

O papel da inteligência artificial na pipeline completo de efeitos visuais no cinema contemporâneo

The role of artificial intelligence in the complete visual effects pipeline in contemporary cinema

Romualdo Amaral

Resumo

Este artigo examina o papel da inteligência artificial no fluxo de produção (pipeline) completo de efeitos visuais no cinema contemporâneo, com ênfase na integração prática de técnicas de aprendizado de máquina (machine learning, ML) a etapas de pré-produção, produção e pós-produção. Argumenta-se que a IA passou a operar como um conjunto de ferramentas de suporte, integradas aos processos já estabelecidos de Efeitos Visuais (visual effects, VFX), como rastreamento de câmera e objetos (tracking), roscopia (roto)/retoque e remoção digital (paint), simulação, renderização (rendering), composição digital (compositing) e entrega, reduzindo dificuldades operacionais e ampliando as possibilidades de experimentação criativa. A análise combina fontes técnicas (SIGGRAPH/ACM), documentação oficial de ferramentas e referências institucionais de governança (créditos profissionais, propriedade intelectual, consentimento e réplicas digitais). Quando dados quantitativos de economia de tempo/custo não são publicamente detalhados, essa limitação é explicitada, privilegiando-se a análise de evidências qualitativas e mecanismos técnicos documentados.

Palavras-chave: Inteligência Artificial; Aprendizado de Máquina; Efeitos Visuais; Fluxo de Produção; Rotoscopia; Redução de Ruído; Composição Digital; Ética e Direitos Autorais.

Abstract

This article examines the role of artificial intelligence (AI) across the complete visual effects (VFX) production pipeline in contemporary cinema, emphasizing the practical integration of machine learning (ML) techniques into pre-production, production, and post-production. It argues that AI has become a set of supporting tools integrated into established VFX workflows, including camera and object tracking, roscoping (roto), digital paint and object removal, simulation, rendering, compositing, and final delivery, reducing operational challenges and expanding opportunities for creative experimentation. The analysis draws on technical sources (SIGGRAPH/ACM), official tool documentation, and institutional guidelines addressing professional

credits, intellectual property, consent, and digital replicas. When quantitative data on time and cost savings are not publicly available in sufficient detail, this limitation is explicitly acknowledged, with emphasis placed on qualitative evidence and documented technical mechanisms.

Keywords: Artificial Intelligence; Machine Learning; Visual Effects; Production Pipeline; Rotoscoping; Denoising; Compositing; Copyright and Ethics.

1. Introdução

A expressão “efeitos especiais” costuma abranger, no uso cotidiano, tanto efeitos especiais práticos (special effects, SFX) quanto efeitos visuais digitais (VFX). Este artigo adota o recorte de VFX — por ser o campo em que a IA vem sendo incorporada de forma mais direta por meio de software, automação e modelos treináveis — sem desconsiderar que a integração entre o local de filmagem (set) e pós-produção depende de práticas de aquisição, dados e supervisão em produção. Essa dependência é reforçada por descrições de funções responsáveis pela integração entre as equipes de filmagem e pós-produção (por exemplo, funções ligadas a pipeline de imagem e gestão de dados entre set e pós), documentadas em guias de estúdio e perfis profissionais.

Entre essas tecnologias, destaca-se o aprendizado de máquina (machine learning, ML), área da inteligência artificial que permite desenvolver modelos capazes de identificar padrões a partir de dados. No contexto dos efeitos visuais, essas técnicas podem auxiliar tarefas como rastreamento, segmentação de imagens, redução de ruído e automação de processos repetitivos.

A adoção de IA em VFX não ocorre como substituição imediata do pipeline tradicional, mas como uma evolução incremental: ferramentas específicas passam a automatizar subtarefas (como propagação de recortes, síntese de pixels, denoise e tracking), enquanto estruturas de produção — prazos, entregáveis, aprovações e responsabilidades — permanecem ancoradas no fluxo de trabalho do audiovisual. Por isso, compreender “IA no pipeline” requer um olhar sistêmico: onde a tecnologia entra, que dados ela exige, quem valida o resultado e como o artefato produzido (máscaras de isolamento (mattes), camadas de renderização (render passes), cache de sim, modelos, versões) circula na cadeia até a entrega final.

Um indicativo da consolidação dessas tecnologias na indústria é a incorporação de IA a áreas reconhecidas por sua relevância técnica e impacto operacional. A redução de ruído (denoising) por ML, por exemplo, foi formalmente discutida em contexto de produção de longas (incluindo títulos de animação e VFX fotorrealistas) em apresentações técnicas associadas ao ecossistema SIGGRAPH, descrevendo o movimento de uma solução de P&D para uma ferramenta integrável em pipeline.

