

Parametric environment for internalization and classification of models generated by the Shap-E tool

Cristian Vinicius Machado Fagundes¹, Léia Miotto Bruscato², Angelica Paiva Ponzio³, Sara Regiane Chornobai⁴

^{1,2,3,4} Federal University of Rio Grande do Sul, Porto Alegre, Brazil

¹fagundes@prof.ufn.edu.br; ²arq.leiab@gmail.com; ³angelica.ponzio@gmail.com;

⁴sararchornobai@gmail.com

Abstract. Computing has been increasingly employed in design environments, primarily to perform calculations and logical decisions faster than humans could, enabling tasks that would be impossible or too time-consuming to execute manually. Various studies highlight the use of digital tools and technologies in diverse methods, such as parametric modeling and evolutionary algorithms, for exploring and optimizing alternatives in architecture, design, and engineering (Martino, 2015; Fagundes, 2019). Currently, there is a growing emergence of intelligent models that increasingly integrate computers into the design process. Demonstrating great potential for initial ideation, artificial intelligence (AI) models like Shap-E (Nichol et al., 2023) by OpenAI stand out. Although this model falls short of state-of-the-art sample quality, it is among the most efficient orders of magnitude for generating three-dimensional models through AI interfaces, offering practical balance for certain use cases. Thus, aiming to explore this gap, the presented study proposes an innovative design agency framework by employing Shap-E connected with parametric modeling in the design process. The generation tool has shown promising results; through generations of synthetic views conditioned by text captions, its final output is a mesh. However, due to the lack of topological information in models generated by Shap-E, we propose to fill this gap by transferring data to a parametric three-dimensional surface modeling environment. Consequently, this interaction's use aims to enable the transformation of the mesh into quantifiable surfaces, subject to collection and optimization of dimensional data of objects. Moreover, this work seeks to enable the creation of artificial databases through formal categorization of parameterized outputs using the K-means algorithm. For this purpose, the study methodologically orients itself in a four-step exploratory experimental process: (1) creation of models generated by Shap-E in a pressing manner; (2) use of parametric modeling to internalize models into the Grasshopper environment; (3) generation of optimized alternatives using the evolutionary algorithm (Biomorpher); (4) and classification of models using the K-means algorithm. Thus, the presented study proposes, through an environment of internalization and classification of models generated by the Shap-E tool, to contribute to the construction of a new design agency methodology in the decision-making process of design. So far, this research has resulted in the generation and classification of a diverse set of three-dimensional shapes. These shapes are grouped for potential applications in machine learning, in addition to providing insights for the refinement and detailed exploration of forms.

Keywords: Shap-E; Parametric Design; Evolutionary Algorithm; Synthetic Database; Artificial Intelligence

1 Introdução

A computação tem revolucionado a forma de abordagem da criação e o desenvolvimento de projetos em diversas áreas (Aranburu et al. 2023; Luis et al, 2023). Nos ambientes de projetação em arquitetura, design e engenharia, sua presença se torna cada vez mais predominante, impulsionada pela capacidade de realizar cálculos complexos e tomar decisões lógicas em velocidades inimagináveis em relação à inteligência humana (Cristie & Joyce 2021, Lee, et al. 2023). O emprego de ferramentas e tecnologias digitais, como a modelagem paramétrica e algoritmos evolutivos, por exemplo, vêm enriquecendo significativamente a exploração e otimização de alternativas na arquitetura, design e engenharia (Martino, 2015; Fagundes, 2019).

Em consonância com essa evolução, verifica-se o surgimento de novos modelos inteligentes, alavancados pela inteligência artificial (IA), que podem redefinir o cenário projetual (Nichol et al., 2022; Luis, et al, 2023). Dentre eles, destacam-se o Dall-E (Ramesh et al. 2022) e o *Shap-E* (Jun, Nichol, 2023), ambos desenvolvidos pela OpenAI. O Dall-E, por meio da IA, é capaz de gerar imagens bidimensionais (2D) a partir de descrições textuais, proporcionando uma ampla gama de possibilidades criativas. Já o *Shap-E* (Jun, Nichol, 2023), também ancorado na IA, opera por meio da geração de modelos tridimensionais (3D), culminando na produção de malhas tridimensionais (*meshes*) a partir de *text captions*. Embora o *Shap-E* demonstre um amplo potencial, nota-se uma lacuna em sua aplicação: a falta de informações topológicas dos modelos gerados, o que dificulta sua utilização em contextos projetuais na arquitetura, design ou engenharia. Nesse âmbito, visando preencher essa lacuna e explorar o potencial dessa interação entre IA voltada a modelagem paramétrica, propor-se aqui uma estrutura inovadora de design agency (Guida, 2023), onde a modelagem paramétrica é conectada ao *Shap-E*.

