



ICONOGRAFIA ALGORÍTMICA: ADAPTANDO DONDIS E PANOFSKY PARA ANALISAR REPRESENTAÇÕES DE ARTISTAS EM IMAGENS DE IA GENERATIVA

Algorithmic Iconography: Adapting Dondis and Panofsky to analyze artists' representations in generative AI images

Iconografía algorítmica: adaptación de Dondis y Panofsky para analizar las representaciones de artistas en imágenes de IA generativa

Emerson Blum Corrêa¹
Augusto Araujo Vuitik²
Josie Agatha Parrilha da Silva³
Ygor de Oliveira⁴

Resumo: Este artigo explora um método experimental de Leitura de Imagem de Inteligência Artificial Generativa (LI-IAG) baseado em técnicas de leitura de imagem das Artes Visuais (Dondis e Panofsky), com vista a analisar composições algorítmicas em imagens geradas por IAG. Nesse estudo, utilizamos a LI-IAG para examinar vieses em representações de gênero, trabalho e raça, utilizando como corpus imagens produzidas pelo *Leonardo.AI*. A metodologia, qualitativa e exploratória, se estrutura em três etapas: (1) desenvolvimento do LI-IAG; (2) seleção e construção do corpus; e (3) aplicação do método. Como principal resultado, destacamos a elaboração do LI-IAG, uma ferramenta útil para a análise sistemática de IAGs, capaz de articular aspectos formais e discursivos.

Palavras-chave: Leitura de Imagem. Viés Algorítmico. LeonardoAI. Inteligência Artificial.

Abstract: This article explores an experimental method of Generative Artificial Intelligence Image Reading (GAI-IR) based on image reading techniques from the Visual Arts (Dondis and

¹ Doutorando em Educação para a Ciências e a Matemática. Universidade Estadual de Maringá, Maringá, Paraná, Brasil. E-mail: emerblum@outlook.com; Lattes: <http://lattes.cnpq.br/1997925352000413>; ORCID iD: <https://orcid.org/0000-0003-4483-582X>.

² Doutorando em Engenharia e Ciências de Materiais. Universidade Estadual de Ponta Grossa, Ponta Grossa, Paraná, Brasil. E-mail: augusto.vuitik@outlook.com; Lattes: <http://lattes.cnpq.br/9410912915982721>; ORCID iD: <https://orcid.org/0000-0003-1731-8309>.

³ Doutora em Educação para Ciência. Universidade Estadual de Ponta Grossa, Ponta Grossa, Paraná, Brasil. E-mail: japsilva@uepg.br; Lattes: <http://lattes.cnpq.br/7528954595127003>; ORCID iD: <https://orcid.org/0000-0002-8778-6792>.

⁴ Licenciando em Artes Visuais. Universidade Estadual de Ponta Grossa, Ponta Grossa, Paraná, Brasil. E-mail: 24007087@uepg.br; Lattes: <http://lattes.cnpq.br/6299904861792651>; ORCID iD: <https://orcid.org/0009-0009-1905-1004>.

Panofsky), aiming to analyze algorithmic compositions in GAI-generated images. In this study, we used GAI-IR to examine biases in representations of gender, labour, and race, using images produced by Leonardo.AI as a corpus. The qualitative and exploratory methodology is structured in three stages: (1) development of GAI-IR; (2) selection and construction of the corpus; and (3) application of the method. As a main result, we highlight the development of GAI-IR, a useful tool for systematically analyzing GAIs, capable of articulating formal and discursive aspects.

Keywords: Image Reading. Algorithmic Bias. LeonardoAI. Artificial Intelligence.

Resumen: Este artículo explora un método experimental de Lectura de Imágenes con Inteligencia Artificial Generativa (LI-IAG) basado en técnicas de lectura de imágenes de las Artes Visuales (Dondis y Panofsky), con el objetivo de analizar composiciones algorítmicas en imágenes generadas por IAG. En este estudio, utilizamos LI-IAG para examinar sesgos en las representaciones de género, trabajo y raza, utilizando imágenes producidas por Leonardo.AI como corpus. La metodología cualitativa y exploratoria se estructura en tres etapas: (1) desarrollo de LI-IAG; (2) selección y construcción del corpus; y (3) aplicación del método. Como resultado principal, destacamos el desarrollo de LI-IAG, una herramienta útil para el análisis sistemático de IAG, capaz de articular aspectos formales y discursivos.

Palabras clave: Lectura de Imágenes. Sesgo Algorítmico. LeonardoAI. Inteligencia Artificial.

Introdução

A ascensão das Inteligências Artificiais Generativas (IAGs) tem reconfigurado a produção e a interpretação de imagens na cultura contemporânea. Se, por um lado, essas ferramentas oferecem acesso a algoritmos capazes de gerar imagens em escala industrial, por outro, elas desafiam os métodos tradicionais de leitura de imagem – concebidos para obras de autoria humana definida. Sua emergência transforma os processos de criação visual, expandindo a produção de imagens — antes restrita a atos humanos individualizados — para sistemas técnicos baseados em aprendizado estatístico. Esse cenário complexo nos confronta com a seguinte questão: como decifrar imagens que não emergem de uma subjetividade artística, mas sim de padrões estatísticos processados em bancos de dados massivos?

Partindo desse contexto, este artigo tem como objetivo analisar imagens produzidas por Inteligências Artificiais Generativas (IAGs) a partir de uma adaptação das abordagens de leitura de imagem propostas por Dondis (2015) e Panofsky (2007), testando sua aplicabilidade em um corpus de imagens geradas pelo modelo *Leonardo.AI*. Para isso, utilizamos *prompts* que solicitam a representação de um artista, utilizando os fundamentos dessas metodologias a fim de adequá-los às especificidades das composições algorítmicas. Como recorte analítico, optamos por examinar representações de gênero, trabalho e raça, por se tratar de um campo fértil para investigar os vieses embutidos em modelos de Inteligência Artificial (IA). Não

buscamos esgotar a questão, mas explorá-la a partir de uma perspectiva interdisciplinar, propondo uma reflexão sobre a capacidade humana de leitura de imagem – especialmente em contraste com os avanços significativos na detecção automatizada por máquinas.