Da mesma forma, tanto empresas especializadas na prestação de serviços de efeitos visuais (vendedores) quanto fabricantes de ferramentas passaram a publicar documentação oficial de recursos “treináveis” pelo artista (como nós de ML em compositing) e de recursos “assistidos por IA” para roscopia e limpeza.



Figura 1 — Macroetapas de um pipeline de VFX e pontos transversais de apoio por IA/ML. Fonte: elaboração gráfica do autor para este artigo; síntese conceitual baseada em [10–12].

1.1 Procedimentos metodológicos

Este estudo caracteriza-se como uma revisão narrativa de caráter técnico-documental, fundamentada em publicações científicas, apresentações técnicas, documentação oficial de ferramentas e diretrizes institucionais. A análise prioriza aplicações documentadas de inteligência artificial no pipeline de efeitos visuais, distinguindo experiências de produção, funcionalidades anunciadas por fabricantes e possibilidades ainda experimentais. Não são realizadas estimativas próprias de produtividade ou redução de custos na ausência de dados quantitativos comparáveis.

2. O pipeline tradicional de efeitos visuais

O pipeline de VFX pode ser descrito como um sistema de fases interdependentes que organiza pessoas, software e dados para transformar intenções narrativas (roteiro e direção) em imagens finais. A literatura técnica e os guias do setor convergem em uma estrutura macro com pré-produção, produção (set) e pós-produção, incluindo desde planejamento e criação de elementos digitais de produção (assets) até composição e entrega.

Na prática, o pipeline contemporâneo é crescentemente não linear: decisões relacionadas aos efeitos visuais precisam ser antecipadas para reduzir os custos de alterações realizadas em etapas avançadas da produção, e isso aproxima pré-visualização (previs)/ visualização técnica (techvis)/ produção virtual (virtual production) de etapas de pós. Essa visão é consistente com descrições de virtual production como um fluxo em que visualização acontece “antes, durante e depois” da filmagem, e inclui previs, techvis e pós-visualização (postvis) como processos de visualização ligados ao VFX. [10]

A decomposição visual das etapas de um efeito (breakdown) sintético apresentado a seguir serve apenas para visualizar a articulação entre captura, representação geométrica e composição; não constitui registro de making-of nem comprovação de uso de IA em uma obra cinematográfica real.




Figura 2 — Breakdown fictício: imagem-base filmada (plate) com recorte por chave de cor (chroma key/chroma), modelo geométrico simplificado (proxy) em representação em linhas da geometria tridimensional (wireframe) e composição final. Fonte: ilustração sintética gerada pelo Autor em outubro de 2026; Representação didática, sem correspondência com uma produção cinematográfica real.

2.1 Papéis, entregáveis e responsabilidades

O pipeline é sustentado por papéis que variam por escala de produção, mas que podem ser descritos com relativa estabilidade. Funções como supervisão de VFX, coordenação de produção e edição de VFX aparecem como elementos centrais para organizar pessoas e entregáveis. Perfis profissionais ressaltam que o supervisor de VFX gerencia o trabalho e responde pela entrega criativa/técnica, enquanto coordenação organiza o fluxo de assets e informação no pipeline. A edição de VFX, tanto na produtora quanto nas empresas responsáveis pelos efeitos visuais, desempenha papel fundamental para transferência formal de materiais para VFX (turnover) de planos (shots) e gestão de versões e revisões de aprovação (reviews). [13–15]

Além disso, existe uma dimensão formal de títulos e créditos. Diretrizes publicadas pela Visual Effects Society propõem padronizações de créditos/títulos em VFX. Outras instituições (como a Producers Guild of America) descrevem a função de “Visual Effects Producer” e seu escopo de responsabilidades e elegibilidade a crédito. [16]; [17]




Figura 3 — Relação entre aquisição, turnover e execução por vendedores. Fonte: elaboração gráfica do autor para este artigo; síntese baseada nos processos descritos em [13–15].

3. Aplicações da inteligência artificial ao longo do pipeline

A IA no pipeline de VFX deve ser entendida como um conjunto de capacidades, geralmente derivadas de visão computacional e aprendizado de máquina, aplicadas em pontos de alto custo (tempo humano) ou alto custo computacional (render). Abaixo, descrevem-se aplicações por estágio, com atenção a requisitos de dados e à integração com ferramentas existentes.

3.1 Planejamento, conceitos e visualização

Em previs/techvis e em ambientes de virtual production, a visualização serve para tomar decisões cedo: bloquear câmera e ação, testar logística e comunicar intenção entre direção, fotografia e VFX. Documentações técnicas de virtual production listam previs, techvis e postvis como processos de visualização relevantes e recorrentes.

