

Separar e Remontar: IA generativa através das lentes das histórias da arte e da mídia

Separate and Reassemble: Generative AI through the lens of art and media histories

LEV MANOVICH^a

Universidade da Cidade de Nova York. Nova York, Estados Unidos

RESUMO

A geração de imagens por IA representa uma evolução lógica dos primeiros algoritmos de mídia digital, começando com programas básicos de pintura na década de 1970 e avançando para sofisticados gráficos 3D e softwares de criação de mídia na década de 1990. Os primeiros algoritmos tinham dificuldade para simular materiais e efeitos, mas os avanços nas décadas de 1970 e 1980 levaram a simulações realistas de fenômenos naturais e técnicas artísticas. A IA generativa continua essa tendência, usando redes neurais para combinar e interpolar padrões visuais de conjuntos de dados extensos. Esse método de criação de mídia digital ressalta a natureza modular e distinta das imagens geradas por computador, distinguindo-as da mídia óptica tradicional.

Palavras-chave: Geração de imagens por IA, mídia digital, redes neurais, computação gráfica, IA generativa

^a É professor presidente de Ciência da Computação no Centro de Pós-Graduação da City University of New York e diretor do Cultural Analytics Lab. É autor e editor de 15 livros, incluindo *Artificial Aesthetics*, *Cultural Analytics*, *Instagram and Contemporary Image*, *Software Takes Command* e *The Language of New Media*. Orcid: <https://orcid.org/0000-0003-0667-7584>. E-mail: manovich.lev@gmail.com

ABSTRACT

AI image generation represents a logical evolution from early digital media algorithms, starting with basic paint programs in the 1970s and advancing to sophisticated 3D graphics and media creation software by the 1990s. Early algorithms struggled to simulate materials and effects, but advances in the 1970s and 1980s led to realistic simulations of natural phenomena and artistic techniques. Generative AI continues this trend, using neural networks to combine and interpolate visual patterns from extensive datasets. This method of digital media creation underscores the modular and discrete nature of computer-generated imagery, distinguishing it from traditional optical media.

Keywords: AI image generation, digital media, neural networks, computer graphics, generative AI

DOI: <http://dx.doi.org/10.11606/issn.1982-8160.v18i2p7-18>

V.18 - Nº 2 maio/ago. 2024 São Paulo - Brasil LEV MANOVICH p. 7-18

MATRIZES



D

Separar e Remontar

¹ Os termos mídia generativa, mídia sintética ou IA generativa referem-se ao processo de sintetizar objetos de mídia com redes neurais artificiais.

Exemplos de tais objetos incluem texto, voz, música, modelos 3D, conjuntos de dados e código de computador.

Os termos imagem generativa, imagem de IA ou IA visual referem-se a objetos visuais especialmente sintetizados.

Esses objetos podem ser imagens estáticas que imitam a aparência e a estrutura de todos os tipos de mídia visual, de fotografias a desenhos, e também imagens em movimento que imitam as aparências de animação e vídeo.

A *IMAGEM DE IA*¹ REPRESENTA uma evolução lógica adicional do processo que se iniciou com os algoritmos de mídia digital na década de 70 e prosseguiu nas décadas seguintes. Os primeiros programas de pintura para computador foram criados na década de 1970, mas ainda não conseguiam simular diferentes tipos de tinta, pincéis e superfícies texturizadas como a tela (Smith, 2001, 2021). Porém, durante os anos 90, programas como o Corel Painter (1991-) começaram a oferecer estes recursos (“Corel Painter”, 2024). Da mesma forma, os primeiros algoritmos de computação gráfica 3D para renderização de formas sólidas, sombreado Gouraud (1971) e sombreado Phong (1973), ainda não conseguiam simular a aparência de diferentes materiais. Posteriormente, nas décadas de 1970 e 1980, pesquisadores de computação gráfica criaram vários algoritmos para simular a aparência de diversos materiais e texturas, como tecido, cabelo e pele, bem como sombras, transparência, translucidez, profundidade de campo, reflexos de lente, desfoque de movimento, reflexos, água, fumaça, fogos de artifício, explosões e outros fenômenos naturais e técnicas e efeitos cinematográficos.