Portanto, para atingir os objetivos, a proposta deste estudo experimental divide-se em quatro etapas: (1) criação de modelos tridimensionais (*meshes*) gerados no *Shap-E*; (2) utilização da modelagem paramétrica para internalização dos modelos no ambiente Grasshopper; (3) geração de alternativas otimizadas com o uso do algoritmo evolutivo *Biomorpher*; (4) e classificação dos modelos por meio do algoritmo *k-means*. Deste modo, irá se demonstrar como esta abordagem inovadora possibilita a transformação dos modelos *mesh* em superfícies topologicamente quantificáveis, tornando-as aptas para coleta e otimização de dados dimensionais dos objetos. Além disso, almeja-se uma construção de bancos de dados artificiais através da categorização formal dos *outputs* parametrizados, abrindo novas perspectivas para a tomada de decisão no processo projetual. O presente estudo viabiliza a internalização dos modelos gerados por IA, em elementos quantificáveis, passível de otimização; dessa maneira, além de contribuir para a integração da AI no processo projetual criativo, corrobora com o uso destas tecnologias no campo expandido da arquitetura e design.

2 Metodologia

Nesta seção, apresenta-se o processo (Figura 1) metodológico da proposta para a exploração da interação entre o modelo geração *Shap-E* e o ambiente de modelagem paramétrica, bem como a organização para a otimização e classificação dos modelos tridimensionais.

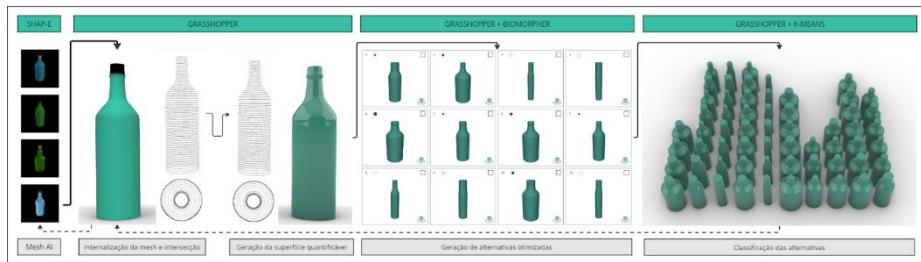


Figura 1. Processo de geração, internalização e classificação dos modelos obtidos.
Fonte: Os autores, 2023.

As principais etapas do estudo são detalhados abaixo:

2.1 Criação de modelos gerados no *Shape-E*

A primeira etapa deu-se pela geração de modelos tridimensionais utilizando o modelo de IA *Shap-E* (Jun, Nichol, 2023). Deste modo, foi criado um *notebook* virtual utilizando o *Google Colab* para importar o repositório do código-fonte da *Open AI*, disponibilizado em: "<https://github.com/openai/shap-e>". Após a criação do ambiente virtual, foram definidos os parâmetros textuais para a geração do modelo tridimensional. Para facilitar a importação do modelo no ambiente paramétrico, o *prompt* utilizado foi: "*a bottle*". A escolha deu-se pelo baixo nível de detalhe de uma garrafa, em conjunto às futuras possibilidades formais atreladas a sua geometria primitiva. Com isso, foi selecionado um dos modelos gerados em *mesh* como base para o processo de parametrização.

2.2 Utilização da modelagem paramétrica para internalização do modelo no ambiente Grasshopper

Na segunda etapa, o modelo gerado pelo *Shap-E* foi internalizado no ambiente de modelagem paramétrica *Grasshopper*. A internalização permitiu uma manipulação mais detalhada do modelo em *mesh* gerado anteriormente, possibilitando a representação em superfícies quantificáveis.

