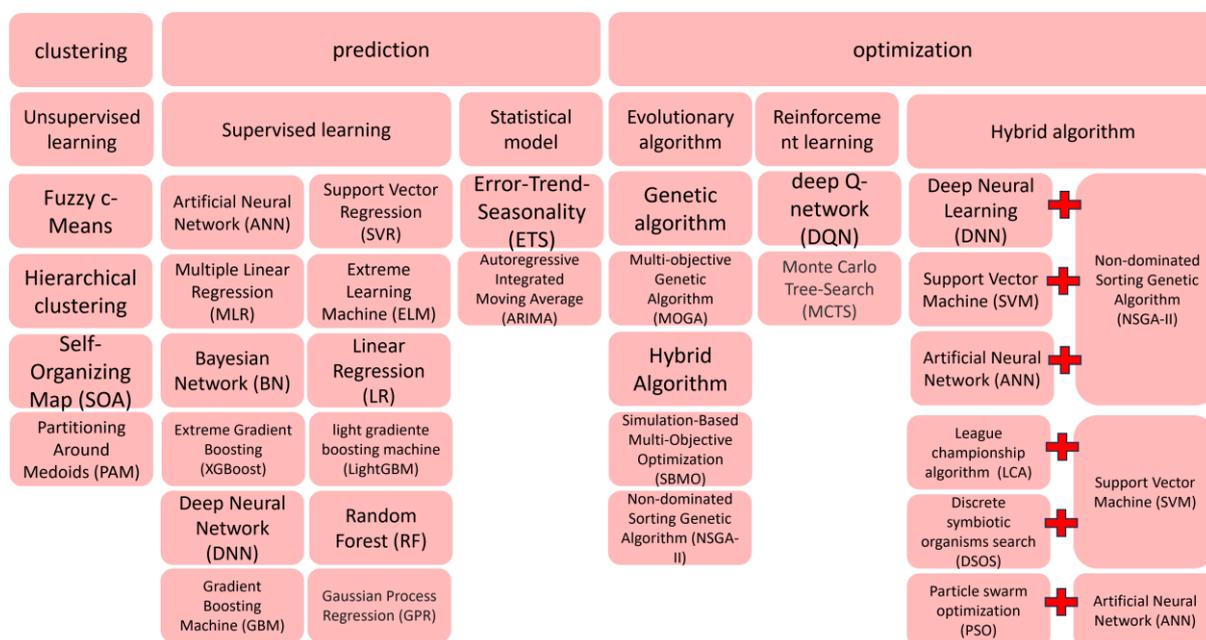
Goal and scope definition refere-se à fase da ACV na qual se define a unidade funcional, limites do sistema, métodos de análise, que auxiliarão no desenvolvimento da ACV. Além disso, nesta etapa, define-se o produto e o estágio do ciclo de vida a ser avaliado,

tais como: fase de projeto; estágio de produção, que abrange a extração da matéria-prima, fabricação do produto e transporte; construção; estágio de uso, que abarca também a manutenção, reparo e substituição e; estágio de fim-de-vida, que abrange a demolição, disposição e processamento de resíduos.

Life Cycle Inventory é caracterizada principalmente pela coleta e armazenamento de dados. *Life Cycle Impact Assessment* é responsável por transformar os resultados da análise de inventário em resultados ambientalmente relevantes, relacionando-os a impactos específicos. Na *Interpretation*, o resultado obtido na fase anterior é analisado e visualizado pelos usuários para auxiliar na tomada de decisão.

Quanto às categorias de elementos associados à AP, dentro da categoria *Algorithm*, os algoritmos podem ser utilizados para clusterização, previsão e otimização. A Figura 7 mostra os algoritmos que foram encontrados na RSL. Para clusterização, foram utilizados algoritmos de aprendizagem não-supervisionada, como: *fuzzy c-means* e *hierarchical clustering*. Para previsão, foram utilizados algoritmos de aprendizagem supervisionada, como RNA, BN, SVR e regressão linear múltipla; bem como modelos estatísticos, como *Error-Trend-Seasonality (ETS)* e *Autoregressive Integrated Moving Average (ARIMA)*. Para otimização, foram utilizados algoritmos evolutivos, como: algoritmo genético, MOGA e *simulation-based multi-objective optimization (SBMO)*.