A simulação de muitos destes fenômenos e técnicas exige vários algoritmos separados que foram desenvolvidos ao longo do tempo. Assim, encontramos sessões distintas dedicadas a esses algoritmos com nomes como *Volumes and Materials*, *Fluid Simulation* ou *Cloth and Shells* nos anais anuais da SIGGRAPH, a principal conferência de computação gráfica (ACM SIGGRAPH, 2022). Por exemplo, o artigo “Predicting Loose-Fitting Garment Deformations Using Bone-Driven Motion Networks”, apresentado na conferência de 2023, descreve “um algoritmo de aprendizado que usa redes de movimento acionadas por ossos para prever a deformação de malhas de roupas soltas em taxas interativas”. Outro artigo da conferência, “Rendering Iridescent Rock Dove Neck Feathers”, descreve uma nova abordagem para modelagem e renderização de penas de pássaros; e assim por diante.

Em meu artigo de 1992, “Assembling Reality: Myths of Computer Graphics” (Manovich, 1992)² analisei este aspecto fundamental da computação gráfica, explicando que “o fotorrealismo sintético é fundamentalmente diferente do realismo da mídia óptica, sendo parcial e desigual, em vez de analógico”:

A recriação digital de qualquer objeto envolve a solução de três problemas distintos: a representação da forma de um objeto, os efeitos da luz e o padrão de movimento. Para que haja uma solução geral para cada problema, é necessária a simulação exata das propriedades e dos processos físicos subjacentes. Devido a altíssima complexidade matemática, isto não pode ser feito... Na prática, os pesquisadores de computação gráfica recorreram à solução de casos específicos, desenvolvendo

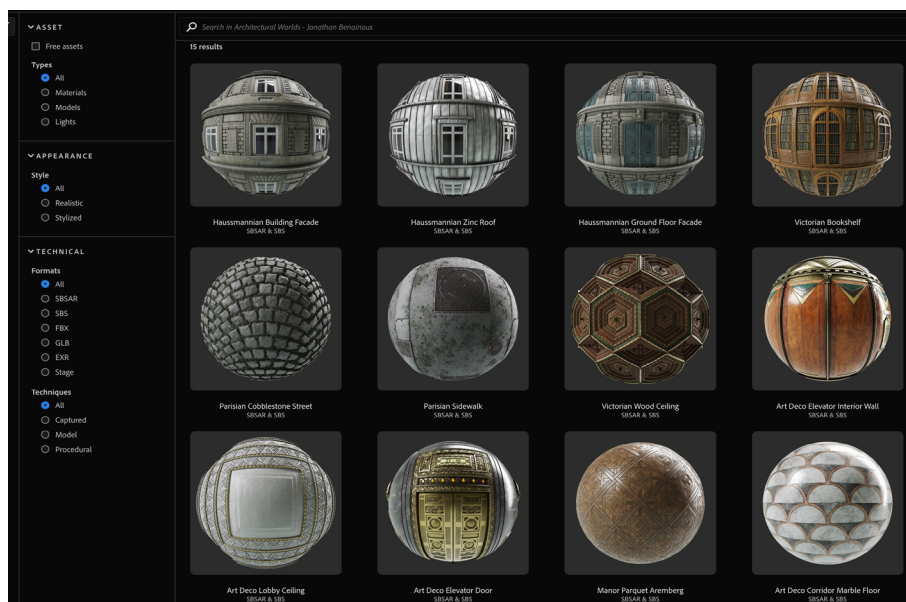
² Consulte também “Part 4: The Illusions” (Manovich, 2002).

vários modelos não relacionados para a simulação de alguns tipos de formas, materiais e movimentos. (Manovich, 1992, pp. 12-14)

Em outras palavras, a computação gráfica 3D divide o mundo que vemos, separando as formas, os materiais, os reflexos de luz, as texturas, os movimentos e os comportamentos dos objetos (Figura 1). Durante a renderização, os efeitos de vários algoritmos que simulam todos esses aspectos são combinados. Assim, *as representações visuais criadas usando computação gráfica são distintas e modulares, em vez de contínuas e “monísticas”*. Essa é uma das características mais importantes da mídia de computação gráfica, distinguindo-a da mídia de imagem óptica baseada em lentes.