Para permitir a modificação dos detalhes no algoritmo evolutivo, foi fundamental transformar a *mesh* em superfícies sólidas. Isso possibilitou a

definição de parâmetros específicos (como dimensões, diâmetros, conjunto de curvas, etc.) que podem ser manipulados durante a otimização. As superfícies sólidas são mais adequadas para a aplicação de operações paramétricas e algoritmos evolutivos, uma vez que essas operações requerem estruturas geométricas bem definidas.

Para realizar esse processo, foi aplicado o componente "perp frames" a fim de criar um conjunto de 50 planos perpendiculares à superfície base da *mesh*. Os planos foram divididos equidistantemente na linha central do eixo vertical da garrafa, ou seja, em sua altura total. Em seguida, utilizou-se o componente "mesh plane" para gerar a interseção entre a *mesh* e os planos criados pelo "perp frames". Essa interseção resultou em uma série de curvas que representam as seções transversais dos modelos em cada ponto do eixo vertical do modelo tridimensional. Essas curvas foram fundamentais para obter as informações topológicas do modelo (Figura 2).

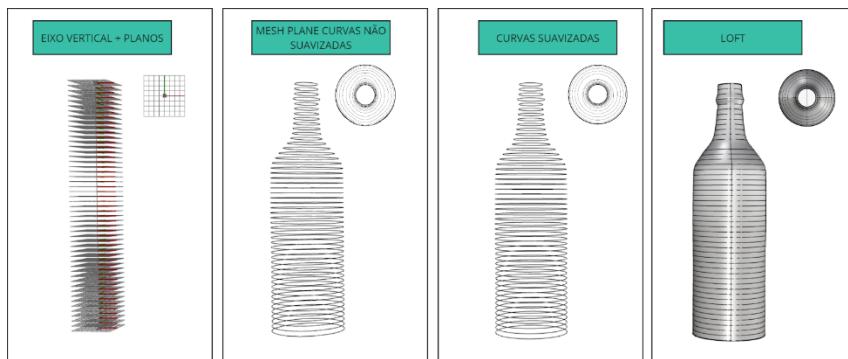


Figura 2. Processo de obtenção e manipulação das curvas. Fonte: Os autores, 2023.

A conversão possibilitou uma abordagem mais precisa na análise e no estudo das características dos modelos, tornando-os mais acessíveis para análise e otimização do processo.

2.3 Geração de alternativas otimizadas com o uso do algoritmo evolutivo *Biomorpher*

Os modelos parametrizados serviram como ponto de partida para a aplicação do algoritmo evolutivo do plugin *Biomorpher*. Para isso, foram configurados os parâmetros de restrição no *input* do componente com base no remapeamento do valor dos diâmetros de cada circunferência. Estes valores foram dispostos para a criação de um intervalo entre os diâmetros mínimos e máximos das possíveis variações formais. Também foram conectados os valores de volume de cada modelo tridimensional com a finalidade de possibilitar uma classificação e otimização mais precisa.

No segundo momento, os parâmetros do componente *Biomorpher* foram organizados com o seu *default* de configuração de 48 alternativas distribuídas em 12 grupos por similaridade formal. Tais parâmetros serviram como operadores de diversidade para a exploração e otimização de soluções. O primeiro parâmetro “crossover rate” com valor de 0.1, foi utilizado para gerar uma variação entre os “parentescos”, ou seja, possíveis variações entre as soluções. O segundo parâmetro “mutation rate” com valor de 0.01, teve como objetivo o acréscimo de uma “diversidade genética” da população por meio da inserção de novos cromossomos (características) nos indivíduos.

Com os parâmetros definidos, o *Biomorpher* gerou um conjunto de alternativas aleatórias, explorando diferentes combinações e variações dos modelos iniciais. Essas alternativas representam soluções com características distintas em relação ao modelo original.

Embora o *Biomorpher* agrupe as alternativas, é importante mencionar que a capacidade de salvar os dados iniciais, como valores de volume para esses grupos, requer uma abordagem adicional. Nesse sentido, a integração da metodologia de classificação dos modelos com o algoritmo *k-means*, em conjunto com o recurso de gravação “record” do ambiente *Grasshopper*, desempenhou um papel crucial. Essa abordagem permitiu a categorização sistemática das alternativas em grupos semelhantes, considerando não apenas suas características formais, mas também atributos como o volume e dimensões topológicas dos modelos.

