



03 a 05 de dezembro de 2025

As Engenharias na Transformação Digital das PMEs

Aprimorando Forma e Função: Design Generativo e Otimização Multiobjetivo Aplicados a Quadros de Bicicletas

Rafael Franco Silva Pinto

Programa de Pós-Graduação em Engenharia de Produção e Sistemas - PUCPR

Gilberto Reynoso Meza

Programa de Pós-Graduação em Engenharia de Produção e Sistemas - PUCPR

Resumo: No campo da engenharia e do design, a integração de Design Generativo (DG) e Otimização Multiobjetivo (OMO) tem se mostrado promissora, permitindo abordar simultaneamente eficiência e estética. Esta pesquisa explora a aplicação dessa metodologia para aprimorar as decisões nas fases iniciais do projeto de quadros de bicicletas. O principal desafio reside na lentidão e nas limitações impostas pela dependência da intuição humana nos métodos tradicionais de design. Assim, o objetivo é propor uma nova abordagem que integre DG e OMO para criar um quadro otimizado em estética e eficiência. Um modelo paramétrico foi desenvolvido em Rhinoceros 3D e Grasshopper, incorporando variáveis de design, avaliação de uma abertura interna estratégica e uma medida numérica estética baseada na proporção áurea. A otimização foi realizada com o algoritmo SPEA-2 via plug-in Octopus, gerando soluções Pareto-ótimas que equilibram a minimização do peso, a maximização de espaço livre interno e a qualidade estética.

Palavras-chave: Design Generativo, Otimização Multiobjetivo, Modelo Paramétrico 3D, Estruturas de Veículos.

Enhancing Form and Function: Generative Design and Multi-Objective Optimization Applied to Bicycle Frames

Abstract: In the field of engineering and design, the integration of Generative Design (GD) and Multi-Objective Optimization (MOO) has proven promising, allowing for the simultaneous addressing of efficiency and aesthetics. This research explores the application of this methodology to improve decision-making in the early stages of bicycle frame design. The main challenge lies in the sluggishness and limitations imposed by the reliance on human intuition in traditional design methods. Thus, the objective is to propose a novel approach that integrates GD and MOO to create a frame optimized in terms of aesthetics and efficiency. A parametric model was developed in Rhinoceros 3D and Grasshopper, incorporating design variables, the evaluation of a strategic internal aperture, and a numerical aesthetic measure based on the golden ratio. The optimization was performed with the SPEA-2 algorithm via the Octopus plug-in, generating Pareto-optimal solutions that balance the minimization of weight, the maximization of free internal space, and aesthetic quality.

Keywords: Generative Design, Multiobjective Optimization, 3D Parametric Model, Vehicle Structures.

1. Introdução

O design de estruturas tem evoluído de abordagens tradicionais baseadas em experiência humana, tentativa e erro para métodos computacionais que integram algoritmos avançados, permitindo maior eficiência, criatividade e otimização de desempenho estrutural e estético. Essa transição reflete a adoção crescente de técnicas como o Design Generativo (DG), que utiliza algoritmos para explorar amplos espaços de soluções [McKnight, 2017]; a Otimização Multiobjetivo (OMO), que equilibra critérios conflitantes como leveza, resistência e estética [Reynoso-Meza et al., 2016]; e a Otimização Topológica (OT), que otimiza a distribuição de materiais em um contorno geométrico predefinido [Zargham et al., 2016].

Este estudo concentra-se na integração entre DG e OMO aplicada ao design de quadros de bicicleta, considerando a Otimização Topológica (OT) como referência conceitual para comparação de diferenças e sinergias. O escopo delimita-se ao uso de ferramentas CAD paramétricas, como Rhinoceros 3D e o plugin Grasshopper, priorizando a geração de geometrias otimizadas nas fases iniciais do projeto, sem envolver prototipagem física.

O problema abordado reside na dependência excessiva da intuição e experiência humana nos métodos tradicionais, o que torna o processo lento, limita a exploração de soluções inovadoras e resulta em designs subótimos em termos de uso de materiais, peso e apelo visual. Essa limitação inibe avanços no desenvolvimento de produtos.

O objetivo principal desta pesquisa é desenvolver técnicas de Otimização Multiobjetivo (OMO) para aprimorar o design generativo de quadros de bicicleta, integrando um modelo paramétrico com critérios estéticos e estruturais, visando leveza, desempenho e inovação. Dessa forma, pretende-se contribuir para a modernização das práticas de projeto e ampliar as possibilidades criativas no design de produtos, buscando:

Desvincular o design das restrições da intuição humana, conectando tecnologia e criatividade, e desafiar paradigmas tradicionais de design por meio do poder de ferramentas de otimização computacional.