[10]

A inserção de IA aqui tende a ser indireta: aceleração de criação de versões (p.ex., geração rápida de fundo visual ou cenário de fundo (background), protótipos visuais, composições temporárias (temporary composites, temp comps)), automatização de recortes para comp temporário, e ferramentas que geram tracking/câmera e máscaras a partir de vídeo para construir cenas editáveis. Um exemplo explícito de ferramenta “pipeline-oriented” é o Flow Studio, da Autodesk, cuja documentação descreve uma solução capaz de transformar o material filmado (footage) em cena CG editável gerando exportáveis típicos (captura de movimento (motion capture, mocap), camera tracking, alpha masks, imagens limpas, sem determinados elementos de cena (clean plates) e passes) e integrando-se a softwares de criação de conteúdo digital (digital content creation, DCCs) via formato de intercâmbio de cenas (Universal Scene Description, USD). [11, 12]

Implicação: parte do “trabalho de base” do VFX (especialmente em shots de substituição de personagem) migra para mais cedo, permitindo previs/postvis mais ricos e alinhados com o que será entregue.

3.2 Aquisição de dados durante a produção

Embora muitas técnicas “em set” não sejam necessariamente IA, a qualidade dos resultados obtidos com ferramentas de IA na pós-produção depende da qualidade dos dados capturados: plate estável, metadados, referências de iluminação e medições. Guias de estúdio descrevem responsabilidades on-set (loais de gravação) ligadas ao pipeline de imagem e à comunicação entre set e pós (incluindo pipeline de cor (color pipeline), metadados e gestão de dados), reforçando que o pipeline é um sistema de continuidade técnica.

Ferramentas modernas, porém, já oferecem saídas computacionais assistidas (tracking, mattes, clean plates) a partir de footage — o que pode reduzir retrabalho mais adiante, desde que os dados capturados sejam coerentes.

3.3 Rastreamento (tracking), correspondência de movimento (matchmoving) e reconstrução de câmera

Nesta etapa, IA aparece principalmente na forma de modelos de visão que ajudam a estimar profundidade, segmentação e/ou tracking em cenários complexos. Em ferramentas que prometem “footage → cena editável”, o tracking de câmera é citado como um dos “export elements” do processo. Quando esses recursos são usados, a questão crítica é validação: falhas no rastreamento podem gerar retrabalho significativo nas etapas posteriores de composição digital e renderização (parallax e alinhamento inconsistentes). [11, 12]

3.4 Rotoscopia, mattes, paint e remoção de objetos

Em janeiro de 2026, a Adobe documentou um recurso de Object Mask assistido por IA no Premiere, com seleção visual de pessoas/objetos, refinamento de bordas e rastreamento. O fabricante diferencia esse recurso das Shape Masks, cujo tracking foi divulgado como até 20 vezes mais rápido em comparação com versões anteriores; tal valor não constitui benchmark independente de rotoscopia de longas de cinema. [23]

A rotoscopia é um dos exemplos mais claros de IA “como acelerador”. Em software de composição e de edição, há documentação explícita de que ferramentas de roto (rotoscopia) passaram a usar IA para acompanhar o movimento do assunto e reduzir refinamento quadro a quadro (p.ex., rotoscopia assistida). [5]

Dois paradigmas se destacam:

1) IA baseada em modelos previamente treinados (pretrained): o usuário aciona uma ferramenta e obtém uma propagação baseada em um modelo já existente (ex.: rotoscopia assistida e ferramentas de “fill” temporal). O

“Content-Aware Fill” em software de composição, por exemplo, é descrito como um processo temporalmente consciente e apoiado por IA para sintetizar pixels ao longo do tempo, reduzindo o esforço de remoção manual. [5]; [6]

2) IA “treinável pelo artista” (few-shot / exemplo): o usuário constrói pares “antes/depois” para treinar uma rede específica de sequência, replicando um efeito ou máscara. A documentação do CopyCat no Nuke descreve explicitamente esse mecanismo: a ferramenta “copia” efeitos específicos de sequência a partir de poucos frames, treina uma rede para replicar e salva o resultado como arquivo reutilizável (para inferência). [4]

Esse segundo paradigma é relevante porque muda a noção de “dataset” (Conjuntos de Dados): o dataset não é apenas um acervo massivo externo, mas pode ser um conjunto pequeno e curado de frames escolhidos por um artista.




Diagrama conceitual de ferramenta treinável por exemplos (não representa um algoritmo específico).

Figura 4 — Fluxo conceitual de aprendizagem supervisionada por exemplos aplicado a mattes e reparos. Fonte: elaboração gráfica do autor para este artigo; fundamentação técnica: [4].