Figura 1

Alguns dos milhares de materiais disponíveis no software de criação de conteúdo 3D da Adobe



Nota. Adaptado do autor

Essa lógica de separação e recombinação também define o próximo estágio da mídia digital: softwares para computadores para criação e edição de mídia. Após seu lançamento inicial em 1990, o Photoshop começou gradualmente a incluir efeitos e técnicas simulados de várias mídias artísticas, desde a fotografia

D

Separar e Remontar

em câmara escura até a pintura a óleo, em um único programa. Esses efeitos podem ser combinados em uma única imagem digital. Da mesma forma, softwares de música permitem que os usuários combinem muitos instrumentos simulados e vários efeitos, como reverberação e eco, em uma única composição. Os programas de processamento de texto e editoração eletrônica separam o processo físico de composição de impressão em suas partes básicas, que também podem ser recombinadas — por exemplo, você pode pegar qualquer fonte e alterar arbitrariamente seu tamanho ou gerar sua própria fonte³.

³ Para uma análise detalhada do software de mídia e suas origens conceituais, consulte Manovich (2013).

Todos esses recursos de software de mídia foram propostos pela primeira vez na década de 1970 e posteriormente realizados nas décadas de 1980 e 1990, tornando-se onipresentes. A mídia geradora de IA segue a mesma lógica, embora sua implementação técnica subjacente seja diferente. Durante o treinamento, as redes neurais aprendem padrões visuais característicos de centenas de mídias artísticas, técnicas e efeitos de iluminação da história da fotografia e da cinematografia e assinaturas visuais de milhares de artistas históricos e contemporâneos, arquitetos, designers de moda e outros criadores. O site de referência Midlibrary lista um total de 367 “técnicas artísticas” que a ferramenta geradora de imagens Midjourney AI pode simular de forma confiável, com base em testes realizados pela equipe do site⁴. Tais técnicas variam de “impressão em albumina” e “anáglifo” a “entalhe em madeira” e “renderização de estrutura de arame”.

⁴ Recuperado em 25 de fevereiro de 2024, de <https://midlibrary.io/>.

É importante ressaltar que um usuário pode incluir referências a várias técnicas e/ou vários criadores com um único comando, o que pode gerar novos tipos de efeitos de mídia que não existiam antes. Com base nos meus experimentos, exemplifico alguns exemplos de tais comandos:

- Uso de vários artistas com um único comando: “Gravura panorâmica muito grande e detalhada do século XVIII mostrando uma paisagem no estilo de *Michael Kaluta*, *Kawanabe Kyosai*, *Pieter Bruegel*, *o Velho*, detalhes insanos, cinematográfica”
- Uso de várias mídias artísticas com um único comando: “Espaço de armazenamento infinito e futurista de museu do século XVIII com objetos de arte nas prateleiras, neve caindo dentro do espaço e neblina, visão de ângulo amplo olhando para baixo, luz noturna suave das 19h, *desenho e gravura* intrincados e detalhados com sombreamento muito fino, *lápiz de cor* sombrio com nuances sutis e *canetas finas*”

A Figura 2 mostra uma captura de tela do site midlibrary.io que mostra algumas das técnicas artísticas, gêneros de arte e “estilos” de pintores, ilustradores, arquitetos, fotógrafos e designers de moda que o Midjourney pode simular. No momento em que este artigo foi escrito, a biblioteca continha cerca de 5.000 referências desse tipo. (Capturado em 24 de março de 2024).

Figura 2

Captura de tela de midlibrary.io



Nota. Adaptado do autor

O teórico pioneiro em mídia digital das décadas de 1990 e 2000, William J. Mitchell, chamou essa característica fundamental da mídia digital de “separar e recombinar”. Em seu livro de 1996, *City of Bits*, ele descreveu esse processo em relação ao planejamento urbano:

D

Separar e Remontar

Os arquitetos clássicos dos séculos XVIII e XIX lidaram com a tarefa de organizar os espaços criando hierarquias de espaços grandes e pequenos em torno de sistemas de circulação axiais e simétricos conectados a entradas grandes e formais e espaços públicos abertos... os modernistas funcionalistas do século XX muitas vezes derivaram seus *layouts* menos regulares diretamente de requisitos empiricamente estabelecidos de adjacência e proximidade entre os elementos espaciais necessários. Mas quando a telecomunicação por meio de bits rápidos na super via de informações (*infobahn*) complementa ou substitui o movimento dos corpos ao longo das vias de circulação, e quando a telepresença substitui o contato face a face entre os participantes das atividades, os vínculos espaciais que esperávamos são afrouxados. Os elementos constituintes de composições arquitetônicas e urbanas até então bem compactadas podem começar a flutuar livremente uns dos outros e podem potencialmente se realocar e se recombinar de acordo com novas lógicas. (Mitchell, 1996, p. 104)

As palestras de Mitchell nos anos 2000 expandiram essa formulação, demonstrando como a lógica de separação e recombinação pode ser vista na mídia digital de várias maneiras. A IA generativa segue a mesma lógica. Uma rede neural extrai elementos e estruturas de centenas de milhões ou bilhões de imagens em seu conjunto de treinamento. Elas incluem paletas de cores distintas, composições, efeitos de iluminação, artefatos de processos fotográficos históricos e assim por diante. Quando você solicita à ferramenta de imagem de IA que gere novas imagens com atributos visuais específicos, ela faz o possível para combinar (ou, mais precisamente, *interpolat*) padrões e efeitos artísticos apropriados.

Nenhum historiador, teórico ou praticante de arte visual, fotografia, cinema ou design conseguiu descrever todos esses padrões. No início do século XX, os historiadores de arte pioneiros Aby Warburg e Erwin Panofsky desenvolveram o estudo da Iconologia. Warburg define este conceito como motivos visuais que (re)aparecem em várias civilizações e mídias.

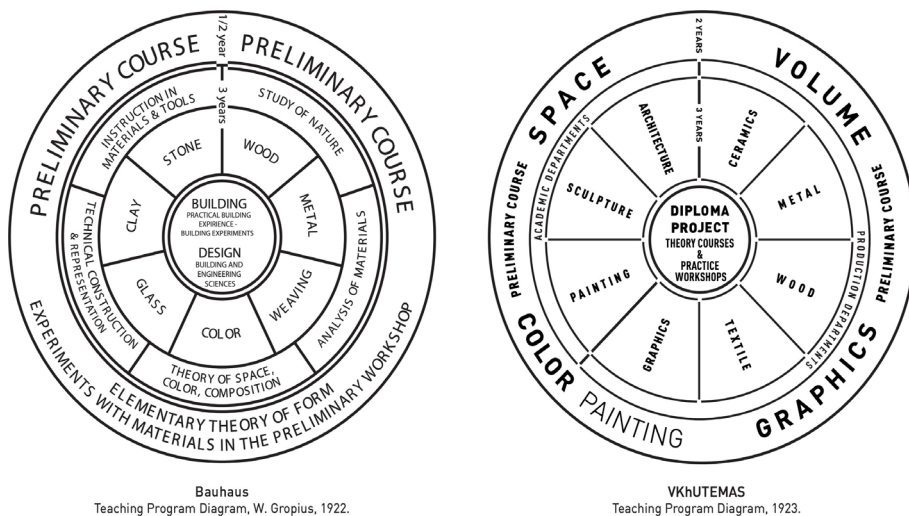
Panofsky o utilizou de forma um pouco diferente, referindo-se a símbolos e motivos que existiram em toda a história da arte. Durante o mesmo período, artistas visuais e arquitetos separaram as artes visuais de uma maneira diferente, decompondo uma imagem em seus componentes e dimensões básicos, como pontos, linhas, planos, formas bidimensionais, cor, espaço, textura, padrão, equilíbrio e balanço, entre outros. Embora este projeto de dismantelamento metódico e criação de novas linguagens visuais