Inteligência Artificial Generativa de imagens

A IA pode ser definida como uma tecnologia que reproduz certas habilidades humanas, como percepção, comunicação por linguagem, pensamento lógico, aprendizado, criatividade e solução de desafios (Comest, 2019). Além disso, os sistemas atuais de IA também possuem a capacidade de planejar. O termo também se refere a uma área de estudo multidisciplinar focada no desenvolvimento dessas tecnologias (Vicari *et al.*, 2023). Embora muitas vezes seja associada a um futuro distante e inovador, a IA já é um campo científico estabelecido, com origens que datam dos anos 1940 (Russel; Norvig, 2013). O termo IAG, por sua vez, refere-se a modelos treinados em extensos bancos de dados de imagens, como o LAION-5B, capazes de aprender padrões visuais estatísticos e gerar novas composições a partir de *prompts* textuais.

Diferentemente da computação convencional, que prioriza métodos de cálculo, a IA emprega abordagens simbólicas e estatísticas para interpretar problemas e sugerir soluções com base em padrões de dados. No entanto, como essas soluções não são determinísticas, os resultados produzidos por sistemas de IA sempre carregam um grau de imprecisão (Vicari *et al.*, 2023).


De acordo com Dalalah e Dalalah (2023), atualmente a IA se limita a identificar e apontar padrões e correlações nos conjuntos de dados, sem compreender de fato seu significado ou conteúdo. Em outras palavras, embora sistemas de IA consigam inserir certo nível de contextualização, análise, previsão ou criatividade em seus processamentos, eles ainda não possuem a capacidade de gerar conhecimento de maneira independente.

A área de ética na IA envolve a discussão de fundamentos teóricos, práticos e políticos que regulam a interação entre humanos e máquinas em diversos cenários sociais (Huang *et al.*, 2023). No tocante as IAGs, a capacidade dessa tecnologia de revolucionar e aprimorar a criação de imagens levanta questões relevantes, tais como: autenticidade, direitos autorais, rastreabilidade do uso, vulnerabilidade de dados, confiabilidade dos resultados e impactos no mercado de trabalho. Considerando que a adoção da IA na sociedade é inevitável, é crucial preparar as pessoas para lidar com suas implicações, por isso neste artigo focamos em estratégias para capacitar indivíduos a interpretar imagens geradas por IA.

Entre as diversas tecnologias de IAG, focaremos nos modelos de difusão, que são a base do *Leonardo.AI*. Esses modelos funcionam a partir da correlação entre dados textuais e visuais, gerando imagens a partir de *prompts* em processo baseado em duas etapas: treinamento e geração.

Durante o *treinamento*, o modelo analisa um grande conjunto de dados de imagens labeladas, observando como elas se degradam quando um ruído gaussiano é adicionado progressivamente. Esse ruído se acumula de forma mais intensa em regiões com *pixels* similares. O modelo aprende a mapear esse processo, identificando como a estrutura da imagem original se deteriora e quais elementos (como cores ou formas distintas) resistem mesmo com o aumento do ruído. Esses padrões residuais servem como base para a reconstrução, permitindo que o modelo compreenda a relação entre degradação e reversão (Salvaggio, 2023).

Na fase de *geração*, o modelo parte de uma composição totalmente aleatória (ruído puro) e, guiado pelo *prompt* textual, remove o ruído de forma iterativa em um processo conhecido como *denoising*. O texto atua como um filtro, direcionando o modelo a buscar representações visuais em seu banco de dados interno, em que palavras estão correlacionadas a padrões aprendidos no treinamento. O ruído é reduzido a cada iteração, até que emergja uma imagem que, estatisticamente, corresponda à descrição fornecida. O resultado é uma síntese entre o comando textual e os padrões visuais internalizados pelo modelo (Salvaggio, 2023). A Figura 1 ilustra esse processo.



Fonte: (Kumar, 2024).

Esse mecanismo opera, em parte, como um sistema semiótico: o usuário descreve uma imagem em palavras, e o computador converte essa descrição em dados numéricos, associando a entrada a representações visuais armazenadas. Em outras palavras, o modelo de IA estabelece

relações entre significantes — por exemplo, vinculando a entrada “coelho” a imagens de coelhos — sem, no entanto, compreender o significado real do objeto. Ou seja, em tese, o sistema poderia correlacionar “coelho” a uma representação incorreta, como a de um pato. Como cada imagem possui múltiplos descritores (ex.: “coelho comendo cenoura”), o modelo não deve buscar apenas correspondências literais, mas também relações contextuais, atribuindo probabilidades estatísticas a conjuntos de conceitos — como entender que “coelho” e “cenoura” são palavras que frequentemente são associadas (Telles, 2023).

Quanto a classificação das imagens, inicialmente os modelos de difusão dependiam de anotações manuais realizadas por codificadores humanos remunerados. No entanto, com a aquisição da ReCAPTCHA pelo Google em 2009, os sistemas passaram a contar com a decodificação de imagens como método de verificação de segurança contra *bots* para alimentar seus bancos, coletando dados de treinamento de forma indireta e não remunerada. Essas imagens, rotuladas por usuários, foram organizadas em categorias pré-definidas ou tiveram suas classificações inferidas pelos próprios modelos com base em semelhanças com categorias existentes (Telles, 2023; Salvaggio, 2023). Além disso, como a maioria das plataformas de IA utiliza imagens publicamente disponíveis na *web*, é provável que os motores de busca capturem e indexem esse conteúdo para alimentar seus bancos de dados visuais (Telles, 2023). Esse mecanismo de coleta, provavelmente inclui modelos como os utilizados pelo *Leonardo.AI*.