3.5 Modelagem, texturização, rigging e animação

Na criação de assets, técnicas de aprendizado de máquina podem apoiar segmentação, reconstrução e geração assistida de materiais; em personagens, sistemas de captura sem marcadores e soluções de rigging (esqueleto/controladores de animação) automático podem fornecer bases editáveis para animação. A documentação atual do Flow Studio, por exemplo, descreve geração de personagens 3D, rigging assistido e exportação de movimento. Essas funcionalidades não equivalem à entrega automática de um personagem pronto para produção: topologia, anatomia, deformações, contatos, escala, direção artística e continuidade entre shots exigem revisão de especialistas. [11, 12]

Em animação, estimativas de movimento e transferência de performance podem acelerar a marcação inicial de movimentos (blocking) e versões preliminares. Por outro lado, o resultado pode falhar em oclusões, contatos e dinâmicas complexas. Em simulações físicas de fluidos, tecidos, cabelos e destruição, métodos aprendidos são uma frente de pesquisa e prototipagem; não devem ser apresentados como substitutos universais de solucionadores físicos de produção, na ausência de estudos comparativos públicos para cada uso.

3.6 Simulações e renderização

No render, a IA ganhou centralidade por meio do denoising: em vez de aumentar amostras até convergir, utiliza-se ML para remover ruído de Monte Carlo e obter imagem utilizável mais cedo. Uma referência industrial importante é a discussão, em ambiente SIGGRAPH, de como o denoising por ML foi implantado em pipelines de longas e em VFX fotorrealistas — com menção direta a produções como Toy Story 4, Ralph Breaks the Internet e Aladdin, além de descrever a transição de uma implementação de P&D para ferramenta de produção. [1, 3]

Entre as ferramentas amplamente documentadas, destacam-se duas soluções:

O denoiser da NVIDIA (OptiX) é descrito como “AI-accelerated”, voltado a reduzir o tempo necessário para obter um render de alta fidelidade com menos ruído, e fundamentado em pesquisa publicada pela empresa. O Open Image Denoise (OIDN), associado à Intel, é descrito como biblioteca de código aberto (open source) de denoise para imagens ray-traced; além disso, a própria Academy of Motion Picture Arts and Sciences reconheceu o trabalho vinculado ao OIDN com prêmio técnico em 2025, citando explicitamente a criação do OIDN e contribuições em denoise por redes do tipo U-Net. [7]; [8, 9]

3.7 Compositing e integração final

Em compositing, IA tende a atuar em três pontos: (a) geração/propagação de mattes e masks; (b) limpeza e remoção; (c) replicação de “repairs” consistentes em sequência. A documentação técnica do CopyCat é exemplar por afirmar explicitamente usos como garbage matting, beauty repairs e deblurring, com treinamento em poucos frames e aplicação no restante da sequência via inferência. [4]

No ecossistema de ferramentas “assistidas”, a documentação histórica da Runway descreve recursos de reconstrução digital de regiões da imagem (inpainting) para remoção de objetos no vídeo, embora o editor referido tenha sido descontinuado em julho de 2026. Isso exige diferenciar exemplos históricos de recursos atualmente disponíveis e avaliar limitações de controle, consistência e artefatos. [24]

Tabela 1 — Aplicações, oportunidades e limitações da inteligência artificial por etapa do pipeline de efeitos visuais.

Etapa	Tarefa típica	Ponto de intervenção	Condição / risco
Planejamento e Desenvolvimento Visual (visdev)	Painéis de referência visual (Moodboards), concept e testes de desenvolvimento	Assistência à geração de variantes	Risco: inconsistência estética e direitos de insumos.

Etapa	Tarefa típica	Ponto de intervenção	Condição / risco
	da aparência visual (lookdev)		
Previs / techvis	Blocking, câmeras, testes de viabilidade	Prototipagem e máscaras temporárias	Exige decisões de direção/fotografia e escala válida.
Set e aquisição	Plates, Imagens de alta faixa dinâmica (HDRI), lentes e metadados	Extração e organização assistidas	Aquisição adequada não é automaticamente IA.
Matchmove	Soluções de rastreamento (solves) de câmera/objeto, profundidade (depth)	Estimativas de tracking assistidas	Validar drift, parallax e distorção de lentes (lens distortion).
Roto / paint	Mattes, clean-up, holdouts	Segmentação, propagação, ML treinável	Bordas, cabelo, oclusões, cintilação (flicker).
Assets / texturas	Modelagem, lookdev, materiais	Geração e reconstrução assistidas	Revisar topologia, mapas e licenças.
Rig / animação	Deformação e atuação CG	Mocap sem marcadores, auto-rig, retarget	Contatos, atuação, deformação e direção.
FX / simulações	Fumaça, água, tecido, destruição	Apoio à pesquisa e prévias (previews)	Não substituir solucionador de simulação (solver) sem validação física.
Lighting / render	Variáveis arbitrarias de saída (arbitrary output variables, AOVs), path tracing, denoise	Denoisers aprendidos para ruído	Avaliar perda de detalhes e artefatos.
Compositing	Integração de passes e repairs	Treinamento por exemplo e masks	Color pipeline, temporalidade, controle de qualidade (QC).
Etapa	Tarefa típica	Ponto de intervenção	Condição / risco

Conform / entrega (delivery)	Revisão, versões, entregáveis	Triagem assistida (dependente do caso)	Assinatura técnica e criativa segue humana.
------------------------------	-------------------------------	--	---

Fonte: elaboração própria com base em [1–12, 23].