a partir desses componentes seja fundamental para a arte modernista e seus diversos ismos, ele encontra seu desenvolvimento mais metódico nos currículos de duas novas escolas de arte e design. A Escola Superior de Arte e Técnica (Vkhutemas), em Moscou (1920-1930), e a Bauhaus, na Alemanha (1919-1933), introduziram na mesma época seu Curso Básico, no qual os alunos aprendiam a trabalhar sistematicamente com todos esses elementos e dimensões. Em vez de desenhar a partir da vida, pintar retratos ou fazer composições históricas, agora os alunos começavam o treinamento concluindo exercícios com primitivos de imagem, como formas básicas, formas e cores. Na Vkhutemas, o Curso Básico foi criado em 1920 por Rodchenko, Popova, Ekster, Vesnin e outros professores de pintura, arquitetura e outras áreas da escola. Em sua primeira versão, consistia em uma série de oficinas, como “Disciplina de formas e cores sincronizadas”, “Plano, cor e design espacial”, “Construção gráfica em uma superfície plana” e “Cor”. O Curso Básico sofreu diversas modificações durante a existência do Vkhutemas. Por fim, quatro sequências de aprendizado foram aprovadas para todos os alunos do Vkhutemas: Plano, Cor, Volume e Espaço⁵ (Figura 3 e 4).


⁵ Consulte Bokov (2021) e Vkhutemas (2020). O Curso Básico dessa escola era mais sistemático e abrangente do que um curso semelhante na Bauhaus; era ministrado por muitos membros diferentes do corpo docente e durava dois anos. Notavelmente, a Vkhutemas era dez vezes maior que a Bauhaus, com 100 professores e 5.000 alunos durante os 10 anos de sua existência, contra apenas 500 alunos na Bauhaus.

Figura 3

As estruturas dos cursos na Bauhaus e na Vkhutemas. Ambos os currículos começam com o curso básico



Nota. Adaptado do autor


Figura 4*Exemplos de exercícios de alunos na Vkhutemas**Observação.* Adaptado de Bokov (2014)

Em certo sentido, pode-se dizer que os modelos de IA generativa dão continuidade a esses programas de decomposição e análise de artes visuais que começaram no início do século XX. Os algoritmos de inteligência artificial extraem padrões (ou “características”) dos dados de treinamento. Contudo, no momento, não podemos analisar bilhões de parâmetros em uma rede geradora gigantesca e obter um catálogo organizado de todos os padrões que a rede aprendeu (Podell et al., 2023). Na década de 2010, quando as redes neurais eram mais simples e menores, os cientistas conseguiram visualizar o que seus neurônios aprendiam. Por exemplo, a Figura 5 mostra os recursos aprendidos por uma rede treinada para reconhecer objetos em fotografias: Visualização do Google Research mostrando os recursos aprendidos por camadas progressivas de uma rede treinada para reconhecimento de imagens. As primeiras camadas aprendem características básicas, como bordas e texturas (veja a página anterior), e as camadas posteriores aprendem a aparência de partes de objetos e objetos inteiros. Uma rede aprende primeiro a reconhecer as características básicas antes de avançar para o reconhecimento de objetos. Infelizmente, a arquitetura das redes generativas que sintetizam imagens nos impede de “olhar para dentro” dessas redes e visualizá-las da mesma forma⁶.

⁶ Para obter uma visão geral dos métodos de visualização de redes profundas disponíveis, consulte Barla (2024).

Figura 5

Visualização do Google Research por camadas progressivas de reconhecimento de imagem



Observação. Adaptado de Olah et al. (2017)

Gostaria de concluir com uma citação relevante do meu livro de 2018 *AI Aesthetics* (Manovich, 2018). Embora naquela época as redes neurais profundas fossem usadas principalmente para classificação e recomendações de mídia, com a revolução da IA generativa ainda a quatro anos de distância, a análise que desenvolvi na seção do livro chamada “AI as a Culture Theorist” tornou-se ainda mais relevante hoje:

[Existe] uma diferença crucial entre um “teórico da cultura de IA” e um teórico/historiador humano. O segundo apresenta princípios explícitos que descrevem o funcionamento de uma área cultural... uma rede neural pode ser treinada para distinguir entre obras de diferentes artistas, estilistas ou diretores de cinema. E também pode gerar novos objetos no mesmo estilo. Mas muitas vezes não sabemos exatamente o que o computador aprendeu... Será que o uso crescente do aprendizado de máquina para criar novos objetos culturais tornará explícitos os padrões em muitos campos culturais existentes dos quais talvez não tenhamos conhecimento? (Manovich, 2018, p. 23)

Para mim, este potencial teórico é um dos aspectos mais interessantes e valiosos da IA generativa, mas teremos que esperar para ver se ele se concretizará no futuro. A IA visual é o quarto efeito significativo de *dados <-> conhecimentos* da Web, um acúmulo global de conteúdo cultural com hiperlinks em rede que começou a crescer rapidamente depois de 1993. Embora as pessoas compartilhem textos e imagens na Internet desde a década de 1970, esse processo ganhou velocidade depois de 1993, quando o primeiro navegador visual, o Mosaic, foi lançado em 23 de janeiro do mesmo ano.