As IAGs transformaram a produção visual ao gerar imagens complexas a partir de comandos textuais simples. Sua natureza estatística explica por que, em alguns casos, as imagens geradas podem parecer genéricas ou até mesmo absurdas. Além disso, a aleatoriedade do processo faz com que um mesmo comando gere saídas diferentes a cada execução (Santaella; Kaufman, 2024).

Um aspecto crucial desses modelos é sua capacidade persuasiva: eles foram treinados para replicar produções humanas de maneira convincente. Esse potencial se torna especialmente preocupante quando aplicado à criação de *deepfakes* e imagens hiper-realistas, que podem ser visualmente críveis, mas completamente falsas. A identificação de imagens falsas exige um esforço crítico deliberado, pois a visão humana tende a aceitar o que é visto como verdadeiro, a menos que detalhes inconsistentes ou informações externas levem a uma análise mais cuidadosa (Santaella; Kaufman, 2024).

É importante ressaltar que o avanço da IA está majoritariamente nas mãos de companhias privadas, criando uma dinâmica que reforça o controle das grandes corporações de tecnologia. Gigantes como *Amazon*, Google, Meta, X e OpenAI têm fortalecido suas plataformas, limitando a independência de organizações públicas e privadas, que passam a seguir as regras comerciais desses grupos e a depender de suas estruturas. Apesar de nem todas elas possuírem modelos especificamente voltados para IAG essas poucas empresas ainda dominam os dados, infraestrutura digital e mercado de tecnologia, e recentemente, tem feito uso da IA para impulsionar conteúdos que exercem pressão geopolítica sobre instituições e autoridades, a fim de avançar suas próprias agendas políticas.

Diante desse contexto, entendemos que as IAGs encapsulam as contradições da cultura digital; potencializam a criação, mas também naturalizam desigualdades (via vieses); esvaziam noções tradicionais de autoria e desafiam a criticidade visual humana. Seu estudo exige um olhar interdisciplinar — da teoria da imagem à sociologia da tecnologia — para entender como elas estão remodelando não só a produção visual, mas também o imaginário coletivo sobre criatividade, trabalho e identidade. Para tornar esses desafios mais palpáveis, discutiremos como essa tecnologia se relacionam a questões de representação de gênero, trabalho e raça na próxima seção.

Gênero, trabalho e representação: Vieses Algorítmicos

As imagens produzidas por sistemas de IAG funcionam como infográficos que condensam padrões presentes nos conjuntos de dados que as originaram. Ao sintetizar bases de imagens e textos, elas revelam não apenas a estrutura desses *datasets*, mas também as escolhas humanas – muitas vezes inconscientes – envolvidas em sua organização. Assim, podem ser “lidas” como textos visuais que espelham mitos coletivos e pressupostos não declarados da sociedade que as produziu. Nesse processo, as máquinas reproduzem e amplificam vieses presentes na coleta e classificação dos dados, codificando visões de mundo que privilegiam certos grupos enquanto marginalizam outros (Salvaggio, 2023).

Os dados utilizados para treinar esses sistemas refletem contextos culturais, políticos e econômicos específicos, frequentemente alinhados aos padrões dominantes do Norte Global⁵.

⁵ De forma sucinta, podemos dizer que a divisão Norte/Sul Global é uma construção socioeconômica e política. Norte Global usualmente é utilizado para se referir ao conjunto de países que controlam a maior parcela da renda global e das indústrias. Sul Global refere-se a regiões da América Latina, África, Ásia e Oceania que são significativamente afetados por desequilíbrios globais de poder – sendo que muitos desses compartilham histórias de colonialismo e ainda sofrem as consequências da colonização.

Como resultado, as imagens geradas perpetuam estereótipos relacionados a idade, gênero, etnia e padrões de beleza. Por exemplo, Salvaggio (2023) observa que rostos brancos aparecem com maior definição e frequência, enquanto rostos negros — sobretudo os de mulheres negras — muitas vezes exibem traços inconsistentes ou pouco detalhados. Representações *queer* também são frequentemente apagadas ou distorcidas, como em imagens de casais homossexuais. Mais do que respostas a *prompts*, essas visualizações expõem os limites e exclusões embutidos no arquivo cultural que as alimenta.

Esse fenômeno pode ser ilustrado pelo estudo de Birhane *et al.* (2024), que demonstrou como a expansão de um modelo de IA — de 400 milhões para 2 bilhões de amostras — aumentou significativamente a associação entre rostos de homens negros e latinos e estereótipos de criminalidade. O estudo evidencia que, embora conjuntos de dados amplos sejam cruciais para o desempenho dos modelos, eles também podem cristalizar preconceitos, vinculando corpos racializados a narrativas negativas.

A IAG pode restringir a geração de ideias, produzir ilustrações distorcidas e excludentes, apagando nuances culturais e grupos sociais marginalizados dos processos locais de criação de imagens. Além disso, acelerar a produção visual, pressiona artistas e designers periféricos, que enfrentam não apenas o risco de perder espaço no mercado, mas também a exigência de criar mais em menos tempo. Diferentemente de artistas humanos — que, mesmo não obrigados a retratar a realidade compartilhada por suas comunidades, carregam responsabilidade moral perante a sociedade —, a IAG produz imagens artificiais, desvinculadas de qualquer responsabilidade (Mim *et al.*, 2024). Os impactos negativos dessa ausência de contexto tendem a se agravar no Sul Global.

Os vieses nas representações de trabalho e gênero têm raízes históricas, para melhor entendê-los vamos começar refletindo sobre o que é trabalho. O termo “trabalho” remete ao latim *tripalium*, instrumento usado para imobilizar animais e torturar pessoas escravizadas, carregando uma conotação negativa (Godinho, 2018). Hirata e Zarifian (2009) o definem como a relação entre operações objetivas e a capacidade humana de realizá-las, com valor medido por tempo ou remuneração.