4. Estudos técnicos e aplicações comerciais de IA em VFX

Foram selecionados dois estudos técnico-industriais e um exemplo de plataforma comercial, representando diferentes aplicações da IA no pipeline de VFX: redução de ruído na renderização, automação de roscopia e retoque digital, e extração de elementos editáveis a partir de material filmado. As funcionalidades anunciadas por fabricantes são analisadas como descrições técnicas, e não como comprovação independente de ganhos de produtividade.

4.1 Denoising por ML em longas e VFX fotorrealistas

Um estudo particularmente relevante é a apresentação “Machine-learning Denoising in Feature Film Production” (SIGGRAPH history), que descreve uma experiência de implantação de denoise por ML em pipeline, citando o contexto de produções de longa-metragem e a necessidade de transformar uma solução de pesquisa em ferramenta operacional. [1, 3]

A importância industrial do denoising também é sugerida por reconhecimento institucional: a página de prêmios técnicos de 2025 da Academia registra premiação ligada explicitamente ao OIDN e a contribuições associadas a redes U-Net em denoise. Dado quantitativo (tempo/custo): não especificado publicamente em termos comparáveis entre produções; a evidência disponível enfatiza redução de tempo para obter imagem utilizável e viabilização de decisões mais rápidas de lighting/lookdev. [8, 9]



Figura 5 — Exemplo sintético de ruído visual e sua redução. Não apresenta resultados reais de IA ou medições comparativas. Fonte: simulação gráfica didática do autor elaborada para este artigo; contexto técnico: [1, 3, 7, 8].

4.2 Automação de roto/paint: colaboração LAIKA–Intel

A apresentação “Rotomation: AI Powered Rotoscoping at LAIKA” (SIGGRAPH Talks) descreve a colaboração entre o estúdio LAIKA e a Intel para acelerar tarefas de paint e roscopia, destacando a intenção de criar ferramentas que se encaixem no workflow e entreguem automação útil. [2]

Este caso é importante por três motivos:

1) Define o problema: roscopia/paint como gargalo de custo humano. 2) Define o critério de sucesso: integração com o fluxo real (não apenas em demonstrações experimentais). 3) Revela a dependência de dados: tarefas como roscopia exigem dados de referência anotados (ground truth), e a produção precisa equilibrar esforço de anotação versus ganho operacional (relação que pode variar por tipo de plate e por design de personagem). [2]

Dado quantitativo (tempo/custo): não especificado no material técnico público; a evidência concentra-se em viabilidade e integração ao pipeline.

4.3 Plataformas comerciais com saídas editáveis de VFX

Um terceiro eixo de evidência vem de ferramentas comerciais que descrevem explicitamente gerar elementos típicos de VFX a partir de vídeo: mocap, tracking, alpha masks e clean plates. A página do produto Flow Studio (anteriormente Wonder Studio) descreve esse escopo e destaca exportáveis e integração com ferramentas 3D populares. [11, 12]

Este caso é útil para entender uma tendência de pipeline: parte da “engenharia do shot” (mattes, tracking, passes) passa a ser obtida cedo e em formato editável, o que pode reposicionar o trabalho do artista para supervisão, refinamento e direção de qualidade, em vez de execução repetitiva.

Entretanto, os resultados gerados podem ser adequados para layout/postvis e iteração inicial, mas ainda requerem revisão e ajustes para padrão “final pixel” (qualidade exigida para a imagem final), sobretudo em shots de alto rigor técnico.



Os outputs permanecem editáveis; o artista verifica escala, parallax, bordas e continuidade.

Figura 6 — Integração de outputs editáveis extraídos de filmagem em ferramentas de VFX. Fonte: elaboração gráfica do autor para este artigo; baseada nas funções anunciadas pela Autodesk [11].

5. Impacto no fluxo de trabalho

A incorporação de IA tende a reconfigurar o pipeline em três dimensões: tempo (iterações), papéis (quem faz o quê) e governança (como rastrear decisões e garantir direitos).

5.1 Tempo, custo e qualidade

Os ganhos relatados publicamente são frequentemente qualitativos (redução de trabalho manual e aceleração de render/iterações). No denoise, por exemplo, os fabricantes descrevem redução do tempo necessário para obter resultados “visualmente menos ruidosos”, apoiando decisões mais rápidas de lighting/lookdev. Em roscopia, a documentação oficial enfatiza redução de refinamento frame a frame por propagação assistida por IA. Quando métricas exatas (percentual de economia, custo por shot) não são publicadas, recomenda-se tratar o impacto como dependente de contexto (tipo de plate, variação temporal, complexidade de edge, requisitos de estúdio e nível de aprovação).