A metodologia adotada segue o procedimento MODP (*Multiobjective Optimization Design Procedure*), com modelagem paramétrica no Grasshopper, otimização via plug-in Octopus utilizando o algoritmo SPEA-2, e avaliação estética baseada na proporção áurea [Suppapitnarm et al., 2004] e implementada em Python.

Este artigo está dividido em seis seções principais. A primeira seção contextualiza o tema geral do design computacional, descreve o problema abordado e apresenta o objetivo da pesquisa. A segunda detalha os objetivos específicos. A terceira traz o referencial teórico, discutindo conceitos de DG, OT e OMO, incluindo diferenças entre as abordagens. A quarta apresenta uma análise comparativa de ferramentas CAD, destacando a adequação de Rhinoceros e Grasshopper ao MODP. A quinta descreve a metodologia aplicada ao design generativo de quadros de bicicleta, com etapas do Problema de Otimização Multiobjetivo (POM), MOD (*Multiobjective Optimization Design*) e Tomada de Decisão Multicritério (Multi-criteria Decision Making - MCDM), incluindo parâmetros de design e funções de custo. A sexta discute os resultados obtidos, enfatizando a eficácia da integração proposta e suas implicações para o design de produtos.

2. Referencial Teórico

Esta seção apresenta os conceitos centrais da pesquisa, abordando o DG, a OMO e a OT, destacando suas origens na natureza e suas aplicações no design paramétrico com o apoio de softwares CAD.

2.1. Design Generativo, Otimização Topológica e suas Diferenças

O DG é uma abordagem computacional inspirada na eficiência e complexidade das soluções naturais [McKnight, 2017]. O DG utiliza o poder computacional para explorar vastos espaços de design, considerando simultaneamente múltiplos objetivos, como funcionalidade, estética e viabilidade econômica [Rohrmann e Vilgertshofer, 2019]. Por meio da simulação de processos evolutivos, o DG gera uma variedade de soluções, superando as limitações da intuição humana e permitindo a otimização de diversos critérios [McKnight, 2017].

A OT, por outro lado, busca a melhor distribuição de material dentro de um espaço de projeto predefinido, com o objetivo de otimizar o desempenho estrutural sob restrições específicas [Bendsøe e Kikuchi, 1988]. A OT explora várias configurações de material visando maximizar a rigidez ou resistência, ou minimizar o peso estrutural, resultando em soluções inovadoras de design [Bialkowski, 2017; Zargham et al., 2016].

Um modelo matemático comum na OT envolve a minimização simultânea da conformidade estrutural e da distância em relação a um design de referência, conforme demonstrado por [Jang et al., 2022], apresentado na Fórmula .

$$\begin{aligned} \min \quad & f(x) = U^T K(x) U + \lambda \|x_r - x\|_1 \\ \text{s.t.} \quad & \frac{V(x)}{V_0} = R \\ & 0 \leq x_e \leq 1, e = 1, \dots, N_e \end{aligned} \tag{1}$$

onde U é o vetor de deslocamentos, $K(x)$ a matriz de rigidez dependente da densidade x , e λ um parâmetro que controla o peso entre desempenho e fidelidade ao design alvo.

A principal distinção entre DG e OT reside no objetivo final de cada abordagem. Enquanto o DG busca gerar uma ampla variedade de alternativas viáveis, favorecendo a exploração do espaço de soluções [Oh et al., 2019], a OT concentra-se na obtenção de uma única solução ideal para um conjunto específico de restrições e objetivos. Além disso, a OT tende a priorizar a minimização de massa, enquanto o DG pode considerar diferentes quantidades de material ao longo da exploração [Jang et al., 2022].

Essa diferenciação nem sempre é claramente refletida em softwares CAD comerciais. Alguns sistemas, como o Fusion 360, frequentemente rotulam erroneamente processos de OT como sendo de DG, possivelmente por motivos de marketing. Estudos recentes em design de quadros de roda ilustram bem essa distinção [Jang et al., 2022; Oh et al., 2019]: o DG é utilizado para gerar múltiplas alternativas a partir de parâmetros iniciais, enquanto a OT é aplicada para otimizar a estrutura de uma única solução para diferentes condições de contorno [Jang et al., 2022; Oh et al., 2019].