Kergoat (2009) relaciona trabalho e gênero, apontando a divisão entre tarefas masculinas e femininas e a hierarquia que privilegia o trabalho dos homens. Atividades associadas às mulheres, como cuidados domésticos, são consideradas difíceis de mensurar e,

portanto, subvalorizadas. Além disso, é importante considerar que a atribuição de tarefas por gênero também varia culturalmente, e que tarefas consideradas femininas em uma sociedade podem ser vistas como masculinas em outra.

Sun *et al.* (2024) apontam que os vieses de gênero na mídia são prejudiciais de duas maneiras principais: ao afetar negativamente a autoimagem e desempenho cognitivo, e ao influenciar a percepção social sobre questões de gênero. Esses vieses se dividem em representacional — como a desigualdade na representação de homens e mulheres em certos papéis — e presentacional — que envolve a reprodução de estereótipos por meio de expressões, gestos ou características físicas. Por exemplo, mulheres são frequentemente retratadas como sorridentes e afetuosas, enquanto homens aparecem como calmos e racionais, reforçando noções culturais tradicionais.

Algoritmos de IA reproduzem e amplificam esses estereótipos, associando profissões de prestígio a figuras masculinas e vinculando mulheres a tarefas domésticas ou cargos subalternos. Além disso, a representação feminina tende a ser mais passiva e submissa, com expressões e ângulos de câmera que reforçam hierarquias de gênero. Enquanto homens são retratados em poses dominantes e autoritárias, mulheres são frequentemente mostradas em posições que transmitem fragilidade ou subordinação (SUN *et al.*, 2024).

Em vista disso, entendemos que a produção de imagens por IAG não é neutra e pode reforçar estruturas coloniais de poder ao reproduzir estereótipos racializados e apagar perspectivas não-hegemônicas. Os *datasets* de treinamento, majoritariamente compostos por imagens ocidentalizadas e em língua inglesa, impõem um viés epistemológico que privilegia corpos brancos, paisagens europeias/americanas e narrativas eurocêntricas. Por exemplo, *prompts* como “pessoa bonita” ou “líder” tendem à geração de figuras com traços caucasianos e corpos masculinos, enquanto representações de “pobreza” ou “violência” tendem a corpos negros ou latinos. Nesse sentido, as IAGs podem operar como mecanismos de controle, atualizando noções de representação que há séculos moldam quem pode ser visto, como e sob quais rótulos.

Leitura de Imagem de IAGs: adaptação a partir de Dondis e Panofsky

A temática imagem é abrangente e carrega muitos significados, então, de que imagem iremos tratar? Areal (2012, p. 1) explica: “uma imagem é sempre uma representação de outra

coisa”. Aqui iremos tratar das imagens fixas (sem movimento) e figurativas (representações de formas humanas).

Os estudos sobre imagens produzidas por IA ainda são recentes e carecem de referenciais consolidados; no entanto, observamos um esforço significativo no campo da computação para desenvolver ferramentas capazes de detectar se uma imagem foi gerada por IAG, especialmente no âmbito forense. Quanto à leitura dessas imagens, foco central deste estudo, destacamos os trabalhos de Salvaggio (2023) e Telles (2023), que, no entanto, abordam a questão sob uma perspectiva distinta da nossa, a qual visa adotar parâmetros de análise de imagem consolidados na área de Artes Visuais.

Para refletir sobre estas imagens que produzimos com a IAG, partiremos da perspectiva warburguiana⁶ (Gombrich, 1986), que busca a compreensão do conteúdo temático, ou seja, o significado da imagem. Adotaremos uma análise que parte de dois elementos *Forma* e *Conteúdo*.

A *Forma*, refere-se ao aspecto visível, seus elementos visuais como cor, linha, dimensão, plano, entre outras qualidades expressivas da imagem. Para realizar a descrição da *Forma* da imagem utilizaremos Dondis (2015) que, em seu capítulo “Elementos básicos da comunicação visual”, apresenta estes elementos: ponto, linha, plano, forma, tom, cor, textura, escala, dimensão e movimento. Assim, realizaremos a descrição destes elementos, entre outros que julgarmos importantes, para desenvolver a descrição da Forma da imagem.

Utilizaremos *Conteúdo* para nos referirmos ao tema e aos significados expressivos da imagem. Partiremos da proposta de Panofsky (2007) para pensar em como interpretar o conteúdo da imagem, sem necessariamente segui-la à risca. Essa proposta é conhecida como metodologia iconológica, e se estrutura em três etapas interpretativas: a Descrição Pré-Iconográfica, a Análise Iconográfica e a Interpretação Iconológica. Assim, para a descrição do *Conteúdo* será importante observarmos na imagem: fatos, personagens, situações, elementos, assuntos e conceitos.

Embora Dondis e Panofsky tenham desenvolvido suas propostas distintas e sem correlações, uniremos as duas a partir da *Interpretação do leitor/a na relação forma-conteúdo*,

⁶ A perspectiva warburguiana refere-se aos estudos de Aby Warburg (1866-1929), historiador e teórico de arte, que iniciou estudos de imagens fundamentados na iconologia, ou seja, os estudos dos seus significados.

neste momento será importante que o/a leitor/a desenvolva sua própria interpretação sobre a imagem, a partir das descrições anteriores.

Outro ponto a se considerar é que a imagem figurativa é uma representação. A fotografia, por exemplo, é uma representação do real, captada pela câmera fotográfica. Por outro lado, na imagem figurativa da IA, a criação é realizada por meio de algoritmos que sintetizam dados visuais a partir de padrões aprendidos em grandes conjuntos de imagens, sem uma referência direta e única ao mundo físico. Esta imagem se aproxima daquela criada por diferentes tecnologias, como explica Couchot (1999, p.42):

[...] a imagem numérica não representa mais o mundo real, ela o simula. Ela o reconstrói, fragmento por fragmento, propondo dele uma visualização numérica que não mantém mais nenhuma relação direta com o real, nem física, nem energética.