D

Separar e Remontar

Venho observando várias repercussões do crescimento das informações na Web nos 30 anos subsequentes. Se quisermos situar o desenvolvimento da IA visual no início da década de 2020 nessa linha do tempo, aqui estão quatro desses efeitos. Certamente outros também podem ser citados, portanto, esta é apenas uma lista de tecnologias de desenvolvimentos tecnoculturais possibilitadas pela Web nas quais estou particularmente interessado:

1. O primeiro efeito é a mudança da organização categórica, hierárquica e estruturada das informações (exemplificada pelos catálogos de bibliotecas e pelos primeiros diretórios da Web) para os mecanismos de busca no final da década de 1990. Havia tanto conteúdo que organizá-lo de maneiras convencionais não era mais prático, e a busca se tornou o novo padrão. Observe que *a pesquisa na Web baseia-se em uma previsão do que será mais relevante para o usuário*, em vez de fornecer uma resposta precisa e definitiva. Além disso, a IA generativa também é preditiva – ela prevê possíveis textos, imagens, animações ou músicas em resposta à sua pergunta ou solicitação. O regime de certeza absoluta, ou seja, uma verdade versus uma mentira, típico da civilização humana, é substituído por previsões, à medida que a estatística se torna a base das ciências humanas no século XX e da ciência de dados e da IA nas últimas décadas.
2. O segundo efeito relevante é o aumento da popularidade da visualização de dados durante os anos 2000. O campo se consolidou por volta de 2005. Como parte desse desenvolvimento, o novo campo “visualização artística de dados” se desenvolve na mesma década, juntamente com outros novos campos culturais: arte de dados e design de dados. (Em nosso laboratório, criamos *Phototrails*, *Selfiecity* e *On Broadway* em 2012-2014. Essas foram as primeiras visualizações interativas de milhões de imagens do Instagram). Se a pesquisa tenta encontrar os itens mais relevantes no gigantesco universo de dados, a visualização tenta mostrar partes desse universo em uma única imagem, revelando padrões e conexões.
3. O terceiro efeito é o surgimento da “ciência de dados” como a disciplina principal da nova era do Big Data no final dos anos 2000. Embora muitos métodos empregados na ciência de dados já estivessem disponíveis há décadas, o rápido aumento de dados não estruturados nos anos 2000 motivou o desenvolvimento de um campo separado de ciência de dados - a nova e importante profissão da sociedade de dados. Minha própria versão desse estágio é a “analítica cultural”,

a ideia que tive em 2005 e na qual trabalhei durante os 15 anos seguintes em nosso laboratório. Nosso principal método era a visualização de dados, mas agora aplicada a extensas coleções de mídia de fotos, vídeos, filmes, mangás, capas de revistas, imagens do Instagram etc. Chamei esse método de *visualização de mídia*⁷.

⁷Veja os projetos em <http://lab.culturalanalytics.info>.

4. O próximo, mas certamente não o último, efeito do crescimento do conteúdo digital visual online é a IA generativa, que se tornou popular no início da década de 2020. O Dalle-e foi lançado em 2020, o MidJourney em 2022, o ChatGPT e o preenchimento generativo do Photoshop em 2023, e centenas de outras ferramentas existem atualmente. Um pouco antes, por volta de 2017, um método específico de IA para geração de mídia chamado GAN já havia se popularizado entre artistas digitais.

É importante mencionar que tanto a IA visual quanto a IA generativa em geral se baseiam em 20 anos de trabalho, com os primeiros artigos relevantes publicados em 2001. A ideia principal é usar o universo de conteúdo da Web como fonte de dados para o aprendizado de máquina, sem rotulá-lo, aparecendo no artigo de pesquisa publicado por volta daquela época.