2.2. Otimização Multiobjetivo

A OMO aborda problemas com múltiplos objetivos conflitantes, gerando soluções Pareto-ótimas que compõem a Frente de Pareto, representando os melhores *trade-offs* [Reynoso-Meza, 2014]. Problemas reais demandam equilibrar objetivos diversos, como lucro e sustentabilidade [Emmerich e Deutz, 2018].

A OMO busca soluções em um espaço de decisão, avaliadas por funções objetivo, visando atender preferências e otimizar múltiplos aspectos [Emmerich e Deutz, 2018]. A Fórmula 2 define o problema, incluindo vetor de decisão, funções objetivo e restrições [Reynoso-Meza et al., 2016]. A dominância de Pareto compara soluções, com as não dominadas formando a Frente de Pareto (Figura 1) [Reynoso-Meza et al., 2016].

$$\begin{aligned} &\text{Minimize } J(x) = [J_1(x), \dots, J_m(x)] \\ &\text{subject to } K(x) \leq 0 \text{ and } L(x) = 0, \\ &\text{where } x = [x_1, x_2, \dots, x_n] \end{aligned} \quad (2)$$

Figura 1



Fonte: Reynoso-Meza, Gilberto and Sanchis, 2016.

3. O Metodologia para Design Generativo com o Procedimento de Otimização Multiobjetivo

O procedimento de Otimização Multiobjetivo (*Multiobjective Optimization Design Procedure* - MODP), baseado em [Reynoso-Meza, 2014], oferece uma abordagem estruturada para problemas complexos com múltiplos objetivos, integrando diferentes perspectivas no processo de design. O MODP possui três etapas: medição, busca e tomada de decisão. Na medição, os objetivos são definidos e quantificados; na busca, um Problema de Otimização Multiobjetivo (POM) explora soluções ótimas na Frente de Pareto com algoritmos avançados, utilizando o plugin Octopus no Grasshopper para integrar restrições; por fim, a Tomada de Decisão Multicritério (MCDM) seleciona a solução ideal com base em preferências, apoiada por visualizações 2D e 3D no Octopus (Rhinoceros), considerando trade-offs.

3.1. Etapa 1 - POM

O processo de design inicia com a definição do conceito, detalhando a formulação do Problema de Otimização Multiobjetivo (POM) aplicado ao design do quadro de bicicleta. Para isso, é utilizada a função de custo resultante, que integra múltiplos objetivos conflitantes em um único framework de otimização, visando, portanto, a minimização do comprimento total dos tubos (f_1), a maximização de espaço livre interno (representado pela função f_2) e o aprimoramento da qualidade estética (f_3).

A minimização do comprimento total dos tubos $f_1(x)$ visa reduzir o uso geral de material, somando o comprimento de todos os tubos, o que contribui para a eficiência de custos na fabricação.

A maximização de espaço livre interno (ou minimização de sua função inversa) $f_2(x)$ tem como objetivo aumentar a abertura e a leveza percebida do quadro. Essa estratégia contribui para múltiplos fatores de design, cuja relevância varia de acordo com a finalidade do projeto, abrangendo a eficiência no uso de material, a facilidade de fabricação e manutenção e o aprimoramento da qualidade estética final.

A minimização da medida estética $f_3(x)$ quantifica a proximidade das proporções entre os componentes-chave do quadro com a proporção áurea. Essa função gera diversidade no design generativo. Para eliminar a subjetividade, utiliza-se uma fórmula baseada em [Suppakitnarm et al., 2004], que calcula um modelo estético usando sistemas de proporção da razão áurea (Fórmula 3), comparando as proporções visuais dos membros (Figura 2) com a abordagem de [Stiny e Gips, 1978]. Essa fórmula, implementada em Python e integrada ao Grasshopper, fornece uma medida estética A , onde valores mais altos indicam menor estética:

$$A = (2 \sum_{i=1}^n \sum_{j=i+1}^n \min |r_{ij} - G^m|) / (n(n-1)) \quad (2)$$


onde r_{ij} é a razão de comprimento dos membros i e j , G é a razão áurea (1,618), n é o número total de membros e m é o expoente inteiro G^m que torna mais próximo de r_{ij} .

A função de custo geral para o quadro de bicicleta é o vetor objetivo:

$$F(x) = [f_1(x), f_2(x), f_3(x)]$$

onde $f_1(x)$ é o comprimento total dos tubos (minimizar), $f_2(x)$ representa a maximização de espaço livre interno e $f_3(x)$ é a medida estética (minimizar).

Figura 2: Comprimentos dos membros em proporções áureas (razão = 1.618)



Fonte: O Autor, 2025.