Em vista disso, a leitura de imagens geradas por IAG precisa levar em conta questões relacionadas ao modelo empregado para sua geração, ao *prompt* textual utilizado e aos possíveis conflitos entre as expectativas do usuário e o resultado produzido pelo sistema. Considerando essa complexidade, apresentamos, na seção de metodologia, uma proposta inicial de adaptação metodológica para a análise dessas imagens.

Metodologia

O presente estudo se configura como uma pesquisa de carácter exploratório (Severino, 2007), uma vez que investiga a adaptação de abordagens consolidadas para analisar um novo tipo de artefato imagético. Trata-se de uma investigação qualitativa (Lüdke; André, 1986), já que seu objetivo é descrever e analisar, de forma contextualizada, o fenômeno da leitura de imagens geradas por IA, sem pretensão de generalizações.

Metodologicamente o processo dividiu-se em três etapas interrelacionadas. A primeira compreende a adaptação do método de leitura de imagem, resultando na elaboração da Leitura de Imagem para IAG (LI-IAG) apresentada no **Quadro 1**.

Na segunda etapa, ocorreu a seleção e construção do corpus, em que foram definidos a plataforma, o modelo de IAG e as configurações utilizadas para a geração das imagens. Por fim, a terceira etapa consistiu na aplicação do método LI-IAG às imagens geradas, permitindo a análise e discussão dos resultados à luz do referencial teórico construído.

Quadro 1 – Proposta LI-IAG: Leitura de Imagem a partir da Forma e Conteúdo para IAG:

ETAPA	O QUE CONTEMPLA	ADAPTAÇÃO PARA IMAGENS IAG
1. Forma	Ponto, linha, plano, forma, tom, cor, textura, escala, dimensão, movimento, entre outros elementos.	Artefatos Técnicos: Pixels desalinhados ou distorções; Fundos incoerentes ou sobreposições impossíveis; Sombras mal renderizadas ou inconsistentes; Gradientes manchados ou cores desfocadas. Padrões Composicionais: - Linhas: Orgânicas (ex.: cabelos fluidos) ou geométricas (ex.: arquitetura). Traços incoerentes ou quebras abruptas. - Formas: Distorções (ex.: mãos com dedos extras) ou surrealismo intencional. - Texturas: Híbridas (ex.: pele com padrões metálicos) ou repetitivas. - Escala: Proporções absurdas. - Movimento: Efeitos estilizados (ex.: desfoque dinâmico) ou caóticos (ex.: traços sem direção clara).
2. Conteúdo	Fatos, personagens, situações, elementos, assuntos e conceitos, entre outros conteúdos.	Estereótipos e Vieses: Roupas, cenários ou características pessoais seguem padrões estereotipados? A representação de gênero, raça ou cultura é tendenciosa? O resultado reflete tendências culturais presentes no <i>dataset</i> de treinamento da IA? Realismo e Coerência: A imagem inclui elementos reconhecíveis ou é totalmente fictícia? As figuras/personagens parecem naturais ou artificiais (ex.: sorrisos rígidos, rostos genéricos, ausência de etnia definida)? As interações entre elementos fazem sentido ou são aleatórias (objetos irreais, múltiplos elementos desconexos, eventos impossíveis, elementos contraditórios)? Estilo e Composição: A imagem imita um estilo específico ou é genérica? Uso intencional de cores, luz e perspectiva, ou padrões repetitivos típicos de IAGs? Há temas genéricos e recorrentes em modelos de IA (ex: distopia, utopia futurista, natureza reimaginada)? Subtexto e Mensagem: A imagem comunica claramente um assunto? Há contradições visuais (ex.: “felicidade” retratada com expressões vazias)? Há sugestão de história ou apenas construção estética?
3. Interpretação do/a leitor/a na relação forma – conteúdo	O leitor/a deve interpretar a imagem a partir das relações entre forma e conteúdo, buscando seus significados subjetivos e possíveis questionamentos.	- A imagem corresponde ao solicitado? Se não, quais desvios ocorreram (ex.: ambiguidades no texto, limitações da IA)? - A IA introduziu distorções ou elementos inesperados? Eles podem ser significativos? - A imagem desafia noções de autoria, originalidade ou ética? Ela expõe limites da IA ou do humano que a idealizou? - Como a imagem dialoga com discussões atuais?

Fonte: Autores.

O Quadro 1 foi construído pela articulação das teorias de Dondis (2015) e Panofsky (2007), e de nossas observações sobre as questões atreladas às imagens produzidas por IA.

As imagens analisadas foram produzidas pelo modelo *Leonardo Phoenix 1.0* com configurações padrão de estilo *Dynamic*, e dimensão 736x1120 *pixels* da plataforma *Leonardo.AI*, escolhida tanto por sua acessibilidade — ainda que não totalmente gratuita, permite a geração de um número controlado de imagens diárias mediante um sistema de créditos — quanto pela familiaridade dos autores com a ferramenta, o que facilitou o manejo técnico.

Utilizamos dois *prompt* para a geração das imagens sendo eles “*Person working as an artist*” (*prompt a*) e “*Black person who works as an artist*” (*prompt b*). A escolha de dois *prompts* distintos permitiu explorar como a especificação racial influencia a construção de identidades visuais, ainda que dentro de esquemas pré-estabelecidos. Optou-se pelo inglês por ser a língua na qual o modelo foi treinado e por empregar expressão de gênero neutro ao referir-se ao artista retratado, o que permitiu uma identificação mais clara do viés algorítmico ao eliminar essa variável.