Veamos que tipo de padrão é estabelecido por esses quatro efeitos. A pesquisa é o primeiro método para lidar com a nova escala de conteúdo na Web. A ciência de dados se concentra em encontrar padrões, relações, agrupamentos e exceções em *big data*, além de prever dados futuros. A visualização de dados tenta resumir os conjuntos de dados visualmente. E agora a IA generativa explora o “*big content*” de outra forma, gerando novo conteúdo que combina muitos padrões da mídia existente.

Em outras palavras, a IA generativa sintetiza um novo conteúdo que tem propriedades estatísticas semelhantes às do conteúdo existente. Mas não se trata de uma cópia do que já existe. A IA gera novo conteúdo (textos, imagens, animações, modelos 3D, música, canto etc.) interpolando entre pontos existentes no espaço latente. Esse espaço contém vários padrões e estruturas extraídos por redes artificiais de bilhões de pares imagem-texto, trilhões de páginas de texto e outras grandes coleções de artefatos culturais humanos existentes. A IA prevê o que pode existir entre esses pontos no espaço de padrões. Por exemplo, ela pode prever uma “pintura” feita pelos artistas A, B, C, usando técnicas D e E, com conteúdo F, G e E, com determinada atmosfera, cores M-N, proporção W, composição K etc.

É digno de nota que todos os três desenvolvimentos anteriores abordam o *big data* resumindo-o. A pesquisa na Web reduz bilhões de páginas da Web aos principais resultados. A visualização de dados os reduz a um diagrama. A ciência de dados os reduz usando estatísticas resumidas, análise de agrupamento,

regressão ou projeção de espaço latente. Mas a IA visual está fazendo algo novo. Ela também reduz primeiro o *big data* durante o aprendizado e então gera novos pontos de dados.

Uma maneira de resumir tudo isso é dizer que passamos da pesquisa probabilística para a geração de mídia probabilística: 1999 a 2022. Mas certamente a IA generativa não é o último efeito da existência de dados da Web; outros provavelmente surgirão no futuro. ■

REFERÊNCIAS

- ACM SIGGRAPH. (2022). *SIGGRAPH '22: ACM SIGGRAPH 2022 Conference Proceedings*.
- Barla, N. (2024, May 14). *How to visualize deep learning models*. Neptune.ai. <https://neptune.ai/blog/deep-learning-visualization>
- Bokov, A. (2014). *VKhUTEMAS training*. Pavilion of the Russian Federation at the 14th International Architecture Exhibition.
- Bokov, A. (2021). *Avant-garde as method: Vkhutemas and the pedagogy of space, 1920-1930*. Park Books.
- Corel Painter. (2024, July 5). In *Wikipedia*. https://en.wikipedia.org/wiki/Corel_Painter
- Manovich, L. (1992). Assembling reality: Myths of computer graphics. *Afterimage*, 20(2), 12-14.
- Manovich, L. (2002). *The language of new media*. MIT press.
- Manovich, L. (2013). *Software takes command*. Bloomsbury Academic.
- Manovich, L. (2018). *AI aesthetics*. Strelka Press.
- Mitchell, W. J. (1996). *City of bits: Space, place, and the Infobahn*. MIT press.
- Olah, C., Mordvintsev, A., & Schubert, L. (2017, November 7). Feature visualization: How neural networks build up their understanding of images. *Distill*. <https://doi.org/10.23915/distill.00007>
- Podell, D., English, Z., Lacey, K., Blattmann, A., Dockhorn, T., Müller, J., Penna, J., & Rombach, R. (2023). *SDXL: Improving latent diffusion models for high-resolution image synthesis*. arXiv. <https://arxiv.org/abs/2307.01952>
- Smith, A. R. (2001). Digital paint systems: An anecdotal and historical overview. *IEEE Annals of the History of Computing*, 23(2), 4-30. <https://doi.org/10.1109/85.929908>
- Smith, A. R. (2021). *A biography of the pixel*. MIT Press.
- Vkhutemas. (2020, June 25). *Main course*. <https://www.vkhutemas.ru/en/structure-eng/faculties-eng/main-course/>

Artigo recebido em 03 de julho de 2024 e aprovado em 14 de agosto de 2024