Cada parâmetro de design do quadro de bicicleta constitui uma variável dentro do vetor de decisão X . Esses parâmetros foram categorizados da seguinte forma, com seus respectivos intervalos de variação:

[illegible]

Figura 4: Nomes e Posição dos Tubos da Bicicleta

**Seat Post:**

- Altura (x_1): Variando de 20 mm a 200 mm.
- Ângulo (x_2): Variando de 0° a 360° .

- Altura (x_3): Variando de 200 mm a 300 mm.
- Ângulo (x_4): Variando de 45° a 80°.

Seat Stay:

- Distância entre Tubos (x_5): Variando de 80 mm a 140 mm.
- Comprimento (x_6): Variando de 200 mm a 400 mm.
- Ângulo (x_7): Variando de -15° a $+15^\circ$.

Top and Down Tubes:

- Comprimento (x_8, x_9): Variando de 240 mm a 380 mm.
- Ângulo (x_{10}, x_{11}): Variando de 0° a 45° .

Head Tube:

- Altura (x_{13}): Variando de 50 mm a 400 mm.
- Ângulo (x_{12}): Variando de 0° a 360° .

Headset:

- Distância (x_{14}): Variando de 100 mm a 200 mm.
- Ângulo (x_{15}): Variando de 0° a 360° .

3.2. Etapa 2 – MOOD

A otimização, componente central do MOOD (Multi-Objective Optimization Design), emprega algoritmos para explorar o espaço de design, avaliando variações em relação a objetivos e restrições, refinando iterativamente os parâmetros para identificar soluções ótimas.

Neste estudo, a otimização foi realizada com o Octopus, um plug-in de OMO para Grasshopper desenvolvido por [Vierlinger, 2013]. O Octopus conecta-se diretamente aos parâmetros do modelo paramétrico do Grasshopper, retroalimentando resultados e permitindo configurar algoritmos evolutivos para otimizar os objetivos. O algoritmo SPEA-2 foi adotado por seu desempenho estabelecido na convergência eficiente para a Frente de Pareto em cenários de otimização multiobjetivo.


3.3. Etapa 3 – MCDM

A Tomada de Decisão Multicritério (Multi-criteria Decision Making - MCDM) permite aos designers avaliar sistematicamente os objetivos conflitantes e encontrar soluções ótimas que os equilibrem efetivamente. A etapa inicial crucial é gerar a Frente de Pareto (JP*), um conjunto de designs que representa os melhores *trade-offs* possíveis entre esses objetivos.

Obtida a Frente de Pareto (JP*), o designer (Tomador de Decisão – TD) utiliza ferramentas de visualização para analisar os *trade-offs* entre os objetivos, facilitando a comparação intuitiva dos designs e a tomada de decisão.

A ferramenta de visualização Octopus foi utilizada para exibir a Frente de Pareto para o problema de design do quadro de bicicleta (Figura 5). O Octopus apresenta um conjunto de quadrados coloridos, cada um representando uma iteração de design distinta. As cores desses quadrados correspondem à proximidade das soluções de design à Frente de Pareto. Especificamente, quadrados vermelhos indicam os designs mais próximos da Frente de Pareto, marcando-os como soluções ótimas de acordo com o modelo e os objetivos atuais.

Figura 5: Visualização da Frente de Pareto pelo Octopus




Fonte: O Autor, 2025

Esse sistema codificado por cores fornece um método intuitivo e amigável para o TD avaliar quais designs oferecem os melhores *trade-offs*. Ao selecionar um quadrado, o TD pode visualizar instantaneamente o design correspondente na interface do Rhino. Essa capacidade permite uma exploração contínua do espaço de design e facilita o processo de tomada de decisão, tornando fácil comparar visualmente as diversas soluções. As ferramentas permitiram ao TD identificar e comparar rapidamente designs ótimos, explorar minuciosamente o espaço de design e tomar decisões com base em uma compreensão clara dos *trade-offs* envolvidos.

4 – Resultados


O resultado das diversas soluções possíveis é apresentado nas Figuras 6, onde foi selecionado um design com maior minimização de comprimento dos tubos; Figura 7, onde ilustra um design com maior eficiência de abertura interna; Figura 8, onde mostra um design com a maior otimização da métrica de proporção estética; e por fim, a Figura 9 apresenta um design que foi localizado mais próximo ao centro da Frente de Pareto, onde tem um maior equilíbrio entre os três aspectos do estudo.

Figura 6: Maior minimização de comprimento dos tubos




Fonte: O Autor, 2025.

Figura 7: Maior eficiência de abertura interna




Fonte: O Autor, 2025.