Cada *prompt* gerou 8 imagens, totalizando 16 imagens no total das quais optamos por realizar a análise aprofundada de 2. Os resultados foram compilados e são discutidos na seção a seguir. Reforçamos que as imagens apresentadas nos resultados correspondem as oito primeiras imagens geradas a partir de cada *prompt* em inglês, ou seja, não fizemos nenhuma curadoria ou testes prévios para gerar esse corpus. Vale destacar também que fizemos uso da tecnologia *Microsoft Copilot* para revisar o documento em tela e aprimorar a coerência e fluidez do texto.

Resultados e discussão

As imagens geradas pelo modelo *Leonardo.AI*, são apresentadas na Figura 2. Na linha “a”, estão representadas as imagens geradas pelo *prompt* “*Person working as an artist*” (*prompt a*), enquanto na linha “b”, estão representadas as imagens geradas pelo *prompt* “*Black person who works as an artist*” (*prompt b*).

Figura 2 – Imagens geradas pelo modelo Leonardo.AI, sendo a) “Person working as an artist” e b) “Black person who works as an artist”



Fonte: Autores (2025).

Dada a natureza exploratória do estudo, decidimos aplicar a LI-IAG somente sobre as primeiras imagens que recebemos como retorno aos *prompts*, apresentadas na Figura 3 e Figura 4. Lembrando que realizamos a leitura de imagem a partir da LI-IAG, ou seja, da Forma, Conteúdo e Interpretação da/o leitor/a na relação forma-conteúdo.

Análise da Forma

Na primeira imagem (Figura 3) gerada a partir do *prompt* neutro, observamos uma mulher branca em um estúdio clássico, com elementos como pincéis, telas abstratas e livros. A composição segue padrões técnicos identificados por Dondis (2015): linhas orgânicas (cabelos fluidos), formas geométricas (quadros retangulares) e uma paleta de cores quentes que sugere criatividade. Há também artefatos técnicos, como sombras inconsistentes no avental e fundos sobrepostos (ex.: livros e outros elementos parecem se unir, quase como se suas cores “escorressem” pelas prateleiras), evidenciam limitações do modelo em simular coerência espacial. A textura da pele, homogênea e desprovida de detalhes realistas. A renderização da mão direita aparenta ter seis dedos, contudo, essa distorção aparenta ser mais uma limitação associada a capacidade da ferramenta de produzir uma mão que necessariamente atrelada a raça da protagonista. Em relação a proporção, nos chamou a atenção que os livros ao fundo parecem ter um tamanho exagerado dado a distância em que estão posicionados.

Na segunda imagem (**Erro! Fonte de referência não encontrada.**), gerada com o *prompt* específico para pessoa negra, a protagonista apresenta cabelo crespo volumoso, brincos

grandes e um colar com símbolos que remetem a estereótipos culturais africanos. A paleta de cores é mais fria, com contrastes acentuados entre tons de amarelo e azul, sugerindo uma tentativa de associar a identidade negra a exuberância visual. A renderização das mãos apresenta irregularidades, percebemos que as mãos não aparecem dando a sensação de estarem amputadas. Salvaggio (2023) aponta que grupos minorizados tem mais chances de serem representados de forma distorcida. Há também sobreposição de elementos no fundo (ex.: alguns quadros parecem não respeitar se espaço físico, quase como se estivessem “flutuando”) reforçam distorções técnicas comuns em IAGs. A textura da pele, embora mais detalhada, ainda carrega um tom uniforme que não reflete a complexidade de tonalidades negras. Em relação a proporção, notamos que os pincéis atrás da protagonista apresentam tamanhos irrealista, dado a distância em que estão.

Figura 3 – Primeiro retorno do *prompt a*.



Fonte: Autores (2025).

Figura 4 – Primeiro retorno do *prompt b*.



Fonte: Autores (2025)

Análise do Conteúdo

As duas imagens (Figura 3e Figura 4) apresentam mulheres que estão no espaço de trabalho, ligado a arte e, mais especificamente, a pintura. Os aventais sugerem o uso de tinta. Tanto na mesa quanto ao fundo observamos diversas produções com a mesma técnica. Apesar do *prompt* ser artista, a interpretação foi da arte apenas como pintura (ficaram excluídas:

desenho, escultura, arte digital, entre outras técnicas e manifestações artísticas). Telles (2023) relata que as IAG normalmente estabelecem um “*ranking*” de correlação entre conceitos, indicando que provavelmente o *Leonardo.AI* relaciona os conceitos de *artista*, *pintura* e *quadros* de forma muito significativa, bem como deve possuir poucos exemplos de imagens baseadas em outras técnicas ou as associa de forma menos significativa com o termo artista.

Ambas as imagens (Figura 3 e Figura 4) reproduzem o estereótipo do “artista solitário”, isolado em um espaço idealizado. Ambas as figuras também representam mulheres, mesmo utilizando um *prompt* que não identifica gênero— indicando que o *dataset* vincula os conceitos de artista (*artist* em inglês, gênero neutro) e mulher.

As mulheres representadas são retratadas de formas muito similares: mesmo estilo de vestimentas, posicionamento em relação ao observador, composição e disposição dos elementos na imagem. Ademais, ambas podem ser consideradas magras, com pele lisa, maquiagem discreta e traços frágeis – muito próximos dos padrões de beleza atuais. Quanto as diferenças entre as personagens, notamos que a mulher branca não possui acessórios, enquanto a mulher negra é representada com um colar e brincos grandes. Essa diferenciação racializada parece revelar como o *dataset* de treinamento da IA associa brancura a universalidade e negritude a marcadores culturais específicos, muitas vezes reduzidos a *tokens* superficiais.