5.2 Reconfiguração de papéis e entregáveis

A incorporação da IA amplia a demanda por competências relacionadas ao aprendizado de máquina, à integração de ferramentas e à supervisão técnica. Profissionais de pipeline, diretores técnicos e artistas especializados podem assumir responsabilidades adicionais relacionadas à preparação de dados, ao treinamento de modelos e à validação dos resultados. Porém, muitos papéis permanecem centrais. Perfis profissionais destacam que o supervisor de VFX mantém responsabilidade pela entrega e pelo gerenciamento do pipeline, e que a coordenação organiza o movimento de assets e informação. [13–15]

O impacto mais consistente é o deslocamento de esforço para:

curadoria de dados (selecionar frames para treinar; organizar fontes e referências); validação e correção (detectar falhas típicas de ML, como instabilidade temporal, “edge chatter” (oscilação das bordas de recorte), alucinações de textura); documentação e rastreabilidade (especialmente em projetos com múltiplos vendedores e ciclos de review intensos).

Tabela 2 — Responsabilidades, entregáveis e critérios de aprovação ao longo do pipeline de VFX.

Fase	Responsáveis (exemplos)	Entregáveis	Critério de aprovação
Pré-produção	Direção, fotografia, supervisão VFX	Briefs, techvis, testes e planejamento	Viabilidade criativa e técnica.
Filmagem / aquisição	Supervisão, data/image teams, produção	Plates, referência de luz, tabelas de conversão de cores (lookup tables, LUTs), lens data	Consistência do set à pós.
Turnover	VFX editor, coordenação, supervisão	Quadros adicionais de segurança (handles), plate IDs, notas, versões	Versão aprovada e rastreável.
Execução / pós	Artistas e supervisors CG/comp/FX	Assets, mattes, sims, renders, comps	Revisões de qualidade; final pixel.
Entrega / créditos	Produção, supervisão, jurídico	Finals, conform, delivery e créditos	Direitos, registros, aceite do cliente.

Fonte: síntese elaborada para o artigo baseada em [13–17].

6. Desafios e limitações

6.1 Dados, treinamento e robustez

A IA não elimina a necessidade de dados; frequentemente a intensifica. Ferramentas treináveis por exemplo requerem pares “antes/depois” e seleção cuidadosa de frames; a própria documentação de CopyCat descreve treinamento a partir de um pequeno conjunto de frames para replicar um efeito e salvar um modelo. Em denoise e outros modelos, o desafio inclui evitar artefatos e instabilidade temporal (flicker), tema recorrente em práticas e em evolução de ferramentas (inclusive em discussões públicas sobre suporte temporal). [4]

6.2 Integração e dívida técnica

Resultados de IA podem acelerar tarefas iniciais, mas também podem adicionar dívida técnica se não forem validados cedo: tracking defeituoso, matte instável e reparos inconsistentes tendem a “contaminar” etapas posteriores. Assim, a integração correta exige testes, padrões internos e gates claros — algo alinhado com recomendações gerais de pipeline de VFX sobre decisões técnicas (formatos,

gestão de versões e consistência) para reduzir falhas e inconsistências nas etapas finais da produção.

6.3 Direitos autorais, réplicas digitais e créditos

Três frentes se destacam:

Treinamento e copyright. O U.S. Copyright Office publicou relatórios em série sobre IA e copyright; a Parte 3 aborda treinamento de modelos generativos e os usos de obras protegidas no desenvolvimento de sistemas. Isso é relevante para VFX quando modelos generativos entram em etapas de criação visual (texturas, composição de elementos, concepção), exigindo avaliação de licenças, rastreabilidade da origem dos dados (provenance) e riscos de contaminação de IP. [18–20]

Imagem, voz e “digital replicas”. A Parte 1 do relatório do U.S. Copyright Office discute “digital replicas” como tema central de política e direito, ressaltando preocupações com representações realistas e falsas de indivíduos. Em paralelo, diretrizes sindicais para consentimento e disclosure (declaração) em usos de replicação digital aparecem em materiais de SAG-AFTRA, reforçando que o uso de IA em performance/face/voz tem implicações contratuais. [18–20]; [21]

Créditos e atribuição. Diretrizes de padronização de títulos/créditos em VFX foram publicadas pelo VES (Visual Effects Society / Sociedade de Efeitos Visuais), e códigos de crédito de associações de produção também descrevem funções como VFX Producer. Com IA, cresce a importância de declarar corretamente o trabalho humano (o que foi “feito por”, “assistido por” ou “gerado e refinado”), tanto por ética profissional quanto por compliance (conformidade com normas e obrigações) e transparência interna. [16, 17]