Figura 8: Maior otimização da métrica de proporção estética



Fonte: O Autor, 2025.

Figura 9: Mais próximo ao centro da Frente de Pareto



Fonte: O Autor, 2025.

5 – Conclusão

Este estudo abordou a aplicação da engenharia de design computacional na geração de quadros de bicicletas, com o objetivo de superar as limitações da intuição humana nos métodos tradicionais e criar designs otimizados em desempenho e estética. Para isso, foi desenvolvida uma metodologia que integra o Design Generativo (DG) com a Otimização Multiobjetivo (OMO), utilizando o ambiente Rhinoceros 3D, Grasshopper e o motor Octopus. Os resultados demonstraram a eficácia da metodologia ao gerar um vasto espaço de soluções e identificar soluções Pareto-Ótimas que equilibram os objetivos conflitantes, facilitando a tomada de decisão do projetista por meio de visualização intuitiva. O trabalho contribui para o campo ao incorporar métricas estéticas objetivas e flexíveis no processo de otimização. Contudo, a pesquisa tem como limitação a dependência da criação de um modelo paramétrico inicial ("modelo zero") como ponto de partida para a geração das soluções otimizadas.

Referências

- Akin, J. E. (2010). Finite element analysis concepts: via SolidWorks. World Scientific.
- Autodesk (2024). Cad. URL <https://www.autodesk.com/br/products/3ds-max/free-trial>.
- Bendsøe, M. P. e Kikuchi, N. (1988). Generating optimal topologies in structural design using a homogenization method. *Computer methods in applied mechanics and engineering*, 71(2): 197–224.
- Bialkowski, S. (2017). topos: Gpgpu accelerated structural optimisation utility for architects. In *Proceedings of the 35th International Conference on Education and Research in Computer Aided Architectural Design in Europe, Rome, Italy*, p. 20–22.
- Dubovska, R., Jambor, J., e Majerik, J. (2014). Implementation of cad/cam system catia v5 in simulation of cnc machining process. *Procedia Engineering*, 69:638–645.
- Emmerich, M. T. e Deutz, A. H. (2018). A tutorial on multiobjective optimization: fundamentals and evolutionary methods. *Natural computing*, 17:585–609.
- Jang, S., Yoo, S., e Kang, N. (2022). Generative design by reinforcement learning: enhancing the diversity of topology optimization designs. *Computer-Aided Design*, 146:103225.
- Lee, K. S. e Song, H. K. (2021). Automation of 3d average human body shape modeling using rhino and grasshopper algorithm. *Fashion and Textiles*, 8:1–20.
- McKnight, M. (2017). Generative design: What it is? how is it being used? why it's a game changer. *KnE Engineering*, p. 176–181.
- Oh, S., Jung, Y., Kim, S., Lee, I., e Kang, N. (2019). Deep generative design: Integration of topology optimization and generative models. *Journal of Mechanical Design*, 141(11):111405.
- Reynoso Meza, G. (2014). Controller tuning by means of evolutionary multiobjective optimization: a holistic multiobjective optimization design procedure. Tese de Doutorado (PhD thesis), Editorial Universitat Politècnica de València.
- Reynoso-Meza, G., Sanchis, J., Blasco, X., e Martínez, M. (2016). Preference driven multiobjective optimization design procedure for industrial controller tuning. *Information Sciences*, 339:108–131.
- Rohrmann, J. e Vilgertshofer, S. (2019). Design optimization in early project stages a generative design approach to project development. no. September. <https://publications.cms.bgu.tum.de/theses/2019RohrmannVilgertshofer.pdf>.
- Stiny, G. e Gips, J. (1978). Algorithmic aesthetics: computer models for criticism and design in the arts. Univ of California Press.
- Suppakitnarm, A., Parks, G., Shea, K., e Clarkson, P. (2004). Conceptual design of bicycle frames by multiobjective shape annealing. *Engineering Optimization*, 36(2):165–188.
- Vierlinger, R. (2013). Multi objective design interface. University of Applied Arts Vienna.
- Willis, K. D., Pu, Y., Luo, J., Chu, H., Du, T., Lambourne, J. G., Solar-Lezama, A., e Matusik, W. (2021). Fusion 360 gallery: A dataset and environment for programmatic

cad construction from human design sequences. *ACM Transactions on Graphics (TOG)*, 40(4):1–24.

Zargham, S., Ward, T. A., Ramli, R., e Badruddin, I. A. (2016). Topology optimization: a review for structural designs under vibration problems. *Structural and Multidisciplinary Optimization*, 53:1157–1177.