Com relação ao realismo e coerência, na Figura 3, apesar de a mulher estar trabalhando com uma pintura, seu instrumento de trabalho é uma caneta, o que não é coerente no contexto representado. A composição é similar entre as duas imagens, sugerindo a presença de uma janela que ilumina a cena, e nota-se a tentativa de acentuar contrastes de luz sombra, como se a própria IAG estivesse tentando fazer uma pintura.

A ausência de contexto social nas duas imagens, como ferramentas digitais, colaborações ou referências a movimentos artísticos coletivos, bem como, reforça a visão eurocêntrica do artista como gênio individual, dissociado de estruturas históricas ou comunitárias. A Figura 4, embora não inclua elementos culturais, apresenta quadros ao fundo representando uma pessoa negra, o olhar confiante da artista contrasta com a passividade de seu entorno, sugerindo uma representação performática de emponderamento.

Interpretação da/o leitor/a na relação forma-conteúdo

A aplicação do LI-IAG evidenciou que, mesmo quando *prompts* buscam diversidade, as IAGs reproduzem hierarquias coloniais embutidas em seus *datasets*. A necessidade de especificar “*Black*” no *prompt* para gerar uma representação não branca expõe um viés estrutural: o modelo entende “artista” como branco por padrão, exigindo correções explícitas para incluir outras identidades.

Além disso, a sobreposição de estereótipos culturais na Figura 4, como cabelo crespo volumoso e brincos grandes associados a “autenticidade” revela como a IA sintetiza dados históricos de representação racial, reforçando narrativas coloniais mesmo quando tenta subvertê-las. A tentativa superficial fica mais clara quando se considera que o conjunto com 16 imagens apresentado na Figura 2 – nele podemos perceber que das 8 pessoas negras, 8 são representadas com cabelo crespo volumoso e 6 com brincos grandes. Em outras palavras, nos parece que a Figura 4 é essencialmente similar a Figura 3, apenas foram adicionados marcadores raciais em um *schema* pré-estabelecido. Mim et al. (2024) corroboram essa ideia ao apontar que as IAGs tendem a produzir imagens esvaziadas de nuances culturais.

Esteticamente, o *prompt* revela que para esse modelo, artista é uma profissão fortemente vinculada a figuras femininas e a corpos frágeis e hiper padronizados. A fragilidade fica mais evidente ao se observar a Figura 2, em que uma parcela significativa das mulheres brancas aparenta está com a cabeça levemente abaixada. O mesmo não ocorre com as mulheres negras, sua postura está mais ereta, com o olhar mais próximo do nível do olho do observador – também não ocorre com a única imagem que apresentou uma figura masculina. Sun et al. (2024) apresentam duas questões sobre vieses de gênero que dialogam diretamente com esses apontamentos: (1) os vieses tendem a prejudicar a autoimagem das mulheres (ao reforçar um padrão de corpo) e (2) as figuras femininas tende a ser mais passiva e submissa, com expressões e ângulos de câmera que reforçam hierarquias de gênero. Notamos a forte correlação sobre a questão (2) no caso das mulheres brancas, o mesmo não pareceu ocorrer com as mulheres negras.

Os artefatos técnicos (ex.: sombras inconsistentes, anatomia distorcida) não são meros erros, mas sintomas de um sistema que prioriza coerência estatística sobre significado humano. Enquanto a Figura 3 aproxima-se de um ideal clássico eurocêntrico, a Figura 4 é marcada por *tokenismo*, incapaz de equilibrar especificidade cultural e complexidade narrativa. Essas tensões destacam a urgência de metodologias críticas, como a LI-IAG, para desvendar como algoritmos não apenas reproduzem, mas atualizam mecanismos de poder visual.

A análise das imagens geradas pelo modelo *Leonardo.AI*, com base no método LI-IAG proposto, revelou padrões estereotipados e vieses algorítmicos que corroboram as discussões teóricas sobre colonialidade e representação em sistemas de IA.

Considerações Finais

A imagem se faz presente, significativamente na vida dos seres humanos desde o período da não escrita, ou seja, antes da escrita as representações visuais eram uma importante forma de comunicação e expressão. Segundo Bredekamp (2015) vivenciamos o século da imagem, ou seja, nunca na história a imagem foi tão utilizada pelos seres humanos. E, com a intensificação do uso da IA, estamos produzindo e reproduzindo imagens em um formato totalmente diferente do que conhecíamos. E, precisamos buscar compreender a questão da imagem nesse novo formato, a IAG.

Este estudo reforça a necessidade de transparência nos *datasets* de IAGs e de práticas decoloniais no treinamento de modelos. A análise das imagens demonstra que a mera inclusão de diversidade em *prompts* não basta; é essencial questionar como as IAGs internalizam e reproduzem convenções visuais historicamente excludentes.

Nossas discussões suscitaram mais questionamentos do que respostas, entre estas elencamos: No que a imagem figurativa produzida pela IAG se diferencia das imagens figurativas já produzidas no decorrer de nossa história? O que a imagem figurativa produzida pela IAG tem em comum com as imagens produzidas por artistas e fotógrafos? Inferimos, assim, a importância de desenvolver mais estudos sobre a IAG, de forma a sistematizar esse campo, bem como, o relacionar estes estudos com os desenvolvidos em áreas que trabalham com a Imagem, como, por exemplo, as Artes Visuais.

A LI-IAG (Leitura de Imagem para IAG) surge como um primeiro esforço para sistematizar critérios de interpretação específicos para IAG, reconhecendo tanto seu potencial quanto suas limitações intrínsecas — como vieses de treinamento e a natureza aberta da relação entre *prompt* e resultado visual. No estágio atual ela ainda é um instrumento experimental que estamos aperfeiçoando, mas, mesmo assim, já pode ser utilizada como uma ferramenta didática para auxiliar educadores a introduzir o letramento visual sobre imagens feitas com IAG em sua prática pedagógica.