Figura 7: Elementos da categoria *Algorithm*



Fonte: os autores.

ANÁLISE INTERPRETATIVA

Na análise interpretativa, foi aplicado um filtro sobre o modelo a fim de compreender o conhecimento a relação entre ACV e AP. A Figura 8 mostra um filtro aplicado ao modelo, com foco nas categorias e elementos contidos nas tabelas periódicas.

O modelo estrutural pode, deste modo, ser utilizado por especialistas ACV e pessoas que desejam utilizar AP, proporcionando-lhes uma compreensão básica antes de mergulharem na seleção ou desenvolvimento de tecnologia. Além disso, o modelo desenvolvido pode ser utilizado para comparação, descrição e compreensão de trabalhos relacionados ao tema.

O resultado desta pesquisa pode ajudar a compreender melhor o desempenho de diferentes abordagens de integração ACV-AP e fornecer aos profissionais de ACV uma maneira de selecionar a abordagem de integração ACV-AP ideal para implementação de ACV. As conclusões desta investigação apoiam que AP pode apoiar ACV nas fases de ICV, AICV e interpretação. Esta pesquisa fornece uma referência importante para compreensão das abordagens de integração entre AP e ACV, examinando a aplicabilidade de diferentes abordagens de integração para diferentes cenários.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001 e Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq – Processo 428604/2018-8.

REFERÊNCIAS

- [1] D’AMICO, B. et al. Machine Learning for Sustainable Structures: A Call for Data. **Structures**, v. 19, p. 1–4, 1 jun. 2019.
- [2] D’AMICO, A. et al. Artificial Neural Networks to assess energy and environmental performance of buildings: An Italian case study. **Journal of Cleaner Production**, v. 239, p. 117993, dez. 2019.
- [3] LI, Yunpeng et al. A Data-Driven Approach for Improving Sustainability Assessment in Advanced Manufacturing. In: IEEE INTERNATIONAL CONFERENCE ON BIG DATA (BIG DATA), 2017, Boston, MA. *Anais...* Boston, MA: IEEE, 2017.
- [4] WINSTON, Patrick Henry. **Artificial Intelligence**. 3rd ed. ed. USA: Addison-Wesley Publishing Company, 1993.
- [5] BILAL, Muhammad et al. Big Data in the construction industry: A review of present status, opportunities, and future trends. **Advanced Engineering Informatics**, v. 30, p. 500–521, 2016.
- [6] WANG, E.; SHEN, Z. Lifecycle Energy Consumption Prediction of Residential Buildings by Incorporating Longitudinal Uncertainties. **Journal of Civil Engineering and Management**, v. 19, n. SUPPL.1, p. S161–S171, 2013.
- [7] XIA, Liming; LIU, Jingjing. Research on Green Building Assessment System Based on BP neural network and Life Cycle Assessment (LCA). **Applied Mechanics and Materials**, v. 357–360, p. pp 508-514, 2013.
- [8] DUPREZ, Sandrine et al. Improving life cycle-based exploration methods by coupling sensitivity analysis and metamodels. **Sustainable Cities and Society**, v. 44, p. 70–84, 2019.
- [9] PERROTTA, Federico et al. A machine learning approach for the estimation of fuel consumption related to road pavement rolling resistance for large fleets of trucks. *out.*

2018, Belgium. *Anais...* Belgium: [s.n.], out. 2018. Disponível em:
<<http://eprints.nottingham.ac.uk/51400/>>.