2.4 Classificação dos modelos com o algoritmo *k-means*

A última etapa consistiu na classificação dos modelos com a utilização do algoritmo *k-means* do plugin *Lunchbox*. Esse processo possibilitou a categorização formal dos modelos parametrizados, além de contribuir também, para uma possível formação de bancos de dados artificiais.

O *k-means* é um algoritmo de aprendizado não supervisionado usado para agrupar dados em clusters. Sua finalidade é encontrar a estrutura subjacente dos dados, dividindo elementos semelhantes em grupos e atribuindo-lhes uma “etiqueta”.

Para a aplicação deste processo, foram configurados os parâmetros do algoritmo. Isso incluiu definir o número de clusters (Figura 4) que se desejava criar e conectar os elementos previamente treinados (resultados gerados anteriormente com o algoritmo evolutivo) ao componente na *input* do componente.

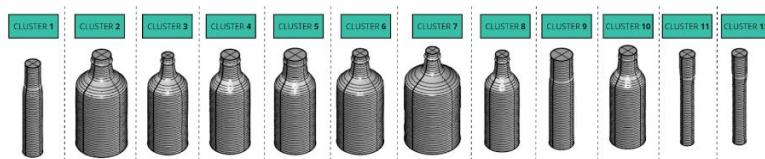


Figura 4. Divisão das alternativas pelo algoritmo *k-means*. Fonte: Os autores, 2023.

O algoritmo *k-means* realizou as etapas de divisão e classificação para encontrar os agrupamentos.

Após a execução, foi utilizado o comando “*data recorder*” do *Grasshopper*. O “*data recorder*” é um componente que permite gravar e armazenar dados de entrada e saída durante a execução do algoritmo. Deste modo, o comando foi aplicado para capturar informações detalhadas sobre cada alternativa, incluindo características de volume e dimensões formais. Após a conclusão do algoritmo *k-means*, os dados gerados foram organizados nos 12 grupos distintos, cada um representando um conjunto de alternativas (*brep*) com características similares.

3 Resultados

Nesta seção, apresenta-se os resultados obtidos a partir da metodologia proposta para a exploração da interação entre modelos de inteligência artificial (IA) e a modelagem paramétrica no processo projetual. As principais etapas do estudo são detalhados abaixo:

3.1 Geração dos modelos

O resultado dessa etapa foram 4 representações dos modelos IA na forma de *mesh*, no tempo total de 1 minuto e 41 segundos. Os modelos tridimensionais gerados utilizando o modelo de *Shap-E* apresentaram resultados com poucos níveis de detalhes, mas com uma forma aceitável para a internalização no *Grasshopper*. As descrições textuais de entrada fornecidas foram adequadamente interpretadas para modelos de baixa complexidade, resultando em uma *mesh* que retratava minimamente as características e propriedades conforme especificado.

Entretanto, é relevante reconhecer que os modelos resultantes da aplicação do *Shap-E*, embora promissores, podem ser caracterizados por uma simplicidade inerente, especialmente quando comparados a designs complexos. Porém, a simplificação formal facilitou a importação para o ambiente do *Grasshopper*, de modo que os modelos mais simples tenderam a ser mais facilmente adaptáveis para internalização, visto que a complexidade reduzida pode resultar em um processo de importação mais direto e com menos complicações.

3.2 Geração de alternativas otimizadas com o algoritmo evolutivo

O algoritmo evolutivo operou de forma iterativa, promovendo a combinação e a mutação dos indivíduos. Neste processo, ao total, foram realizadas 9 gerações, totalizando um conjunto de 432 formas (48 indivíduos por cada

geração) separados em 12 grupos (Figura 5) organizados pelo critério dos valores de volume.

A aplicação do algoritmo evolutivo *Biomorpher* resultou em um conjunto diversificado de alternativas. As iterações realizadas pelo *Biomorpher* exploraram o espaço de soluções, fornecendo possibilidade formais atreladas aos limites volumétricos estabelecidos. Essa etapa evidenciou a capacidade do *Biomorpher* em ampliar as alternativas geradas pelo *Shap-E*, contribuindo para o processo criativo.