Futuras pesquisas poderiam explorar como diferentes modelos (ex.: Leonardo AI, Adobe Firefly, DALL-E ou Midjourney) respondem a variações de *prompts* sobre gênero, raça e trabalho, ampliando o diálogo entre teoria da imagem e ética em IA – é possível também analisar os vieses produzidos por essas ferramentas sobre outras questões. Outra possibilidade interessante é verificar o quanto a LI-IAG proposta pode ser útil como ferramenta auxiliar para que observadores humanos diferenciam imagens feitas por IAGs de imagens feitas por pessoas – apontando possíveis experimentos.

Referências

- AREAL, L. O que é uma imagem? **Aulas abertas: no 5**, 2012. Disponível em: <https://iconline.ipleiria.pt/bitstream/10400.8/566/1/art4.pdf>. Acesso em: 05 abr. 2025.
- BIRHANE, A.; DEHDASHTIAN, S.; PRABHU, V. U.; BODDETI, V. The dark side of dataset scaling: Evaluating racial classification in multimodal models. In: **Proceedings of the 2024 ACM Conference on Fairness, Accountability, and Transparency**. 2024. p. 1229-1244. Disponível em: <https://arxiv.org/abs/2405.04623>. Acesso em: 12 abr. 2025.
- BREDEKAMP, H. **Teoria do acto icônico**. Trad. Artur Morão. Lisboa: KKYM, 2015.
- COMEST. **Preliminary Study on the Ethics of Artificial Intelligence**. Paris: Unesco, 2019. Disponível em: <https://unesdoc.unesco.org/ark:/48223/pf0000367823>. Acesso em: 1 abr. 2025.
- COUCHOT, E. Novas Imagens, Novos Modelos. In: PARENTE, A. **Imagem-máquina: a era das tecnologias do virtual**. 4. ed. Rio de Janeiro: Editora 34, 2011.
- DALALAH, D.; DALALAH, O. M. A. The false positives and false negatives of generative AI detection tools in education and academic research: The case of ChatGPT. **The International Journal of Management Education**, v. 21, n. 2, p. 100822, 2023.
- DONDIS, D. A. **Sintaxe da Linguagem Visual**. 3. ed. São Paulo: Martins Fontes, 1994.
- GODINHO, Thais. **Trabalho organizado: encontre equilíbrio e significado num mundo cada vez mais sobrecarregado**. São Paulo. Editora Gente, 2018.
- GOMBRICH, E. **Aby Warburg: an intellectual biography**. Oxford: Phaidon, 1986.
- HIRATA, Helena; ZARIFIAN, Philippe. Trabalho (conceito de), in: HIRATA, Helena et al. (orgs), **Dicionário crítico do feminismo**. São Paulo: Editora UNESP, 2009.
- HUANG, C., ZHANG, Z., MAO, B., YAO, X. An Overview of Artificial Intelligence Ethics. **IEEE Transactions on Artificial Intelligence**, v. 4, n. 4, p. 799–819, 2023.
- KERGOAT, Danièle. Divisão sexual do trabalho e relações sociais de sexo, in: HIRATA, Helena et al. (orgs), **Dicionário crítico do feminismo**. São Paulo: Editora UNESP, 2009.
- KUMAR, S. DDPM: Denoising Diffusion Probabilistic Models. Sushant Kumar Blog, [S. l.], [20--]. Disponível em: <https://sushant-kumar.com/blog/ddpm-denoising-diffusion-probabilistic-models>. Acesso em: 12 abr. 2025.

LÜDKE, M.; ANDRÉ, M. E. D. A. **Abordagens qualitativas de pesquisa: a pesquisa etnográfica e o estudo de caso**. São Paulo: EPU, 1986.

MIM, N. J.; NANDI, D.; KHAN, S. S.; DEY, A.; AHMED, S. I. In-between visuals and visible: The impacts of text-to-image generative ai tools on digital image-making practices in the global south. In: **Proceedings of the 2024 CHI Conference on Human Factors in Computing Systems**. 2024. p. 1-18. Disponível em: <https://doi.org/10.1145/3613904.3641951>. Acesso em 10 abr. 2025.

PANOFSKY, E. **Significado nas Artes Visuais**. Trad. M. C. F. Keese e J. Guinsburg, 3. ed. São Paulo: Perspectiva, 2007.

RUSSEL, S.; NORVIG, P. **Inteligência artificial**. 3ª Edição. Tradução Regina Célia Simille. Rio de Janeiro: Elsevier, 2013.

SALVAGGIO, E. How to Read an AI Image: Toward a Media Studies Methodology for the Analysis of Synthetic Images. **Image**, vol. 37, n. 1, p. 83-99, 2023.

SANTAELLA, L.; KAUFMAN, D. A Inteligência artificial generativa como quarta ferida narcísica do humano. **MATRIZES**, v. 18, n. 1, p. 37-53, 2024.

SEVERINO, A. J. **Metodologia do Trabalho Científico**. 23. ed. São Paulo: Cortez, 2007.

SUN, L.; WEI, M.; SUN, Y.; SUH, Y. J.; SHEN, L.; YANG, S. Smiling women pitching down: auditing representational and presentational gender biases in image-generative AI. **Journal of Computer-Mediated Communication**, v. 29, n. 1, p. zmad045, 2024.

TELLES, M. Estilo artístico na arte gerada por inteligência artificial: um estudo de caso de Jim Lee. In: **Anais do 32º Encontro Anual da Compós**, Campinas, 2023. UNCANNY X-MEN. Nova Iorque: Marvel Comics, n.248, set. 1989.

VAROUFAKIS, Y. **Technofeudalism: What killed capitalism**. Londres: Bodley Head, 2023.

VICARI, R.; BRACKMANN, C.; MIZUSAKI, L.; GALAFASSI, C. **Inteligência artificial na educação básica**. São Paulo: Novatec Editora, 2023. 1. ed.

Recebido em: 16 de abril de 2025

Aceito em: 16 de agosto de 2025