Além disso, há discussões institucionais sobre IA no ecossistema de premiações; por exemplo, comunicados oficiais sobre regras do Oscar incluem menções a IA generativa em contexto de elegibilidade e avaliação, indicando que a indústria procura enquadrar o tema sem reduzir a análise à ferramenta em si. [22]

ETAPA	OPORTUNIDADE	RISCO A VALIDAR
Planejamento	variações rápidas de conceito	proveniência e incoerência de look
Set / tracking	organização e extração de dados	drift / lens / captura insuficiente
Roto e paint	propagação de masks; repairs	edge chatter, oclusões e flicker
CG e render	iteração visual; denoising	viés visual, perda de detalhe
Compositing / entrega	repetição de ajustes e QC	consistência temporal e rastreo

Matriz conceitual: categorias qualitativas, sem valores estatísticos de produtividade.

Figura 7 — Matriz qualitativa de oportunidades e riscos ao longo das etapas de VFX.

Fonte: elaboração gráfica do autor para este artigo; síntese analítica do texto (sem dados estatísticos).

A Figura 7 apresenta uma síntese qualitativa das principais oportunidades e dos riscos associados à integração da inteligência artificial nas diferentes etapas do pipeline de efeitos visuais.

7. Conclusão

A inteligência artificial já opera como uma camada estrutural do pipeline contemporâneo de VFX: não apenas como “novidade”, mas como infraestrutura de apoio à produtividade e recurso de otimização computacional, especialmente na redução de ruído durante a renderização (denoising), com efeitos práticos na velocidade de iteração e na forma como decisões criativas são testadas e aprovadas. Evidências técnicas em SIGGRAPH mostram que, em áreas como denoising e roscopia assistida, houve esforço explícito para mover soluções de pesquisa para o mundo da produção — o que reforça a tese de que a transformação é incremental, mas consistente. Contudo, a adoção sustentável exige três condições: (1) integração com o pipeline (formatos, versões, validação e gates), (2) governança de dados e direitos (treinamento, IP e consentimento), e (3) clareza de responsabilidades e créditos. A IA, nesse sentido, não simplifica o pipeline por si só: ela desloca complexidades — do trabalho manual para a curadoria, validação e controle de riscos — e torna ainda mais crítico o papel de supervisão e de produção organizada.

Referências

Fontes acadêmicas, técnicas e institucionais. URLs identificadas em 8 out. 2026; links de documentos PDF podem depender de políticas do servidor. Acesso indicado para fins de consulta e rastreabilidade.

- **[1]** DAHLBERG, Henrik D.; ADLER, David M.; NEWLIN, Jeremy. Machine-learning denoising in feature film production. ACM SIGGRAPH Talks, 2019. DOI: 10.1145/3306307.3328150. [Disponível em: https://disneyanimation.com/publications/machine-learning-denoising-in-feature-film-production/](https://disneyanimation.com/publications/machine-learning-denoising-in-feature-film-production/)
- **[2]** STRINGER, Jeff et al. Rotomation: AI Powered Rotoscoping at LAIKA. ACM SIGGRAPH Talks, 2020. DOI: 10.1145/3388767.3407315. [Disponível em: https://history.siggraph.org/wp-content/uploads/2022/08/2020-Talks-Stringer-Rotomation-AI-Powered-Rotoscoping-at-LAIKA.pdf](https://history.siggraph.org/wp-content/uploads/2022/08/2020-Talks-Stringer-Rotomation-AI-Powered-Rotoscoping-at-LAIKA.pdf)
- **[3]** VOGELS, Thijs et al. Denoising with Kernel Prediction and Asymmetric Loss Functions. ACM Transactions on Graphics, v. 37, n. 4, artigo 124, 2018. DOI: 10.1145/3197517.3201388. [Disponível em: https://doi.org/10.1145/3197517.3201388](https://doi.org/10.1145/3197517.3201388)
- **[4]** THE FOUNDRY. Nuke Reference Guide: CopyCat. Documentação técnica, s.d. [Disponível em: https://learn.foundry.com/nuke/content/reference_guide/air_nodes/copycat.html](https://learn.foundry.com/nuke/content/reference_guide/air_nodes/copycat.html)