- [10] ZIYADI, Mojtaba; AL-QADI, Imad L. Model uncertainty analysis using data analytics for life-cycle assessment (LCA) applications. **The International Journal of Life Cycle Assessment**, v. 24, n. 5, p. 945–959, maio 2019.
- [11] MA, Jungmok; KIM, Harrison M. Predictive Usage Mining for Life Cycle Assessment. **Transportation Research Part D: Transport and Environment**, v. 38, p. 125–143, 2015.
- [12] MARVUGLIA, Antonino; KANEVSKI, Mikhail; BENETTO, Enrico. Machine learning for toxicity characterization of organic chemical emissions using USEtox database: Learning the structure of the input space. **Environment International**, v. 83, p. 72–85, 1 out. 2015.
- [13] AZARI, Rahman et al. Multi-Objective Optimization of Building Envelope Design for Life Cycle Environmental Performance. **Energy and Buildings**, v. 126, p. 524–534, 15 ago. 2016.
- [14] SCHWARTZ, Yair; RASLAN, Rokia; MUMOVIC, Dejan. Implementing multi objective genetic algorithm for life cycle carbon footprint and life cycle cost minimisation: A building refurbishment case study. **Energy**, v. 97, p. 58–68, 15 fev. 2016.
- [15] SHI, Qian; XU, Yilong. The Selection of Green Building Materials Using GA-BP Hybrid Algorithm. In: 2009 INTERNATIONAL CONFERENCE ON ARTIFICIAL INTELLIGENCE AND COMPUTATIONAL INTELLIGENCE, nov. 2009, Shanghai, China. *Anais...* Shanghai, China: IEEE, nov. 2009. p. 40–45.
- [16] THIRY-CHERQUES, Hermano Roberto. O Primeiro Estruturalismo: Método de Pesquisa para as Ciências da Gestão. **RAC**, v. 10, n. 2, p. 137–156, 2006.
- [17] DRESCH, Aline; LACERDA, Daniel Pacheco; ANTUNES JUNIOR, Jose Antonio Valle. **Design Science Research: A Method for Science and Technology Advancement**. Switzerland: Springer International Publishing, 2015.
- [18] FENG, Kailun; LU, Weizhuo; WANG, Yaowu. Assessing Environmental Performance in Early Building Design Stage: An Integrated Parametric Design and Machine Learning Method. **Sustainable Cities and Society**, v. 50, p. 101596, 1 out. 2019.
- [19] GOLAK, Sławomir et al. Application of Neural Network for the Prediction of Eco-Efficiency. *Lecture Notes in Computer Science*, 2011, Berlin, Heidelberg. *Anais...* Berlin, Heidelberg: Springer, 2011. p. 380–387.
- [20] SHARIF, Seyed Amirhosain; HAMMAD, Amin. Developing surrogate ANN for selecting near-optimal building energy renovation methods considering energy consumption, LCC and LCA. **Journal of Building Engineering**, v. 25, p. 100790, set. 2019.
- [21] TEODOSIO, B. et al. Environmental, economic, and serviceability attributes of residential foundation slabs: A comparison between waffle and stiffened rafts using multi-output deep learning. **Journal of Building Engineering**, v. 80, p. 107983, 1 dez. 2023.
- [22] JI, Sukwon et al. Effect of realistically estimated building lifespan on life cycle assessment: A case study in Korea. **Journal of Building Engineering**, v. 75, p. 107028, 15 set. 2023.
- [23] JI, Sukwon; LEE, Bumho; YI, Mun Yong. Building life-span prediction for life cycle assessment and life cycle cost using machine learning: A big data approach. **Building and Environment**, v. 205, p. 108267, 1 nov. 2021.
- [24] MARTÍNEZ-ROCAMORA, Alejandro et al. Environmental benchmarking of building typologies through BIM-based combinatorial case studies. **Automation in Construction**, v. 132, p. 103980, 1 dez. 2021.