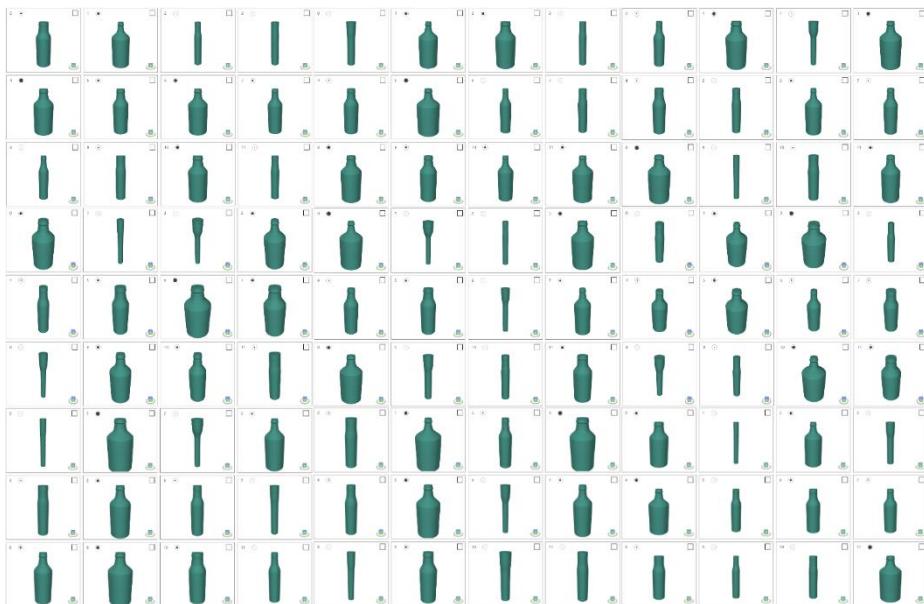


Figura 5. Resultado das alternativas geradas pelo *Biomorpher*. Fonte: Os autores, 2023.

Além da busca de explorações formais, uma das metas foi criar um banco de dados artificiais contendo as alternativas geradas. Esse banco de dados foi categorizado com informações sobre as diferentes soluções, representadas por seus respectivos conjuntos formais e valores paramétricos.

Classificação dos modelos com o algoritmo *k-means*

A categorização dos modelos (Figura 6) proporcionou uma organização mais clara e estruturada das alternativas em relação ao processo do *Biomorpher*, facilitando a visualização e a análise das diferentes variações de design e suas relações entre si. É importante destacar que a classificação em grupos não apenas oferece uma visão mais clara das variações formais presentes nas alternativas, mas também estabelece uma estrutura para futuras análises e tomadas de decisões por meio de um histórico de soluções.

Outro aspecto relevante a ser considerado é a possibilidade de transformar os modelos tridimensionais em *mesh*, o que abre caminho para a criação de

uma base sintética de dados. Essa base de dados artificiais, composta por alternativas geradas e organizadas de forma sistemática, pode ser utilizada para treinar e aprimorar modelos de reconhecimento. Por exemplo, o desenvolvimento de um modelo de aprendizado de máquina capaz de reconhecer objetos com base em suas características visuais e geométricas. Essa abordagem oferece um potencial significativo para além do processo de design inicial.



Figura 6. Classificação das alternativas pelo algoritmo k-means. Fonte: Os autores, 2023.

A classificação das alternativas em grupos distintos não apenas facilita a análise comparativa, mas também fornece insights para a seleção de soluções adequadas. Ao considerar o exemplo da garrafa que deu origem a possíveis formas cilíndricas, como uma lanterna por exemplo, pode-se explorar essa abordagem como um estímulo à descoberta de novas direções criativas que podem não ter sido inicialmente consideradas.

Entretanto, é essencial destacar as limitações intrínsecas neste método de classificação, onde a geração atual se restringe a criar uma única volumetria por vez, o que pode limitar a diversidade do espectro de resultados. Além disso, a falta de controle direto sobre as características detalhadas de cada geração pode restringir a aplicabilidade do método a projetos que requerem formas altamente específicas e detalhadas.

4 Discussão

Os resultados obtidos demonstram o potencial da integração entre modelos de inteligência artificial e a modelagem paramétrica como uma abordagem inovadora no processo projetual. A combinação do modelo *Shap-E* e da modelagem paramétrica permitiu a geração rápida e criativa de modelos tridimensionais, oferecendo uma diversidade de alternativas otimizadas formalmente para análise e avaliação.

As etapas da metodologia possibilitaram uma abertura significativa na exploração de soluções de design, fornecendo um subsídio para a tomada de decisão na fase inicial do projeto.