- [5] ADOBE. Roto Brush and Refine Matte in After Effects. Documentação, s.d.
Disponível em:
<https://helpx.adobe.com/after-effects/desktop/roto-brush-and-refine-matte/roto-brush/roto-brush-refine-matte.html>
- [6] ADOBE. Use Content-Aware Fill to remove unwanted objects from your video. Documentação, s.d. Disponível em:
<https://helpx.adobe.com/after-effects/desktop/remove-objects-from-your-videos/content-aware-fill.html>
- [7] NVIDIA. NVIDIA OptiX AI-Accelerated Denoiser. Documentação técnica, s.d. Disponível em: <https://developer.nvidia.com/optix-denoiser>
- [8] INTEL. Intel Open Image Denoise: Documentation. Documentação técnica, s.d. Disponível em:
<https://www.openimagedenoise.org/documentation.html>
- [9] ACADEMY OF MOTION PICTURE ARTS AND SCIENCES. Scientific & Technical Awards: 2025. Comunicado institucional, 2025. Disponível em:
<https://www.oscars.org/sci-tech/ceremonies/2025>
- [10] EPIC GAMES. What Is Virtual Production? Documentação institucional, s.d. Disponível em:
<https://www.unrealengine.com/en-US/explainers/virtual-production/what-is-virtual-production>
- [11] AUTODESK. Flow Studio: Overview. Descrição oficial de funcionalidades, s.d. Disponível em: <https://www.autodesk.com/products/flow-studio/overview>
- [12] AUTODESK / WONDER DYNAMICS. Getting Started with Character Creation in Flow Studio. Documentação, s.d. Disponível em:
<https://help.wonderdynamics.com/character-creation-getting-started/>
- [13] SCREENSKILLS. VFX Supervisor: Job Profile. Guia profissional, s.d. Disponível em:
<https://www.screenskills.com/job-profiles/browse/visual-effects-vfx/on-set/vfx-supervisor/>
- [14] SCREENSKILLS. Production Coordinator (Visual Effects): Job Profile. Guia profissional, s.d. Disponível em:
<https://www.screenskills.com/job-profiles/browse/visual-effects-vfx/production-management/production-coordinator-visual-effects-vfx/>
- [15] SCREENSKILLS. VFX Editor: Job Profile. Guia profissional, s.d. Disponível em:
<https://www.screenskills.com/job-profiles/browse/visual-effects-vfx/production-management/vfx-editor/>
- [16] VISUAL EFFECTS SOCIETY (VES). Titles Release / Credit Guidelines. Documento institucional, 2014. Disponível em:
<https://vesglobal.org/wp-content/uploads/2014/07/titles-release.pdf>
- [17] PRODUCERS GUILD OF AMERICA. Producing Credits for Feature Films: Code of Credits. Guia profissional, s.d. Disponível em:
<https://producersguild.org/code-of-credits-feature-films/>

- **[18]** U.S. COPYRIGHT OFFICE. Copyright and Artificial Intelligence. Portal institucional, s.d. [Disponível em: https://www.copyright.gov/ai/](https://www.copyright.gov/ai/)
- **[19]** U.S. COPYRIGHT OFFICE. Copyright and Artificial Intelligence, Part 1: Digital Replicas. Relatório, 2024. [Disponível em: https://www.copyright.gov/ai/Copyright-and-Artificial-Intelligence-Part-1-Digital-Replicas-Report.pdf](https://www.copyright.gov/ai/Copyright-and-Artificial-Intelligence-Part-1-Digital-Replicas-Report.pdf)
- **[20]** U.S. COPYRIGHT OFFICE. Copyright and Artificial Intelligence, Part 3: Generative AI Training. Versão pré-publicação, 2025. [Disponível em: https://www.copyright.gov/ai/Copyright-and-Artificial-Intelligence-Part-3-Generative-AI-Training-Report-Pre-Publication-Version.pdf](https://www.copyright.gov/ai/Copyright-and-Artificial-Intelligence-Part-3-Generative-AI-Training-Report-Pre-Publication-Version.pdf)
- **[21]** SAG-AFTRA. Artificial Intelligence: Member Resources. Informações sindicais, s.d. [Disponível em: https://www.sagaftra.org/contracts-industry-resources/member-resources/artificial-intelligence](https://www.sagaftra.org/contracts-industry-resources/member-resources/artificial-intelligence)
- **[22]** ACADEMY PRESS OFFICE. Awards Rules and Campaign Promotional Regulations Approved for 98th Oscars. Comunicado, 2025. [Disponível em: https://press.oscars.org/news/awards-rules-and-campaign-promotional-regulations-approved-98th-oscars](https://press.oscars.org/news/awards-rules-and-campaign-promotional-regulations-approved-98th-oscars)
- **[23]** DRUSS, Jason. New AI-powered video editing tools in Premiere, plus major motion design upgrades in After Effects. Adobe Blog, 20 jan. 2026. [Disponível em: https://blog.adobe.com/en/publish/2026/01/20/new-ai-powered-video-editing-tools-premiere-major-motion-design-upgrades-after-effects](https://blog.adobe.com/en/publish/2026/01/20/new-ai-powered-video-editing-tools-premiere-major-motion-design-upgrades-after-effects)
- **[24]** RUNWAY. Inpainting. Documentação histórica de recurso descontinuado em 30 jul. 2026. [Disponível em: https://help.runwayml.com/hc/en-us/articles/19155664495379-Inpainting](https://help.runwayml.com/hc/en-us/articles/19155664495379-Inpainting)