- [25] ESTEGHAMATI, Mohsen Zaker; FLINT, Madeleine M. Developing data-driven surrogate models for holistic performance-based assessment of mid-rise RC frame buildings at early design. **Engineering Structures**, v. 245, p. 112971, 15 out. 2021.
- [26] BRAGANÇA, Luís; MUNIESA, María Concepción Verde. Measuring Carbon in Cities and Their Buildings through Reverse Engineering of Life Cycle Assessment. **Applied System Innovation**, v. 6, n. 5, p. 76, out. 2023.
- [27] KHARBANDA, Kritika et al. LearnCarbon: 40th Conference on Education and Research in Computer Aided Architectural Design in Europe, eCAADe 2022. In: 42ND ECAADE CONFERENCE 2022 - CO-CREATING THE FUTURE, Proceedings of the International Conference on Education and Research in Computer Aided Architectural Design in Europe, 2022, Nicosia, Cyprus. *Anais...* Nicosia, Cyprus: Education and research in Computer Aided Architectural Design in Europe, 2022. p. 601–610. Disponível em: <<http://www.scopus.com/inward/record.url?scp=85139248291&partnerID=8YFLogxK>>. Acesso em: 29 fev. 2024.
- [28] KOYAMPARAMBATH, Anish et al. Implementing Artificial Intelligence Techniques to Predict Environmental Impacts: Case of Construction Products. **Sustainability**, v. 14, n. 6, p. 1–12, 2022.
- [29] SU, Shu et al. Temporal dynamic assessment of household energy consumption and carbon emissions in China: From the perspective of occupants. **Sustainable Production and Consumption**, v. 37, p. 142–155, 1 maio 2023.
- [30] TOOSI, Hashem Amini et al. A novel LCSA-Machine learning based optimization model for sustainable building design-A case study of energy storage systems. **Building and Environment**, v. 209, p. 108656, 1 fev. 2022.
- [31] COLLETO, Giseli Mary; GOMES, Vanessa. Exploring Machine Learning-Based Archetypes for Urban Life Cycle Modeling (UBiM). In: CENTRAL EUROPE TOWARDS SUSTAINABLE BUILDING 2022 (CESB22), 1., 21 dez. 2022, Prague. *Anais...* Prague: CTU, 21 dez. 2022. p. 169–175. Disponível em: <<https://ojs.cvut.cz/ojs/index.php/APP/article/view/8295>>. Acesso em: 22 fev. 2024.
- [32] ABDU, N. et al. Prediction and optimization of heating and cooling loads for low energy buildings in Morocco: An application of hybrid machine learning methods. **Journal of Building Engineering**, v. 61, p. 105332, 1 dez. 2022.
- [33] ZHOU, Yijun; TAM, Vivian WY.; LE, Khoa N. Trade-off between embodied and operational carbon emissions of residential buildings in early design stage. In: 36TH INTERNATIONAL CONFERENCE ON EFFICIENCY, COST, OPTIMIZATION, SIMULATION AND ENVIRONMENTAL IMPACT OF ENERGY SYSTEMS (ECOS 2023), 2023, Las Palmas de Gran Canaria, Spain. *Anais...* Las Palmas de Gran Canaria, Spain: ECOS 2023, 2023.
- [34] ABOKERSH, Mohamed Hany et al. Sustainability insights on emerging solar district heating technologies to boost the nearly zero energy building concept. **Renewable Energy**, v. 180, p. 893–913, 1 dez. 2021.
- [35] APELLÁNIZ, Diego; PETERSSON, Björn; GENGNAGEL, Christoph. A Flexible Reinforcement Learning Framework to Implement Cradle-to-Cradle in Early Design Stages. 2023, Cham. *Anais...* Cham: Springer International Publishing, 2023. p. 3–12.
- [36] SONG, Junkang et al. Framework on Low-Carbon Retrofit of Rural Residential Buildings in Arid Areas of Northwest China: A Case Study of Turpan Residential Buildings. **Building Simulation**, v. 16, n. 2, p. 279–297, 1 fev. 2023.
- [37] FARAHZADI, Leila; KIOUMARSI, Mahdi. Application of machine learning initiatives and intelligent perspectives for CO2 emissions reduction in construction. **Journal of Cleaner Production**, v. 384, p. 135504, 15 jan. 2023.

- [38] GHOROGHI, Ali et al. Advances in Application of Machine Learning to Life Cycle Assessment: A Literature Review. **The International Journal of Life Cycle Assessment**, v. 27, n. 3, p. 433–456, 1 mar. 2022.
- [39] BARROS, Natalia Nakamura; RUSCHEL, Regina Coeli. Machine Learning for Whole-Building Life Cycle Assessment: A Systematic Literature Review. In: 18TH INTERNATIONAL CONFERENCE ON COMPUTING IN CIVIL AND BUILDING ENGINEERING, 2021, São Paulo. *Anais...* São Paulo: Springer Nature Switzerland, 2021. p. 109–122.
- [40] ALGREN, Mikaela; FISHER, Wendy; LANDIS, Amy E. Chapter 8 - Machine learning in life cycle assessment. In: DUNN, Jennifer; BALAPRAKASH, Prasanna (Org.). . **Data Science Applied to Sustainability Analysis**. [S.l.]: Elsevier, 2021. p. 167–190. Disponível em: <<https://www.sciencedirect.com/science/article/pii/B9780128179765000097>>. Acesso em: 29 fev. 2024.