Apesar dos resultados positivos, é importante reconhecer as limitações do estudo. O modelo *Shap-E* ainda está em desenvolvimento, e a qualidade das amostras geradas pode ser aprimorada. Além disso, é necessário avaliar a confiabilidade e robustez da integração proposta em projetos de maior escala e complexidade.

Uma observação crucial a ser feita é que a transformação de modelos complexos e altamente detalhados, como aqueles com ornamentos e recortes, em uma representação quantificável pode ser um desafio. Embora possuam um alto nível de detalhes, podem resultar em geometrias irregulares após a conversão para uma superfície sólida. Isso pode dificultar a posterior manipulação paramétrica e otimização algorítmica.

Outro ponto importante a considerar é a necessidade de transformar as *meshes* geradas pelo *Shap-E* em superfícies sólidas no *Grasshopper*. Essa transformação é essencial para permitir a aplicação de operações paramétricas e algoritmos evolutivos, pois superfícies sólidas fornecem uma estrutura geométrica mais definida e apropriada para a definição de parâmetros modificáveis. Isso se torna especialmente relevante ao pensar na aplicação de um algoritmo evolutivo como o *Biomorpher*, no qual a manipulação precisa dos elementos é fundamental para a geração de alternativas otimizadas.

A classificação das alternativas em grupos e a criação de uma base de dados sintéticos oferecem oportunidades para o treinamento e aprimoramento de algoritmos de reconhecimento, abrindo possibilidades futuras para aplicações de aprendizado de máquina.

Em conclusão, o trabalho apresenta uma abordagem inovadora para a exploração de alternativas de design, combinando inteligência artificial, modelagem paramétrica e algoritmos evolutivos. Embora traga benefícios consideráveis, como uma gama de soluções, ainda enfrenta desafios relacionados à qualidade dos modelos gerados e à complexidade da transformação para superfícies paramétricas. Essas discussões, no entanto, fornecem bases para futuras iterações e aprimoramentos.

Agradecimentos. Gostaríamos de agradecer à UFRGS/DS/CAPES, pelo financiamento parcial desta pesquisa.

Referencias

- Aranburu, Aritz, Jorge D. Camba, Daniel Justel, and Manuel Contero. 2023. “An Improved Explicit Reference Modeling Methodology for Parametric Design.” CAD Computer Aided Design 161: 103541. <https://doi.org/10.1016/j.cad.2023.103541>.
- Cristian Vinicius Machado Fagundes. 2019. “Sistema Generativo Como Ferramenta De Otimização No Processo Exploratório Do Design De Produto.” Faculdade De

Arquitetura Programa De Pós-Graduação em Design. Universidade Federal Do Rio Grande Do Sul. Dissertação (Mestrado), 118.

Cristie, Verina, and Sam Conrad Joyce. 2021. "Versioning for Parametric Design Exploration Process." *Automation in Construction* 129 (June): 103802. <https://doi.org/10.1016/j.autcon.2021.103802>.

Guida, George. 2023. "Multimodal Architecture."

Jun, Heewoo, and Alex Nichol. 2023. "Shap-E: Generating Conditional 3D Implicit Functions." <http://arxiv.org/abs/2305.02463>.

Lee, Hyunoh, Jinwon Lee, Soonjo Kwon, Karthik Ramani, Hyung gun Chi, and Duhwan Mun. 2023. "Simplification of 3D CAD Model in Voxel Form for Mechanical Parts Using Generative Adversarial Networks." *CAD Computer Aided Design* 163: 103577. <https://doi.org/10.1016/j.cad.2023.103577>.

Martino, Jarryer Andrade De. 2015. "Algoritmos Evolutivos Como Método Para Desenvolvimento de Projetos de Arquitetura." Tese (Doutorado), 313.

Nichol, Alex, Heewoo Jun, Prafulla Dhariwal, Pamela Mishkin, and Mark Chen. 2022. "Point-E: A System for Generating 3D Point Clouds from Complex Prompts." <http://arxiv.org/abs/2212.08751>.

Ramesh, Aditya, Prafulla Dhariwal, Alex Nichol, Casey Chu, and Mark Chen. 2022. "Hierarchical Text-Conditional Image Generation with CLIP Latents," no. Figure 3. <http://arxiv.org/abs/2204.06125>.